

分类号: TP243

密 级: 公开

学校代码: 10363

学 号: 2220320123



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题目 基于深度学习的电缆线芯数
量检测系统的研究

论 文 作 者 丁家乐

校 内 导 师 徐晓光 教授

校 外 导 师 郝旭耀 工程师

专业学位类别 电子信息

研究方向(领域) 检测技术与自动化装置

论文提交日期: 2025 年 5 月 12 日

分类号：TP243

密 级：公 开

单位代码：10363

学 号：2220320123

题 目 基于深度学习的电缆线芯数量检测系统的
研究

题 目 Research on Deep Learning based Cable
Core Count Detection System

学 生 姓 名： 丁家乐

校 内 导 师： 徐晓光 教授

校 外 导 师： 郝旭耀 工程师

专 业 学 位 类 别： 电子信息

研究方向（领域）： 检测技术与自动化装置

论 文 答 辩 日 期： 2025 年 5 月 12 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律结果由本人承担。

学位论文作者签名：丁家乐

日期：2025 年 5 月 15 日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 _____ 年解密后适用本版权书。

本学位论文属于

不保密 ☒。

学位论文作者签名：丁家乐

指导教师签名：徐晓光

日期：2025 年 5 月 15 日

日期：2025 年 5 月 15 日

基于深度学习的电缆线芯数量检测系统的研究

摘 要

电缆是电力传输的主要载体,实现电缆线芯的智能化检测能够有效推动电缆制造业的信息化发展。由于不同种电缆线芯的排列各不相同且其截面存在纹理噪声干扰,线芯总体呈现尺寸小、分布密集的特点。传统方式依赖人工计数线芯数量的方式不仅耗时耗力,而且容易出现计数错误,效率低下。因此实现电缆线芯数量实时自动检测,提高电缆线芯数量检测效率、降低检测成本,成为当前电缆生产工业中急需解决的问题。本文提出了一种基于 SRW-YOLO 的电缆线芯数量检测系统,旨在实现电缆线芯数量的智能化检测。主要研究内容如下:

首先,针对目前公开电缆线芯数据集稀缺的现状,本研究通过产学研合作模式联合尚纬电缆厂构建电缆截面数据集。采用标准化切割工具采集电缆截面样本后利用 LabelImg 实现线芯特征标注,并采用翻转、旋转、放缩等方式进行数据增强,以提高数据集的广泛性。而后针对电缆线芯的特点提出新的检测模型 SRW-YOLO。该模型以 YOLOv8n 模型为基线,分别在 Backbone 部分和在 Head 部分通过引入 GCELAN 特征网络提取模块和 COMKER 多尺度特征融合模块,在降低模型计算量和参数量的同时增强模型特征提取和梯度流通的能力,随后选用 WIoU-v2 损失函数,以改善密集场景下线芯目标的漏检以及重叠问题,进一步提高了模型的检测性能。

其次,通过消融实验和不同算法对比实验可以看出 SRW-YOLO

模型对 141840 个线芯标签的检测准确率达到了 99.6%。其召回率、mAP@0.5 以及 mAP@0.5-0.95 分别为 99.6%，99.6%和 81.2%。而后结合电缆线芯实际情况通过应用 IoU 阈值，能有效滤除假检测，提升检测精度。热力图和检测结果显示，相较于 YOLOv8 和其它 YOLO 检测模型，SRW-YOLO 对线芯注意力有明显提升，检测效果更好。

最后，基于 PyQt5 软件搭建了电缆线芯数量在线检测系统。该系统可支持静态图片检测、视频检测以及开启摄像头实时性检测。检测结果可视化，可将检测时间、线芯位置以及数量统计显示在界面上，检测完成后可对检测后的结果进行保存处理，方便后续查看。满足了电缆生产环节对线芯质量的高时效与高精度需求，有效助力电缆生产企业提升产品质量与生产效率。

关键词：电缆线芯，数量检测，深度学习，密集对象，SRW-YOLO

RESEARCH ON DEEP LEARNING BASED CABLE CORE COUNT DETECTION SYSTEM

ABSTRACT

Cables are the main carriers of power transmission. Realizing the intelligent detection of cable cores can effectively promote the informatization development of the cable manufacturing industry. Due to the different arrangements of various cable cores and the interference of texture noise in their cross-sections, the cores generally exhibit the characteristics of small size and dense distribution. The traditional method of relying on manual counting of the number of cores is not only time-consuming and labor-intensive but also prone to counting errors and has low efficiency. Therefore, realizing the real-time automatic detection of the number of cable cores, improving the detection efficiency of the number of cable cores, and reducing the detection cost have become urgent problems to be solved in the current cable production industry. This paper proposes a cable core number detection system based on SRW-YOLO, aiming to achieve the intelligent detection of the number of cable cores. The main research contents are as follows:

First, in view of the current scarcity of publicly available cable core datasets, this study constructs a cable cross-section dataset in collaboration with Shangwei Cable Factory through the industry - university - research

cooperation model. After collecting cable cross - section samples using standardized cutting tools, LabelImg is utilized to annotate the core features. Data augmentation is carried out through methods such as flipping, rotation, and scaling to improve the comprehensiveness of the dataset. Subsequently, a new detection model, SRW - YOLO, is proposed according to the characteristics of cable cores. Based on the YOLOv8n model, this model introduces the GCELAN feature network extraction module in the Backbone part and the COMKER multi - scale feature fusion module in the Head part respectively. This reduces the computational load and the number of parameters of the model while enhancing its feature extraction and gradient flow capabilities. Then, the WIoU - v2 loss function is selected to address the issues of missed detections and overlaps of core targets in dense scenes, further improving the detection performance of the model.

Secondly, through ablation experiments and comparison experiments with different algorithms, it can be seen that the detection accuracy of the SRW-YOLO model for 141,840 core labels reaches 99.6%. Its recall rate, mAP@0.5, and mAP@0.5-0.95 are 99.6%, 99.6%, and 81.2% respectively. Then, by applying the IoU threshold in combination with the actual situation of cable cores, false detections can be effectively filtered out, and the detection accuracy can be improved. The heatmap and detection results show that, compared with YOLOv8 and other YOLO detection models,

SRW-YOLO has a significant improvement in the attention to cores and a better detection effect.

Finally, an online detection system for the number of cable cores is built based on the PyQt5 software. This system supports the detection of static images, video detection, and real-time detection by turning on the camera. The detection results are visualized, and the detection time, core position, and quantity statistics can be displayed on the interface. After the detection is completed, the detected results can be saved for convenient subsequent viewing. It meets the high-efficiency and high-precision requirements of the cable production process for the quality of cores, effectively helping cable production enterprises to improve product quality and production efficiency.

Ding Jiale (Electrical engineering)

Supervised by Professor Xu Xiaoguang

KEY WORDS: Cable cores, Quantity detection, Deep learning, Dense objects, SRW-YOLO

目 录

第 1 章 绪论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状.....	3
1.2.1 基于深度学习的目标检测算法研究现状	3
1.2.2 常见电缆缺陷检测研究现状	5
1.2.3 基于深度学习的电缆缺陷视觉检测研究现状	7
1.3 本文研究内容与章节安排.....	9
第 2 章 目标检测相关理论与算法基础.....	11
2.1 目标检测相关理论	11
2.2 典型 YOLO 检测算法.....	15
2.2.1 YOLOv5 检测算法	15
2.2.2 YOLOv6 检测算法	16
2.2.3 YOLOv8 检测算法	18
2.2.4 YOLOv10 检测算法	19
2.3 常见网络结构改进.....	20
2.3.1 GhostNet 网络结构.....	20
2.3.2 CSPNet 网络结构	21
2.3.3 Omni-Kernel 网络结构.....	22
2.4 本章小结	23
第 3 章 电缆截面数据集制作及 SRW-YOLO 检测模型构建	24
3.1 电缆截面数据集制作与分析	24
3.1.1 数据集采集	24
3.1.2 数据集制作	25

3.1.3 数据集分析	27
3.2 SRW-YOLO 检测模型构建	29
3.2.1 特征提取网络改进	29
3.2.2 融合多尺度特征模块改进	31
3.2.3 损失函数选择	33
3.3 模型评价指标	37
3.4 本章小结	38
第 4 章 基于 SRW-YOLO 的电缆线芯数量检测模型性能分析	39
4.1 实验环境设置	39
4.2 模型改进后的测试与分析	39
4.2.1 SRW-YOLO 模型训练结果	39
4.2.2 不同损失函数对比结果	40
4.2.3 消融实验对比结果	41
4.2.4 各算法对比结果	43
4.3 电缆线芯检测可视化结果分析	44
4.3.1 热力图分析	44
4.3.2 设置合适 IoU 值滤除	45
4.3.3 检测结果分析	46
4.4 本章小结	47
第 5 章 基于 SRW-YOLO 的电缆线芯数量检测系统	48
5.1 PyQt5 介绍	48
5.2 系统设计及测试	50
5.2.1 系统设计	50
5.2.2 系统测试	52

5.3 本章小结	53
第 6 章 总结与展望.....	54
6.1 总结	54
6.2 展望	55
参考文献.....	56
攻读学位期间发表的学术论文和科研成果.....	62
致谢.....	63

第 1 章 绪论

1.1 研究背景及意义

电缆是国民经济中最大的配套行业之一。电缆产品的种类十分众多、应用范围涵盖生活中各个方面，涉及到电力供应、建筑建设、电子通信、工厂生产制造等众多下游行业，其发展状况与国民经济发展水平息息相关。目前，我国已成为全球数一数二的电线电缆进出口国家。中商产业研究院发布了《2024-2029 年中国电线电缆行业调研及发展战略研究预测报告》^[1]中展示了关于电缆行业发展现状近些年来产量的变化如图 1-1 所示。2023 年我国电缆产量约为 6203 万千米，同比增长 4.7%。未来，随着可再生能源的发展和智能电网的建设，电缆需求将不断增长。根据中商产业研究院的首席分析师预测，2024 年我国电缆产量将达 6531 万千米。预计到 2026 年国内电缆行业需求规模有望达到 1.8 万亿元。




图 1-1 2019-2024 年中国电缆产量统计

我国作为全球最大的电缆产出国，出口量逐年增长，其中东南亚、中东、非洲、欧洲等地区是主要出口市场。近两年，尽管受新冠疫情影响，电缆的出口量及销售收入增速放缓。但是在后疫情时代，随着国内经济的快速复苏，传统产业、战略性新兴产业以及高端制造业开始逐渐向数字化转型升级，这给电缆行业带来

了新的机遇，2023 年我国电缆出口量 233 万吨，同比增长 2.8%。从金额方面来看，2023 年我国电缆出口金额 1626.65 亿元，预计到 2026 年全球对电缆的市场需求将会达到 2300 亿美元。根据十四五国家对电缆的主要应用领域的规划来看，我国电线电缆行业将不断向着“产业基础高级化、产业链现代化”的方向迈进。

电缆为国家 CCC 强制认证产品，其质量事关国家战略性经济和国民生命安全，一旦出现质量问题，就会产生无法估量的后果。比如之前的“西安地铁奥凯问题电缆事件”发生之后，国家质检总局关于电缆的质量抽查有了新的规定，要求全国各地务必针对电缆产品开启专项整治的要求，始终保持生产质量红线不能触碰的原则，鼓励相关企业优化生产工艺，保证电缆产品的质量提高同时更注重环保。随后国家市场监督管理总局通报了 2022 年电缆产品质量国家监督抽查情况^[2]：在抽查产品中的不合格率为 2.8%，较上次抽查下降 0.5 个百分点。抽查中该产品近 3 次抽查不合格率分别为 5.0%、3.3%、2.8%。通报显示，本次抽查检验的河北、山西、北京等 29 个省（区、市）3325 家电缆企业生产的 3334 批次中。针对涉及架空绝缘电缆、塑料绝缘控制电缆、挤包绝缘低压电力电缆等 6 个品种，分别进行抽查后共发现 93 批次产品不合格，抽查不合格率为 2.8%，通过分析调查发现不合格的原因主要有以下三点：一是原材料质量不符合要求，二是生产工艺不当，三是结构设计不合理。为保证电缆市场的健康发展，对电缆产品的质量检测和追踪显得尤为重要，迫切需要研发便捷、快速、准确、智能的新型电缆检测技术和装备。

电缆通常由绝缘层和线芯两部分构成，根据其外形、绝缘皮和线芯材质可分为以下几种。如图 1-2 所示。其中聚氯乙烯（PVC）材质的绝缘皮具有一定的阻燃性和机械性能，且价格较低。橡胶材质绝缘皮具有一定的柔软性和弹性。聚乙烯（PE）绝缘皮具有良好的电气绝缘性能、化学稳定性。因此需要根据成本预算和使用的场景选择最为合适的电缆。




图 1-2 典型电缆示例

电缆在实际生产过程中,由于以及机器老化或者人工造作不当会导致缺陷电缆的产生,如果流入市场将会造成不可估量的后果,因此在生产过程中必须严格按照操作流程进行,对电缆线芯中导体的根数及导体质量等性能指标进行严格检验和控制,本文将深度学习 YOLO 检测算法结合电缆线芯特点提出 SRW-YOLO 算法能够很好的对电缆线芯的数量进行识别,这对电缆工业中生产出合格电缆有着重要的应用价值。

1.2 国内外研究现状

1.2.1 基于深度学习的目标检测算法研究现状

深度学习的核心思想是利用对人工神经网络的研究和发展,通过构建深层次的神经网络来解决问题。目前,基于深度学习的目标检测算法从检测方式上大致分为两大类^[3]:以 R-CNN(基于区域的卷积神经网络)系列为代表的双阶段目标检测和以 YOLO(只通过一次网络传播)系列为代表的单阶段目标检测。双阶段目标检测通常先通过一个区域提议网络 RPN 生成一系列可能包含目标的候选区域 RoI。然后,对这些候选区域进行分类和位置精修。将候选区域的特征提取出来,经过全连接层进行目标类别分类和边界框回归,得到最终精确的目标检测结果。而单阶段目标检测则是直接在整个图像的特征图上预测目标的类别和位置,没有生成候选区域这一单独的阶段,它通过一次前向传播就能够输出所有目标的检测结果,整个过程相对简洁。图 1-3 为基于深度学习的目标检测算法发展历程图。




图 1-3 基于深度学习的目标检测算法发展历程图

2014 年, Girshick 等人提出了 R-CNN 模型^[4]。该模型是基于深度学习的目标检测算法的开创性工作之一。它首次将深度学习应用于目标检测的候选区域生成与分类任务中。在 PASCAL VOC 数据集进行实验, 结果显示检测率从原来的

35.1%提升到了 53.7%，显著提高了目标检测的精度，但它由于每个候选区域都需要单独进行卷积神经网络的前向传播计算，导致计算量巨大，检测速度非常慢。随后 He 等人提出了 SPP - Net（空间金字塔池化网络）模型^[5]。通过引入空间金字塔池化层，保证传到下一层全连接层的输入固定。在 R - CNN 的基础上提出了改进，通过对 feature map 进行映射后结合 SPP 层处理，可以在一定程度上减少模型运算时间。2015 年，Girshick 等人在 R - CNN 的基础上再次提出了 Fast-R - CNN^[6]模型。引入了兴趣区域池化层（RoI Pooling），该池化层可以将候选区域的特征映射到固定大小的特征向量，从而允许在整个图像上只进行一次卷积神经网络的前向传播，极大地减少了模型计算量。与 R - CNN 相比，Fast R - CNN 的检测速度得到了显著提升，同时保持了较高的检测精度。但在实时性方面仍存在挑战。为此 Girshick 等人又提出了 Faster R - CNN 模型^[7]。提出了区域提议网络（Region Proposal Network, RPN），替代了传统的选择性搜索算法来生成候选区域。使得目标检测算法实现了真正意义上的端到端训练，进一步提高了检测速度和精度。在后续的研究和实际应用中得到了广泛的应用和深入的研究。2017 年，何凯明等人提出了 Mask R - CNN 模型^[8]。在 Faster R - CNN 的基础上增加了语义分割分支，不仅能够进行目标检测，还可以对检测到的目标进行像素级别的分割。Mask R - CNN 的提出使得目标检测算法在实例分割任务中取得了重大突破，为计算机视觉领域的多任务学习提供了新的思路和方法。在图像编辑、自动驾驶场景理解等领域，Mask R - CNN 能够提供更丰富的目标信息，有助于提高系统的整体性能和智能化水平。

2015 年，Redmon 团队提出 YOLO 算法^[9]。把输入的图像无规律的划分为固定大小的网格，每个网格负责预测该网格内是否存在目标以及目标的位置和类别，一次性检测方式提高了速度，但早期版本在小目标检测和边界框精度上有不足，随后 Redmon 等人再次提出了 YOLOv2^[10]。对 YOLO 进行改进，采用了新的网络结构 Darknet-19，提高了检测精度和速度，能够检测更多种类的目标。2018 年，Redmon 等研究员又设计出了 YOLOv3 网络^[11]。进一步改进网络结构，通过使用 Darknet-53 替换原来的骨干网络，进而提升了对小目标的检测能力。2020 年，Ultralytics 公司提出了 YOLOv5 算法^[12]。对 YOLO 系列进行了优化，包括网络结构、训练策略等方面，提供了不同的模型大小以适应不同的应用场景，具有较高的检测速度和精度。YOLOv6 是由美团视觉智能部推出的专注于检测精度和推

理效率适用于工业应用的算法^[13]。该算法使用了更为高效的 Efficient Rep 来替换原来的骨干网络，采用 Efficient Decoupled Head 使模型更为简洁，训练策略上，采用 Anchor-free 无锚范式，辅以 SimOTA 标签分配策略以及 SIoU 边界框回归损失来提高检测精度。2023 年，Ultralytics 公司又提出了 YOLOv8 算法^[14]。采用了新的骨干网络和检测头结构，提高了检测精度和速度；同时，还引入了一些新的数据增强和训练技巧，进一步提升了模型的性能。2024 年，清华大学研究团队提出了 YOLOv10 算法^[15]。提出了一个无 NMS 训练的一致双重分配的 YOLO 以及整体效率精度驱动模型架构设计策略，包括轻量级分类头、空间通道解耦下采样和大内核卷积等，以提高模型的效率和准确性。

总体来说基于深度学习的目标检测算法的发展历程主要是先从双阶段逐渐发展到单阶段的过程。双阶段算法以其高精度的特点在复杂目标检测任务中占据重要地位，而单阶段算法则凭借其快速的检测速度在实时性要求高的场景中得到广泛应用。随着技术的不断创新和发展，两种算法在相互借鉴和融合中不断改进，并且朝着多模态融合、轻量化、无监督和自监督学习等方向发展。

1.2.2 常见电缆缺陷检测研究现状

电缆作为电力传输与分配体系里的核心基础设施，其质量的好坏与电力系统能否安全、稳定地运行密切相关。在如今全球电力需求逐渐增大的情况下，保障电缆质量是否符合国家要求的标准成为当今电力工程和材料科学领域重点关注的研究方向。按照目前检测技术的手段大致分为以下三种：传统检测方法、超声波检测方法以及基于机器视觉的检测方法。

（1）传统检测方法

传统检测方法主要依托工人目视检查以及借助简易的测量工具例如放大镜等。观察像表面划伤、凹陷、裂缝等这类问题，但受主观因素影响大，并且极难察觉微小缺陷。在针对物体精度检测环节，通常会使用游标卡尺、千分尺等工具来实施测量。但是这种接触式测量的操作过程繁杂，还极易致使物体表面受损。

在国外，一些发达国家早期也运用传统检测手段。但随着工业自动化步伐的不断加快，原来传统人工检查的弊端越来越明显。早在 20 世纪中叶，部分欧洲国家的制造业企业开始引入简易的机械自动化设备来辅助人工检测，以此提升检测效率，反观国内，直至当下仍然有很多工厂采用视觉检查与手动测量工具相搭

配的模式来对物体缺陷进行检测。但是伴随着国内制造业的迅猛发展以及市场的需求的提高,传统检测方法已逐渐无法适应市场需求,加快检测技术的更新换代已成为当务之急的优化方向。

(2) 超声波检测方法

超声波检测方法由于不需要与被检测物体直接接触而避免了对检测物体产生磨损、划伤等损坏缺陷检测中具有重要地位。

何维晟等人^[16]在 2022 年针对高压电缆缓冲层烧蚀缺陷时会产生超声信号特征,为此选用超声技术来检测该信号从而避免因为烧蚀缺陷而造成巨大损失。同年王韵等人^[17]通过电缆局部放电的超声传播模型,可以有效分析检测位置和超声频率对局放超声信息获取的影响,从而可以提前预知电缆绝缘失效。方春华等人^[18]在 2024 年针对常规测量会损坏电缆硅橡胶界面问题,提出一种基于非线性超声的无损检测方法能够有效的评价电缆硅橡胶复合界面的压力状态。朱家豪等人^[19]在 2025 年对在通电条件下高压电缆断股损伤情况,选用激光超声对高压电缆进行检测并给出了最佳的频率范围。Yücel, MK 等人^[20]提出由换能器环激发的超声导波来检测电缆的缺陷,探究了缺陷尺寸对波传播的影响。Wu, YQ 等人^[21]在 2023 年针对铝芯钢增强(ACSR)电缆结冰的情况,提出了超声导波结合 PCA-EMD 方法可以对 ACSR 电缆的结冰监测具有很好的检测效果。

(3) 基于机器视觉的检测方法

机器视觉技术的蓬勃发展,为缺陷检测开辟了新的路径。此技术一般来说是先借助相机、镜头等成像装置,获取物体图像数据,随后运用常见的图像处理算法对所获图像加以处理,进而达成对检测物体外观缺陷、尺寸精度等质量指标的检测工作。

沈尹扩等人^[22]在 2020 年针对电缆导体横截面积的测量选用 Otsu 阈值分割结合数字形态学对电缆轮廓进行提取。刘硕等人^[23]针对电缆表面缺陷检测采用于基于轮廓跟踪法可以有效的提取出缺陷的面积和周长特征从而完成识别。王峰等人^[24]在 2024 年设计了一款基于机器视觉软件平台 VisionPro 开发,利用 SQL-Server 进行存储数据的检测系统,能够实现对电缆接头的缺陷检测与信息存储功能。吴伟等人^[25]在 2024 年为了对电缆局部绝缘材料老化的缺陷进行检测,提出了改进深度卷积神经网络缺陷识别方法,通过提取增强后的目标特征进行识别。

LI B 等人^[26]在针对寒冷天气下电缆表面结冰的情况采用了边缘检测技术中的 Canny 算子对采集的图像进行处理。Gou S 等人^[27]在 2024 年针对电缆间距缺陷提出了一种级联双深度卷积网络检测方法来精确测量电缆间距。

1.2.3 基于深度学习的电缆缺陷视觉检测研究现状

深度学习的核心就是依托对人工神经网络的深入研究并在此基础上通过搭建具有多层次结构的神经网络来实现问题的求解。人工神经网络架构如图 1-4 所示。深度学习的一个重要特征是通过融合低级特征，进而有效的识别出重要的特征要素。基于此特点可以为电缆缺陷检测领域带来了新的技术支持。在设置好训练参数后就不再依赖人工操作，深度学习模型自动对图像进行特征提取与识别后进行训练，输出训练好的模型就可以进行检测，可以进一步提升检测效率与检测精度。




图 1-4 人工神经网络架构

2021 年，Yi Xie 等人^[28]使用 VGG16 卷积神经网络来替代人工检查高压电缆缓冲层缺陷检测。结果证明该方法可以很好的对缓冲层缺陷进行检测。Zhou Z 等人^[29]在 2022 年提出了基于 YOLOv7 的桥梁缆索表面损伤检测方法，可以有效检测常见的桥接电缆缺陷，包括划痕、污垢和磨损等问题，Zhang, B 等人^[30]在 2023 年提出了基于深度学习的高压电缆铝护套类腐蚀缺陷定位检测。可以做到在检测复杂高压电缆附件结构的铝护套腐蚀情况也有不错的效果。同年 Min, SG 等人^[31]通过结合深度神经网络 DNN 和长短期记忆 LSTM 算法，提出了一个合并模型，通过现有电缆支撑桥梁的测量响应数据集验证所提出的方法的优越性。

Wang, WD 等人^[32]在 2023 年提出了基于深度学习的电缆振动识别系统。可以实现在复杂环境中无需标记即可可靠地识别电缆振动。Maeng Jemo 等人^[33]在 2023 则是根据电缆电晕放电的现象采用深度学习模型对这些图像进行分类和定位。显著提高了电晕放电诊断的效率和准确性。Wen Chen 等人^[34]在 2024 年使用 YOLOv5 算法制作了电缆识别系统,可以识别和定位目标物体。Liu, Q 等人^[35]在 2024 年提出了基于 ViTR-Net 的无监督视觉变压器轻量级重建网络,该网络可以用正常的斜拉电缆表面图像就可以实现对图像中缺陷区域的端到端定位。Jiang, TY 等人^[36]在 2024 年提出了一种基于语义分割和复杂性追踪算法的方法用于电缆振动频率估计的复杂背景分割方法。还有些研究者通过自编码器的方式进行检测,比如在 2021 年中, Wu Yang 等人^[37]训练了两个结合稀疏自动编码器和卷积神经网络的模型来估计老化位置和严重程度。由于自动编码器效率较低, Huang, ZH 等人^[38]在 2024 年提出了基于 Transformer 的高效编码器深度学习分割网络 Trans-DCN, 用来检测桥接电缆表面的缺陷。

也有些研究学者根据所检测物体的特点对 YOLO 检测模型的网络结构进行了针对性优化。Qu, X 等人^[39]在 2024 年针对于电缆到端子的连接关系,提出了基于 YOLOv8 的姿势检测模型 YOLOv8-Pose, 在目标较小和遮挡密集的环境中也可以有不错的检测精度和实时性能。同年 Chen, D 等人^[40]提出 YOLOv7 的铠装电缆缺陷检测网络算法 AWUCD-Net。替换主干网替、增加可变形卷积以及选用新的损失函数, 进而提高系统整体检测性能。

综上所述, 基于深度学习的检测方法虽在电缆表面缺陷(如腐蚀、老化等)识别方面取得系列突破性进展,但在电缆线芯的智能化检测领域仍有待深入。值得关注的是,随着计算机视觉技术的突破性发展, Xu, XG 等人^[41]在 2024 年提出了 YOLO-cable 模型,为电缆线芯的高精度轮廓识别与自动化计数提供了理论可行性与技术实现路径。为此本研究针对电缆线芯的特点在 YOLOv8n 检测模型的基础上通过优化网络结构、选用合适损失函数,提出了一种新的检测模型 SRW-YOLO,相较于其它典型的 YOLO 检测模型, SRW-YOLO 模型更加注重线芯的轮廓,可以避免因检测框过多而导致错检的情况发生,力求进一步提升电缆线芯检测的精准度与效率。

1.3 本文研究内容与章节安排

本文研究内容主要围绕电缆线芯数量检测来进行。鉴于目前没有电缆线芯的公开数据集，为此联合电缆工厂进行合作制作出电缆截面数据集，随后结合电缆截面数据集密集程度高、检测目标小的特点对 YOLOv8n 模型进行改进提出一种新的检测模型 SRW-YOLO，而后针对该模型进行测试后发现通过应用 IoU 阈值的方法进一步提高模型检测的准确度。最后利用 PyQt5 软件搭建了电缆线芯在线检测系统，为电缆线芯缺陷检测提供了新的解决方案。论文总体技术路线如图 1-5 所示。




图 1-5 论文总体技术路线

本文的章节安排如下：

第 1 章：绪论。本章首先介绍了电缆发展的目前现状和未来预测，然后介绍了基于深度学习的目标检测发展史并针对于常见的电缆缺陷检测列举了国内外常见的几种检测方法。接着通过研究其他学者基于深度学习的电缆缺陷检测现状提出了新的检测方向，最后给出了本文的章节安排。

第 2 章：目标检测相关理论与算法基础。本章首先介绍了卷积神经网络的基

本组成：卷积层、激活层、池化层以及全连接层。随后分析了 YOLOv5、6、8、10 系列检测算法的结构特点，接着对常见的几种网络改进结构进行介绍，本文中对模型的改进灵感也是来源于此。

第 3 章：电缆截面数据集制作及 SRW-YOLO 检测模型构建。本章主要是对数据集的采集、制作以及分析进行了说明，介绍了实验电缆截面数据集的由来。接着选择 YOLOv8n 作为基线算法，通过 Backbone 部分通过替换特征网络提取 GCELAN 模块，以降低模型参数量，Neck 部分添加融合多尺度特征 COMKER 模块增加模型检测能力，以及选择 WIoU-v2 版本的损失函数提高模型的边框回归性能，开发出新的检测模型 SRW-YOLO。最后介绍了本文所使用的几种评价指标。

第 4 章：基于 SRW-YOLO 的电缆线芯数量检测模型性能分析。本章是对于第 3 章所提出的模型进行性能分析，首先介绍了实验环境以及主要超参数设置，随后通过消融实验和与其它几种 YOLO 检测模型对比实验展示出所提出改进点的有效性，接着在测试可视化结果分析时设置合适的 IoU 值来滤除假检测框进一步提升检测精度，最终提出了适用于电缆线芯数量检测的高效模型——SRW-YOLO。

第 5 章：基于 SRW-YOLO 的电缆线芯数量检测系统。本章首先结合电缆线芯数量检测实际需求利用 PyQt5 软件进行搭建电缆线芯数量检测系统，随后将训练好的检测模型嵌入到模型后，打开检测系统界面进行功能测试，结果证明可以实现对电缆线芯数量的实时检测。

第 6 章：总结展望。总结本文工作的研究重点，并对本文工作的不足和下一步延伸进行了说明，为电缆线芯数量检测的下一步研究做出展望。

第 2 章 目标检测相关理论与算法基础

基于深度学习的目标检测方法与其它目标检测方法最大的不同就是卷积神经网络(CNN)的使用。神经网络通俗来说就是依照人类大脑的复杂神经结构进行模仿。这通常需要大量的数据来进行训练从而学习到识别特征。其结构主要由输入层、隐藏内层和输出层组成。此外深度学习的学习效果与模型的深度和复杂度是密不可分的,因此如何在提升算法模型检测精度的同时尽可能的降低模型的参数量成为目前研究的重点。

2.1 目标检测相关理论

(1) 卷积层

卷积层是 CNN 的核心构建块^[42],其作用是利用卷积运算提取输入数据的局部特征,对局部区域进行加权求和操作,从而得到特征映射。这种局部感知机制使得网络能够自动学习到数据中的不同特征模式,如图像中的边缘、纹理等。其数学表达式如下:

$$Y(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(i+m, j+n) \cdot W(m, n) + b \quad (2-1)$$

其中, X 是输入数据, Y 是输出数据, W 是卷积核权重,用于学习特征表示, b 为偏置项,用于调整每个位置的输出, i 和 j 分别表示输出特征图中的位置, M 和 N 是卷积核的尺寸。

(2) 激活层

激活层通过引入非线性变换^[43],以此达到增强神经网络的检测和全局表达的能力。由于卷积层等线性运算层的堆叠只能表示线性关系,而真实数据往往具有复杂的非线性特征,激活层便是对卷积层输出的特征映射进行非线性激活操作,使网络能够学习到数据中的非线性模式,从而提高模型的拟合能力。常见的激活函数有:

1, Sigmoid 函数

Sigmoid 函数输出值的范围是[0,1]。由于输出值的限制因此特意的对每个神经元的输出都进行了归一化处理,其函数表达式如式 2-2 所示:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2-2)$$

Sigmoid 函数常被用来作为输出模型，这是因为其图像梯度较为平缓，能够防止输出值出现跳跃情况，不过，当输入值过大或过小时，容易引发梯度消失问题。Sigmoid 函数的图像详见图 2-1 所示：




图 2-1 Sigmoid 函数图像

2, Tanh 函数

Tanh 函数的数学表达式如式 2-3 所示，当输入值接近于 0 的情形下，Tanh 函数的表现近似于线性变换。

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2-3)$$

与 Sigmoid 相比，Tanh 具有“以零为中心”的特性。以减少学习过程中的偏移，有助于数据的稳定性和收敛性。但是 Tanh 函数对权重初始化较为敏感，如果权重初始化不当，可能会导致梯度消失或爆炸问题。图像如下图 2-2 所示：




图 2-2 Tanh 函数图像

3, ReLU 函数

ReLU 提供了一种非常简单的非线性变换。表达式如式 2-4 所示，给定元素 x ，ReLU 函数被定义为该元素与 0 的最大值。

$$\text{ReLU}(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2-4)$$

ReLU 有效解决了 Tanh 函数所面临的梯度消失的问题，当输入值为正数的情况下，神经元不会出现饱和的现象。但是当输入值为负数时，其梯度值为 0。这会导致该神经元以及后续与之关联的神经元梯度恒定为 0，对任何数据都不再产生响应，最终使得相应参数始终无法得到更新。并且由于没有进行指数运算，计算复杂度较低，与 Sigmoid 函数不同的是 ReLU 函数的输出并非以 0 为中心。ReLU 函数的图像表示如图 2-3 所示。




图 2-3 ReLU 函数图像

4, Leaky ReLU 函数

Leaky ReLU 是一种修正线性单元，它在正数部分保持线性变化，而在负数部分引入一个很小的斜率（通常是一个很小的正数），以防止梯度消失问题。完美解决了 ReLU 当输入值为负时神经元会出现“死亡”的问题，Leaky ReLU 函数的表达式如式 2-5 所示。

$$\text{Leaky}(x) = \begin{cases} x, & x \geq 0 \\ \lambda x, & x < 0 \end{cases} \quad (0 < \lambda < 1) \quad (2-5)$$

函数中的 λ 需要通过经验进行人工赋值（一般设为 0.01），这里为了画图明显设置等于 0.1，函数的图像表示如图 2-4 所示。




图 2-4 Leaky ReLU 函数图像

(3) 池化层

池化层作为卷积神经网络（CNN）架构里的关键构成要素^[44]，在网络结构中发挥着不可或缺的作用。它的主要作用是对输入的数据进行下采样处理，从而减小数据的维度，还可以在在一定程度上保留重要的特征信息。根据操作方式主要分为两种：最大池化和平均池化。

最大池化遵循梯度总和维持恒定的准则。在正向传播阶段，会选取图像块（patch）中的最大值传递至下一层，而其余像素值则被直接摒弃。相应地，在反向传播过程里，梯度仅会径直传输至前一层中的特定某一像素，其它像素无法接收梯度，因而其它梯度值为 0，运用池化窗口进行操作就是选择四个值中的最大值，以此来保证检测图像中的最明显的特征保留下来。最大池化传播过程如图 2-5 所示。



图 2-5 最大池化传播过程

平均池化也满足梯度之和不变的原则，在正向传播过程时，就是把一个 patch 中的值进行平均处理后做 pooling，反向传播传播则是把某个元素的梯度等分为 n 份，然后将其分配给前一层，如此一来，便保证了在池化操作之前与之后梯度（残差）的总和始终维持恒定状态。平均池化传播过程如图 2-6 所示。



图 2-6 平均池化传播过程

(4) 全连接层

全连接层的作用是将前面层所提取的所有特征进行整合^[45]，通过全连接的神经元对特征进行综合处理，实现对数据的最终分类或回归预测。它将多维的特征映射转换为一维向量，并通过一系列的线性变换和激活函数得到最终的输出结果。其结构如下图 2-7 所示。




图 2-7 全连接层结构

2.2 典型YOLO检测算法

2.2.1 YOLOv5 检测算法

YOLOv5 在单阶段 YOLO 目标检测中具有里程碑意义的算法^[46]，相对于 YOLOv4 来说，YOLOv5 在一些特定的场景下准确性略低一点，但是在检测速度和模型的轻量化性能上有着明显的提升。可以有效地识别图像中的多个目标物体，并确定它们的位置和类别。因此一经问世就在目标检测领域获得了广泛的应用。

YOLOv5 在网络结构上采用了一系列优化策略^[47]。在骨干部分采用改进的 CSPDarknet53，通过 CSP 架构可以将特征图分成两部分，一部分进行常规卷积

运算，另一部分直接连接到后续层，这种设计可以在降低计算负担的同时依然维持住较高的检测精度；在 Nect 部分采用 FPN 和 PAN 结构，该结构能够高效融合不同层级的特征。还可以对骨干网络中不同层次特征进行上下采样与拼接操作，实现了高低层特征间的信息交互，让网络既能聚焦局部细节，又能兼顾全局信息，从而全方位提升目标检测的性能^[48]；除此之外还采用了 GIoU 损失函数，能够更好的预测出检测框减少误检的可能性进而提升检测精度。

这些改进共同使得 YOLOv5 相较于之前的 YOLO 检测版本具有更出色的计算效率和检测性能^[49]，此外，YOLOv5 拥有简洁、清晰的代码结构和完善的训练、测试、部署脚本，方便用户根据自身需求进行二次开发。YOLOv5 的网络结构图如图 2-8 所示。




图 2-8 YOLOv5 网络结构图

2.2.2 YOLOv6 检测算法

YOLOv6 是由美团视觉智能部开发的一款致力于工业应用的检测模型^[50]。它满足工业应用从模型训练、推理到多平台部署等一系列全链条需求。旨在同步

提升检测精度与推理效率，更好地适合工业实际生产的需要。

YOLOv6 的改进主要分为三大部分^[51]：创新性的在网络结构上引入了重参数化卷积。这种卷积是指将多个不同结构的卷积组合在一起，作用是在训练阶段使用复杂结构，在推理阶段则使用更简单的卷积进行运算。可以提高网络的性能的同时保持网络的高效性，减少推理时间；启用了新的骨干网络架构。在图像特征提取方面更加高效，更好地捕捉图像中的目标信息，为后续的目标检测任务提供高质量的特征信息；检测头采用了 Efficient Decoupled Head。主要作用是将分类和回归任务进行分离，这样就可以让每个任务都能够独立地进行学习和优化。此外，它还采用了无锚（Anchor-free）范式，降低了对锚框（Anchor）的依赖程度。利用这种简化了的检测头结构，在一定程度上规避了因锚框设置不当引发的检测问题，增强了模型检测的灵活性与准确性。

总的来说，骨干网络和颈部的重参数化技术使 YOLOv6 在推理阶段具有很高的效率^[52]。能够在保证精度的同时快速地处理目标检测图像或者视频数据。但是尽管有先进的特征提取和融合机制，在处理极小目标检测时，仍然可能存在特征提取不充分和定位不准确的问题。YOLOv6 模型的网络结构图如图 2-9 所示。




图 2-9 YOLOv6 网络结构图

2.2.3 YOLOv8 检测算法

YOLOv8 是 Ultralytics 团队提出的一种新的检测算法^[53]，更加偏向于工程实践，可支持图像分类、检测以及实例分割等任务。

YOLOv8 采用了全新的网络结构 YOLOX-P。能够更好的挖掘出图像的深层次特征^[54]，从而提升从输入图像中提取特征信息的速度；基于缩放系数提供了多个版本的不同大小的模型，用来满足不同场景需求对不同物体尺度的适配能力；在骨干部分将原来的 C3 结构替换为梯度更流畅的 C2f 结构，如此一来，即便模型面对存在遮挡、尺度变化显著的物体，也能够维持较高的检测精度；在 Head 部分则是换成比较主流的解耦头结构（Decoupled-Head）将分类与检测头分离，舍弃了之前的 Anchor-Based 更换为 Anchor-Free，能够有效应对更为复杂的场景。特别是在小物体检测以及其它不同尺度物体的检测任务中，提升了检测准确度。

YOLOv8 更偏向于工程实际运用和部署^[55]，其开放的网络架构方便开发者对其进行研究。因此在本文中采用 YOLOv8n 算法为基准算法开发出针对于电缆线芯数量检测的新型检测模型，YOLOv8 的网络结构图如图 2-10 所示。




图 2-10 YOLOv8 网络结构图

2.2.4 YOLOv10 检测算法

YOLOv10 是清华大学研究团队在 2024 年最新提出的一种致力于实时端对端的目标检测方法^[56]。目的是解决 YOLO 以前版本在后处理和模型架构方面的不足。通过消除非最大抑制（NMS）采用无 NMS 训练的一致双重分配以及优化各种模型组件，可以显著降低计算开销，提高模型检测性能。

以往的 YOLO 模型进行训练时，通常采用一对多的分配方式，其优点是产生了丰富的监督信号有利于获得上级性能^[57]，缺点是必须依赖 NMS 进行后处理，从而导致模型部署的推理效率降低。而 YOLOv10 采用了一致双重分配策略，一对一的分配只为每个地面实况分配一个预测，这样就可以很好的避免了 NMS 的后处理，但是相应的也会带来了额外的推理开销。为了抵消额外的推理开销 YOLOv10 对模型组件进行了优化，采用轻量化结构的分类头以及将空间下采样和通道转换操作解耦保留了信息率从而有更高的竞争力，此外由于网络架构变得复杂，YOLOv10 会对计算资源和存储资源有更高的要求^[58]。在训练和推理阶段对资源有限的设备存在不少的计算负担。YOLOv10 的网络结构图如图 2-11 所示。




图 2-11 YOLOv10 网络结构图

2.3 常见网络结构改进

2.3.1 GhostNet 网络结构

GhostNet 是华为诺亚方舟实验室提出的一种轻量级深度学习网络^[59]。正常情况下卷积神经网络在提取检测图像的特征点时，会生成大量的特征图，而特征图之间会存在明显的冗余现象。增大了模型的计算量。GhostNet 就是从卷积神经网络在提取图像特征会产生冗余特征图的特点出发，提出了一种廉价操作（cheap operation），通过线性变化的方式，以较低的成本生成大量 Ghost 特征图，如图 2-12 所示，相似的特征图用相同颜色的框标注起来，这些相似的特征图只需要进行简单的线性变换就能得到，这样就可以用很小的代价获得与普通卷积层相似的表现能力，有效地从原始特征中发掘所需信息，减少了计算量。




图 2-12 特征图可视化

在卷积神经网络中，为了提取足够丰富的特征，常常不得不采用大量的卷积核，这就会导致模型参数量呈爆炸式增长。为此 GhostNet 创造性的融合普通卷积和线性操作。具体的操作过程是先运用较小卷积核进行普通卷积操作，随后针对输出的特征图实施线性变换操作，得到与其相似的特征图，最后将这两部分特征图进行叠加，以获得高维的输出特征图。通过这种操作可以有效削减了模型参数量，减轻了计算负担。其中，由卷积运算和线性运算所构成的模块化组合被称作 Ghost 模块。理论上的参数压缩比与理论上的加速比几乎相同，但是线性运算的计算成本比常规卷积运算低很多。该模块的设计思路是通过先执行一次普通卷积后输出的特征图数量较少，以此降低计算量。在此基础之上，通过线性变换，输出包含一个恒等映射图以及 $s-1$ 个其它特征图。具体过程如图 2-13 所示。




图 2-13 普通卷积层与 Ghost 模块对比图

2.3.2 CSPNet 网络结构

在深度学习领域中，其架构持续向深度和广度拓展，网络计算量不断增大。为此 CSPNet 结构应运而生，CSPNet 结构主要由三个关键部分构成^[60]：特征图划分、局部路径和融合阶段。它的设计理念是在不牺牲太多准确性的情况下，减少计算量并增强网络的学习能力。其核心思想是将输入特征图按照通道维度进行划分为两部分，一部分直接进行卷积等操作，另一部分则经过局部稠密块（Dense Block）后再与前面的部分进行特征融合。如下图 2-14 所示。




图 2-14 CSPNet 网络结构

值得一提的是 CSPNet 并非单指一种网络结构，更是一种具备广泛适用性的可移植理念。它常与 ResNet、DenseNet 等网络架构相互结合，可以分割网络结构中的梯度流，使梯度流在不同的网络路径中传播，此外还可以基于网络设计经验以及对任务的深刻理解来优化网络结构，不仅能够高效利用特征图所携带的信息，还能有效规避过多的冗余计算，最后达到降低计算量与减少内存消耗的目的。

2.3.3 Omni-Kernel 网络结构

近年来，计算机硬件性能实现了跨越式的发展，但是传统操作系统在驾驭这些先进硬件资源时却困难重重。比如在使用多核心处理器时，常常出现使用效率低下、核心负载失衡（部分处理核心闲置，而部分核心却不堪重负）等问题。严重影响了多核处理器的整体计算效率。为此 Omni - Kernel 网络结构就被设计出来，旨在突破传统操作系统的局限性^[61]。主要依靠其创新性的架构设计，可以显著提升系统运行效率与资源利用率，并且可以适配不同类型应用在不同场景下的需求。其核心组件是 OKM 模块。该模块包含三个分支，分别为局部分支、大分支和全局分支。三个分支各自运算后的结果通过加法运算进行融合，然后借助一个 1×1 卷积操作将融合结果进一步整合，最终输出运算成果。OKM 模块结构图如图 2-15 所示。




图 2-15 OKM 网络结构

三个分支分别从全局、大尺度和局部三个不同的角度进行学习特征表示，能够有效地捕获多尺度感受野，对于处理多尺度退化的图像恢复任务也很有效，可适应不同退化程度和类型的图像。虽然采用了大核卷积，但通过把全核模块设置

在 Bottleneck 位置, 就可以减少了大核卷积带来的计算量增加, 在保证模型性能不变的同时提高了计算效率, 在实际应用中更具可行性。不仅如此, 该网络结构还具有广泛性。可以作为一个通用的模块插入到现有的卷积神经网络中, 与其它网络结构和方法相结合, 进一步提升模型的性能, 具有很强的可扩展性和兼容性。

2.4 本章小结

本章主要介绍基于深度学习的目标检测基础理论和典型的 YOLO 检测算法以及常见的几种网络结构改进方法。首先介绍了卷积网络中的卷积层、激活层、池化层以及全连接层的相关知识, 其次介绍了 YOLOv5、6、8、10 的网络结构特点, 最后介绍了 GhostNet、CSPNet 以及 Omni-Kernel 三种改进网络结构, 为后续网络模型改进奠定了理论基础。

第 3 章 电缆截面数据集制作及 SRW-YOLO 检测模型构建


电缆截面数据集具有线芯分布密集、体积较小的特点。选用常规的 YOLO 版本算法进行检测效果并不太好。为此，提出了以 YOLOv8n 为原型的 SRW-YOLO 算法模型。该模型可以使预测框在位置上更加贴合目标的真实框，有效防止了因真实框过多而导致预测框重叠的问题，从而提升了对电缆线芯的检测精度。

3.1 电缆截面数据集制作与分析

3.1.1 数据集采集

近年来电缆行业发展更为迅速，生产基地主要集中在无为、杭州、宁波、温州等地，其中安徽芜湖下辖无为市具有“全国电缆生产之乡”的美誉，是我国电缆行业产业集群中的四大基地之一。本文所使用电缆截面数据集是由安徽省无为市的尚纬电缆工厂提供电缆样品合作所得。

采用工厂中标准化切割工具（博尔特便携式多功能带锯）对电缆进行截面切割。相较于传统砂轮切割机面临着噪声大耗电多、火花四射安全隐患高、无法斜切角度不可调等缺点。博尔特带锯可以很好的避免上述问题。相较于传统砂轮切割机由于高速运转导致切割后的截面会产生火花烫伤发黑，博尔特带锯有 6 个不同转速档位可以根据实际物体切割需求进行选择，能够做到切割截面平整无烫伤、无毛刺飞边、无火花的切割效果。博尔特带锯结构如下图 3-1 所示。



(a) 博尔特带锯结构



(b) 工作中的带锯

图 3-1 博尔特便携式多功能带锯

根据线芯的数量可将采集到的电缆分为两种：单芯圆形电缆（线芯数量为 60 根）和三芯圆形电缆（线芯数量为 144）。考虑到后期应用到移动端进行使用，选用移动手机作为数据采集设备。将物距设定在 15 - 20 厘米的范围之内，图像格式被设置为.jpg 格式，图像分辨率为 3024×4032，两种电缆的结构如下图 3-2 所示。




图 3-2 电缆结构图

3.1.2 数据集制作

在完成图像采集工作后，经过去除由于采集过程中受到不可控因素的影响而采集到的不合格图像，总共采集到 208 张电缆截面图，其中包括 88 张单芯电缆图像和 120 张三芯电缆图像，由于数据集中电缆截面样本数量有限，为了提高检测精度和符合实际场景的需要，对所采集到的电缆样本进行了数据增强处理，经过数据增强后的数据集不仅提高了鲁棒性其检测结果也避免了过拟合的情况。最终得到电缆截面数据集样本总数量为 1300 张，数据增强使用的方法有翻转、旋转、放缩、亮度以及添加噪声的方法^[62]，其具体操作方式及参数见表 3-1 所示，图 3-3 为经过数据增强后的图片。

表 3-1 数据增强参数

序号	操作类型	操作参数
1	垂直翻转	\
2	旋转角度	-30-30
3	放缩处理	0.7-1.3
4	亮度调节	0.7-1.3
5	噪声调节	0-30




图 3-3 数据增强后的图片

随后采用 LabelImg 软件图像进行标注操作。LabelImg 是一款目前广泛使用的图像标注工具，主要功能就是对图像中的目标对象进行标注，从而生成高质量的标注数据集。可支持矩形框标注、多边形标注圆形标注和线条标注以及多边形图形标注，标注后的图像可保存为 PASCAL VOC 或者 YOLO 格式。PASCAL VOC 格式是以 XML 文件的形式存储标注信息，包括图像的文件名、尺寸、目标物体的类别、位置等。YOLO 格式则是以 TXT 文件的形式进行储存，每一行代表一个目标物体的标注信息，包括类别编号、中心坐标、宽度和高度等。本文中采用的是矩形框标注的 YOLO 格式，标签指定为 core，软件操作步骤如下：

- 1) 先下载好 LabelImg 软件后进行启动；
- 2) 在菜单/文件中单击“Change Save Dir(更改默认保存的注释文件夹)”进行保存路径预设值；
- 3) 点击“Open (打开单个图像)”或者“Open Dir(打开图像所在文件夹)”；
- 4) 点击“Create RectBox(选择标记类型)”；
- 5) 单击并释放鼠标左键以选择一个区域来标注矩形框；
- 6) 后面为了方便操作，可以使用鼠标右键拖动矩形框来复制或移动它；

7) 点击“Next Image(下一张图像)”继续标注, 最后点击保存按钮;

通过以上步骤对 1300 张电缆截面数据集进行标签标注工作后总共产生标签 141840 个, 其中单芯图像标签个数为 32400 个, 三芯图像标签个数标签为 109440 个, 随后按照 7:2:1 的比例随机分配为训练集、验证集和测试集三个部分^[63]。图 3-4 为 LabelImg 标注界面。




图 3-4 LabelImg 标注界面

3.1.3 数据集分析

在完成电缆截面数据集的制作后, 为深入剖析该数据集特性, 对其进行标签可视化处理, 以便从直观层面观察电缆截面数据集特征。




图 3-5 标签分析图

图 3-5 描述的是训练数据集中标签分布情况。 (m, n) 表示第一行第一个, 其它以此类推, $(1, 1)$ 表示训练集中标签为 **core** 的标签数据量, $(1, 2)$ 表示标签框的尺寸和数量, $(2, 1)$ 表示边界框中心点在图像中的位置分布情况。 $(2, 2)$ 表示训练集中目标高宽比例的分布状况。




图 3-6 标签对应图

图 3-6 是张颜色矩阵图, 它展示了目标检测算法在训练过程中预测标签之间的相关性。在这里主要是分析 YOLO 算法模型与电缆数据集的适配度如何。图形逻辑是线芯标签中心点坐标 x 和 y , 以及框的高宽间的关系, 单元格颜色的深浅表示模型对标签关联性的强弱, 矩阵中的颜色越深, 表示对应标签之间的相关性越强; 颜色越浅, 表示相关性越弱。对角线上的颜色表示每个标签的自身相关性, 通常都是最深的。第一行图表示中心点横坐标 x 的分布情况, 基本集中在整幅图的两边中心位置, 第二行图表明中心点纵坐标 y 的分布情况, 基本跟电缆线芯的分布一致, 第三行图则表示标注框宽的分布情况, 可以看到大部分框的宽的大小不到整幅图的一半, 第四行图表示标注框高的分布情况, 可以看到大部分框的高的大小也没有超过整幅图的一半。

从图 3-5 和图 3-6 可以看出自建电缆截面数据集的标签与真实线芯分布基本一致, 呈现出密集小目标检测数据集的典型特征。跟 YOLO 算法的适配度也很高, 这一特性使得后续提出的新型 YOLO 检测算法在基于此自建数据集开展训练与检测过程中, 能够高效学习电缆线芯的特征模式, 进而快速、精准地识别电缆中的线芯目标。

3.2 SRW-YOLO检测模型构建

本文针对于 YOLOv8n 的 Backbone 和 Neck 以及损失函数部分进行改进。在模型中引入基于 GhostNet 思想的特征提取网络 GCELAN 卷积模块替换原来的 C2f 模块^[64]；在 P2 特征层增加 SPDCConv 得到更多信息的图像特征后结合 CSP 思想和 Omni-Kernel 模块进行联合得到多尺度特征融合 COMKER 模块进行特征整合^[65]；最后通过比较 WIoU-v1、v2、v3，选择 WIoU-v2 版本的损失函数^[66]。经过上述改进，提出了一种 SRW-YOLO 模型。模型结构图如图 3-7 所示。




图 3-7 SRW-YOLO 网络结构图

3.2.1 特征提取网络改进

特征提取作为深度学习领域的核心概念之一，其本质上来说是从输入数据中提炼出能够表征数据本质的关键信息，进而增强模型对数据的理解与学习能力。在深度学习中，输入数据往往具有较高的维度这就给特征提取带来了一定的难度，而优质的特征能够提升模型对输入数据的理解从而提升预测或分类任务的准确性。因此一个高效的特征提取网络不仅能影响到算法的性能，更是决定模型能否

成功实现学习与推广的重要基石。

YOLOv8n 中使用 C2f 卷积模块来提取特征信息。该卷积模块主要由 1×1 的卷积层 Conv 和残差瓶颈结构 (Bottleneck) 组成。其网络结构如图 3-8 所示。首先通过一个 1×1 的卷积层 Conv 对输入的特征图进行通道维度的变换,以调整特征图的通道数,减少后续计算量并增加非线性能力。随后,特征图会进入一系列的残差瓶颈结构的处理。这些结构通常由多个 3×3 的卷积层组成,并在每个卷积层后接批归一化 (Batch Normalization) 和激活函数等操作,以加速模型收敛并进一步提升非线性表达能力。最后,通过一个卷积层 (Conv) 将处理后的特征图与输入特征图进行特征融合,确保输入输出特征图在通道维度上的一致性,从而实现特征信息的高效利用与融合。




图 3-8 C2f 模块

尽管 C2f 模块通过结构优化在一定程度上降低了计算量,但由于内部包含的多层卷积操作和残差连接机制对硬件计算能力及内存带宽有着较高的要求,在资源受限的边缘设备上可能难以实现高效部署。此外,该模块的结构复杂度较高,包含多个子模块(如 1×1 卷积层、残差瓶颈结构等)及非线性操作(如批归一化和激活函数),这不仅增加了模型的参数量和计算负担,还可能导致训练时间显著延长以及过拟合风险上升。因此,在实际应用中,通常需要结合大规模数据集和更精细的训练策略来优化模型性能并提升其泛化能力。

针对上述问题,本文提出采用 GCELAN 模块替代 C2f 模块的优化方案。

GCELAN 模块借鉴了 GhostNet 的设计思想，通过 1×1 卷积对输入特征图进行通道压缩，并利用廉价操作生成部分冗余特征图，从而显著降低模型的计算复杂度和参数量。摒弃了传统的残差瓶颈结构，并引入缩放因子（这里设置为 0.5）以进一步优化计算效率。在特征处理过程中，模块将输入特征图分为两部分：一部分经过 RepConv 卷积操作后，依次通过 $n-1$ 个 3×3 卷积和 1×1 卷积；另一部分则直接与处理后的特征图进行通道拼接（Concat），最后通过 1×1 卷积输出。这种设计不仅有效减少了模型的运算量，还增强了特征提取能力和梯度流通效率，其详细结构如图 3-9 所示。




图 3-9 GCELAN 模块

3.2.2 融合多尺度特征模块改进

在 YOLOv8n 模型中，目标检测通常依赖于 P3、P4 和 P5 特征层，这些层具有较大的感受野（Receptive Field），即卷积神经网络中某一层输出的单个像素点所对应的输入图像区域范围。较大的感受野使其更适合检测大尺寸目标。然而，对于小目标检测而言，这些特征层可能存在局限性：一方面，由于 P3、P4 和 P5 层主要关注高层语义信息，小目标的细节特征可能在特征聚合过程中丢失；另一方面，小目标在低分辨率特征图上对应的特征点较少，导致模型难以充分捕捉其形状、纹理等关键信息，从而影响检测精度。

针对这一问题，本文首先利用 SPDConv 对 P2 特征层进行处理^[67]。SPDConv 是一种针对低分辨率和小目标检测能力的卷积操作，操作的核心是将输入特征图的空间信息重新分配到通道维度。能够在减少特征图分辨率的同时保留更多的细节特征，特别适用于小目标检测任务，在处理低分辨率图像方面，由于低分辨率图像本身存在模糊、像素丢失等问题，SPDConv 从多尺度特征融合出发从不同层面挖掘图像潜在特征，以弥补因分辨率不足导致的信息缺失。具体操作步骤是对于给定了一个特征图 X，随后按照比例因子进行下采样处理，例如当比例因子设置为 2 时，就可以得到 4 个特征子图(S/2,S/2,C1)，将 X 进行下采样 2 倍后沿着通道维度依次连接 4 个特征子图，这样就可以得到中间特征图(S/2,S/2,4C1)。

随后与一个包含 $C2$ 个滤波器的非跨步卷积层($S/2, S/2, C2$)进行卷积操作，具体过程如图 3-10 所示。




图 3-10 SPDConv 结构

随后将 SPDConv 提取到的富含小目标信息的特征与 P3 层进行特征融合；使用 CSP 思想，将融合后特征的 25% ($P=0.25$) 通道输入 Omni-Kernel 模块，其余通道直接通过 Concat 操作进行拼接，最终构建 CSP-Omni 模块以实现高效特征整合。其结构如图 3-11 所示。




图 3-11 CSP-Omni 结构

图 3-11 中 Omni-Kernel 模块由三个分支组成，包括全局分支、大分支和局部分支，具体结构详见本文第 2.3.3 小节。为平衡计算效率与特征学习能力，本文

将大分支中的深度卷积（DConv）核尺寸从 63×1 缩减至 31×1 ，同时保留其它结构不变，从而在降低计算开销的同时，有效学习从全局到局部的多层次特征表征，最终显著提升小目标检测性能。CSP-Omni 模块 SPDConv 两者相互融合共同构成了 COMKER 模块能有效提升模型对于目标尺寸较小或目标与背景对比度较低的检测效果。

3.2.3 损失函数选择

在目标检测任务中，交并比（Intersection over Union, IoU）常常被作为评估预测边界框（Bounding Box）与真实边界框（Ground Truth Box）之间匹配程度的核心指标。能够直观反映检测结果的准确性，并为模型性能优化提供重要依据。IoU 通过计算预测框与真实框的交集面积与并集面积的比值，量化了两者之间的重叠程度。其计算公式如下：

$$IoU = \frac{(A \cap B)}{A \cup B} \quad (3-1)$$

其中， A 是预测框的面积， B 是真实框的面积。从几何意义上讲，IoU 就是指预测框与真实框的交集面积除以两者的并集面积，如图 3-12 所示，IoU 的取值范围为 $[0,1]$ ，当 IoU 值为 0 时，表示预测框与真实框完全无重叠，当 IoU 值为 1 时，表示预测框与真实框完全重合。




图 3-12 IoU 模型

然而，传统的 IoU 仅是通过计算预测框与真实框的重叠区域面积来评估检测精度，而忽略了两者的非重叠区域信息。这种局限性在遇到复杂的检测场景，例如目标遮挡、密集目标分布或目标尺度变化较大中尤为显著，很大程度上会导致评估结果出现偏差，进而影响模型训练的有效性和优化方向的准确性。

因此，针对传统 IoU 的不足，探索一种能够综合考虑重叠区域与非重叠区域的改进方法，对于提升目标检测模型的性能评估精度和优化效果具有重要的理论价值与实践意义。

（1）CIoU 损失函数

CIoU（Complete Intersection over Union）损失函数是在传统 IoU 损失函数基础上的一种改进形式。与 IoU 仅考虑预测框与真实框的重叠区域不同，CIoU 引入了三个关键修正因子：中心点距离、宽高比一致性以及重叠区域面积，从而更好的度量目标框之间的相似性。尽管 CIoU 的计算方法相较于传统 IoU 更为复杂，但是能够更精确地反映预测框与真实框之间的空间关系，在模型训练过程中能更好地指导目标框的位置回归和形状优化。CIoU 的计算公式如下：

$$CIoU = IoU - \frac{d^2}{c^2} - \alpha v \quad (3-2)$$

$$\alpha = \frac{v}{(1 - IoU) + v} \quad (3-3)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^g}{h^g} - \arctan \frac{w}{h} \right) \quad (3-4)$$

其中， d 为预测框和真实框两者中心点的距离， c 为最小外接矩形的对角线距离。 w^g 、 h^g 、 w 、 h 分别代表真实框的宽度、真实框的高度、预测框的宽度、预测框的高度， v 是修正因子，是衡量真实框与预测框宽高比是否一致性的重要参数， α 是长宽比一致的权衡函数，CIoU Loss 最后定位损失公式为：

$$CIoU \text{ Loss} = 1 - IoU + \frac{d^2}{c^2} + \alpha v \quad (3-5)$$

CIoU 损失函数示意图见图 3-13 所示。




图 3-13 CIoU 损失函数示意图

由于综合考虑了中心点距离、宽高比一致性以及重叠区域面积等因素，CIoU 损失函数相较于传统 IoU 损失函数，能够更精确地度量预测框与真实框之间的

差异，尤其是在处理低重叠度或宽高比差异显著的目标时，能够为模型提供更有有效的优化指导，从而显著提升目标检测的准确性。但是，CIoU 的改进也带来了更高的计算量，不仅要计算预测框与真实框的完整交叉面积，还需要引入额外的修正因子参与计算，这就会导致模型需要更多的训练数据和更长的训练周期才能充分学习目标框的精确位置和形状信息。

(2) WIoU 损失函数

YOLOv8n 采用 CIoU 作为边界框回归的损失函数。相比于 YOLOv5n 用优化锚框 (Anchor) 偏移量来逼近标签值的策略不同，YOLOv8n 引入了 Anchor-Free 机制，将模型从输出锚框大小偏移量变为预测目标框左、上、右、下边框距目标中心点的距离。这一改进增强了对样本特征的关注度，但当训练数据中包含较多低质量样本（如模糊目标或部分遮挡目标）时，CIoU 对中心点距离和宽高比等几何因素的敏感性会加剧对低质量样本的惩罚，从而降低算法的泛化能力，导致训练不稳定。

为了解决上述问题，本文提出采用 WIoU (Weighted Intersection over Union) 损失函数替代 CIoU。WIoU 通过动态调整几何因素的权重，能够在目标框与锚框重合较好时减弱几何因素的影响，从而提升模型对低质量样本的鲁棒性，增强算法的泛化能力。根据聚焦机制的不同 WIoU 分为三个版本：WIoU-v1、WIoU-v2 以及 WIoU-v3 版本。其损失函数的示意图如图 3-14 所示。




图 3-14 WIoU 损失函数示意图

1.) WIoU-v1 版本

WIoU-v1 版本的特点是通过距离度量构建了一种双层距离注意力机制。该机制能够在锚框与目标框重合效果较好的情况下,有效降低了对中心点距离的依赖,增加对普通质量锚框的 IoU 值。减少高质量锚框的 $\mathcal{R}_{WIoU}$ 值,为了避免收敛的梯度对检测安生影响,将 W_g 和 H_g 从计算图中分离开来,没有引入诸如长宽比之类的新指标,以较少的训练干扰就可以做到锚框与目标框有较好的重合效果。如式(3-6)、(3-7)所示:

$$\mathcal{L}_{WIoUv1} = \mathcal{R}_{WIoU} \mathcal{L}_{IoU} \quad (3-6)$$

$$\mathcal{R}_{WIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (3-7)$$

其中, $\mathcal{L}_{IoU}$ 表示预测框与真实框的重叠程度,取值范围为[0,1], $\mathcal{R}_{WIoU}$ 为惩罚项,取值范围为[1,e], W_g 、 H_g 是最小的封闭框的大小,上标*表示 W_g 和 H_g 从计算图中分离。

2.) WIoU-v2 版本

WIoU-v2 损失函数借鉴了 Focal Loss 的单调聚焦机制,该机制通过动态调整聚焦系数,能够让模型在减少低质量样本对损失值影响的同时,更能够集中对困难样本的注意,从而提升模型整体的分类性能。但是在模型训练过程中,聚焦系数会逐渐变大,反向传播梯度的动态变化可能导致梯度增益随 IoU 值的减小而减小,模型训练后期收敛速度降低,为此 WIoU-v2 中引入了 $\mathcal{L}_{IoU}$ 均值作为归一化因子,可以随训练变化动态调节有效解决了模型训练后期速度较低的问题。公式如下所示:

$$\mathcal{L}_{WIoUv2} = \left(\frac{\mathcal{L}_{IoU}^*}{\overline{\mathcal{L}_{IoU}}}\right)^\gamma \mathcal{L}_{WIoUv1} \quad (3-8)$$

其中, $\mathcal{L}_{IoU}^*$ 为单调聚焦系数, $\overline{\mathcal{L}_{IoU}}$ 为动量为 m 的滑动平均值, $(\mathcal{L}_{IoU}^* / \overline{\mathcal{L}_{IoU}})^\gamma$ 为梯度增益, $\gamma > 0$ 。

3.) WIoU-v3 版本

WIoU-v3 版本定义了离群度 β 用来量化锚框的质量,如式(3-9)所示。离群度值越小就代表着锚框质量越高,此时分配一个小的梯度增益就可以使模型专注于普通的锚框,而对于离群度较大的锚框就分配较小的梯度增益,通过这样操作可

以防止低质量样本对检测结果的影响。为了更好的分配模型的聚焦重点用 β 构造了非单调聚焦系数 η 跟 $\mathcal{L}_{\text{WIoUv1}}$ 相乘后就得到了 $\mathcal{L}_{\text{WIoUv3}}$ 。公式如下：

$$\beta = \frac{\mathcal{L}_{\text{IoU}}^*}{\mathcal{L}_{\text{IoU}}} \in [0, +\infty) \quad (3-9)$$

$$\mathcal{L}_{\text{WIoUv3}} = \eta \mathcal{L}_{\text{WIoUv1}}, \eta = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (3-10)$$

其中，当 $\beta = \delta$ 时，梯度增益 $\eta = 1$ ， β 、 δ 均为超参数，当 $\beta = C$ (C 为定值) 时，此时锚框会获得最高的梯度增益。

综上所述，WIoU 的三个版本在基本原理上保持一致，都是通过不同的权重系数计算方法和优化策略来改进传统 IoU 在目标检测评估中的局限性，解决评估目标检测结果时可能存在的偏差问题。为此需要根据检测物体的特点选择合适的 WIoU 版本，从而有效提升模型检测精度。

3.3 模型评价指标

在本文实验中，模型性能的评估主要基于精确度(Precision)、召回率(Recall)平均精度(Average Precision, AP)以及全类平均精度(mean Average Precision, mAP)来评估模型性能。精确度表示准确检测目标的个数与总检测目标个数的比例，Recall 表示正确识别目标占整个实际现存目标总数中的比例。计算公式如下所示：

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3-11)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3-12)$$

其中， TP 是正确检测的目标数目， FP 是误检的目标数目， FN 是漏检的目标数目。可以简单理解为 Precision 越高时，模型的误检率越低。Recall 越高时，模型的漏检率越低。

平均精度 (AP) 是通过计算不同召回率下的精确度平均值得到的，其值等于精确度-召回率曲线 (Precision-Recall Curve) 与坐标轴围成的面积。AP 值越大，表明模型在不同召回率下的精确度整体表现越好。全类平均精度 (mAP) 则是对所有类别的 AP 值取平均得到的综合指标，用于评估模型在多类别目标检测任务中的整体性能。mAP 值越大，表明模型的整体检测精度越高，其对应的精确度-

召回率曲线与坐标轴围成的面积也越大。AP 和 mAP 的具体计算公式如下所示：

$$AP(i) = \int_0^1 P(r)dr \quad (3-13)$$

其中， i 表示检测次数， $P(r)$ 表示不同召回率下精确度。

$$mAP = \frac{1}{c} \sum_{i=1}^c AP(i) \quad (3-14)$$

其中， c 为检测类别数， $AP(i)$ 为第 i 类缺陷的平精度。

此外，为了全面评估模型的复杂性和计算效率，本文中还引入了每秒帧数（Frames Per Second, FPS）和参数量（Parameters, Params）作为评估指标。FPS 用于衡量模型在单位时间内能够处理的图像数量，反映了模型的计算速度和实时性；Params 则用于度量模型的大小，反映了模型的复杂度和对计算资源的需求。同时，为了验证模型在实际应用中的性能，本研究还进一步评估了模型对电缆线芯根数的识别效果，包括识别准确率和关注度等方面的表现。

3.4 本章小结

本章主要介绍了电缆截面数据集的制作和 SRW-YOLO 模型的构建以及本文的模型评价指标。通过联合芜湖下辖无为市尚纬电缆厂进行合作取得电缆样品，接着采用 Labellmg 软件对电缆线芯进行标注，随后对标注后的图像进行数据增强，以增加电缆截面数据集的泛化性，然后针对电缆截面数据集在 YOLOv8n 模型基础上分别在 Backbone、Neck 进行网络结构改进以及选用 WIoU-v2 损失函数提出了新的检测模型 SRW-YOLO，可以在降低模型参数量的同时增加梯度流通能力加快模型识别速度，最后介绍了本文中评价模型性能的一些指标参数。

第 4 章 基于 SRW-YOLO 的电缆线芯数量检测模型性能分析

本章内容主要是针对于第三章中提出的 SRW-YOLO 模型在电缆截面数据集上的检测效果如何展开了实验。首先,对实验软硬件环境和训练中的超参数进行介绍。接着通过消融实验对几种改进模型方法进行分析,最后与几种经典的 YOLO 检测算法进行对比实验并将检测结果以可视化的形式显示出来,验证了本文所提出的 SRW-YOLO 模型在电缆截面数据集上具有不错的检测性能。

4.1 实验环境设置

该实验在 Ubuntu 22.04 操作系统环境下进行,硬件平台采用 NVIDIA RTX 3090 GPU 对模型进行训练与测试。使用的主要软件包括 Python 3.10、Pytorch 2.4, CUDA11.8, 以及 OpenCV 4.1 和 PyQt5。最后为了确保实验环境的一致性,在整个实验环境中都保持了相同的超参数^[68],具体的超参数配置如表 4-1 所示。

表 4-1 主要训练超参数设置

参数名称	参数规格
训练轮数	300
图像尺寸	640×640
学习率动量	0.937
批量大小	16
优化器	SGD
学习率	0.001
权重衰减系数	0.0005

4.2 模型改进后的测试与分析

4.2.1 SRW-YOLO 模型训练结果

在保持实验环境相同的情况下,利用 YOLOv8(选用 n 版本,下面同理)和 SRW-YOLO 模型分别对电缆数据集进行训练 300 轮后结果如图 4-1 所示。从模型的精确度变化曲线来看 SRW-YOLO 模型在 0-50 轮之间上升的速度明显高于

YOLOv8 模型,且上升到最高点时稳定收敛下来。召回率和 mAP50 两者的数值基本一致,对于 mAP50-95 来看 SRW-YOLO 模型明显要高于 YOLOv8 模型,说明改进后的模型提高了原模型的表达能力和感知力,更有助于提高模型在测试集上的表现,从而实现更好的检测性能。




图 4-1 YOLOv8 与 SRW-YOLO 训练对比图

4.2.2 不同损失函数对比结果

YOLOv8 中采用的是 CIoU 损失函数。需要计算预测框和目标框的重叠面积、中心点距离以及宽高比等多个参数,这会导致模型在训练过程的计算开销较大,此外对于小目标或者低质量样本时,尤其是当预测框与目标框宽高比差异大或中心点距离远的情况时,模型的检测精度会有所下降。因此为了确定最适合的损失函数,本研究在相同的实验条件下,对 WIoU 损失函数的三个版本(v1、v2、v3)进行了对比实验^[69],实验结果如图 4-2 所示,具体实验数据结果如表 4-2 所示(表中数据加粗的为最优参数)。




图 4-2 不同损失函数实验曲线

表 4-2 损失函数对比试验

Model	Precision(%)	Recall(%)	mAP50(%)	mAP50-95(%)
CIoU	99.5	99.5	99.4	79.1
WIoU-v1	99.4	99.4	99.4	79.8
WIoU-v2	99.6	99.6	99.6	81.2
WIoU-v3	99.5	99.6	99.6	80.0

从图 4-2 和表 4-2 可以看出, 对于 Precision 来说, WIoU-v2 相较于其它损失函数能够较快的达到收敛值且准确率也是最高的, 在 Recall 和的 mAP50 中四种损失函数的效果基本一致, 但在 mAP50-95 比较中 WIoU-v2 的平均精度值达到了 81.2%, 明显高于其它三种损失函数结果, 因此在 SRW-YOLO 模型中选用 WIoU-v2 作为损失函数来增加检测精度。

4.2.3 消融实验对比结果

为了验证 SRW-YOLO 模型中每个模块对检测性能的影响, 采用相同的实验

环境和参数，基于 YOLOv8 网络进行了系统的消融实验，实验结果如图 4-3 所示，实验参数配置如表 4-3 所示，在表 4-3 中“√”表示在 YOLOv8 算法基础上添加了相应模块进行实验。




图 4-3 不同改进策略实验结果曲线

表 4-3 消融实验结果参数

COMKER	GCELAN	WIoU-v2	mAP50 (%)	mAP50-95 (%)	Param(M)	FPS
			99.4	79.1	6.1	205.9
√			99.4	80.7	6.6	162.7
	√		99.2	78.6	4.5	235.2
		√	99.4	79.5	6.1	205.9
√	√		99.5	80.5	5.0	191.5
√		√	99.5	80.4	6.6	162.5
	√	√	99.4	79.4	4.5	235.1
√	√	√	99.6	81.2	5.0	191.5

通过对比第一组和第二组以及第七组和第八组的实验结果可以看出在引入 COMKER 模块后，mAP50-90 分别提升了 1.6 和 0.8 个百分点，但参数量增加了

0.5M，同时发现 FPS 分别下降了 43.2 和 43.8，对比第一组和第三组以及第二组和第五组的实验结果可以看出在模型中引入 GCELAN 模块后，mAP50-90 分别下降了 0.5 和 0.2 个百分点，但参数量减少了 1.6M，同时 FPS 分别提升了 29.3 和 28.8，此外，对比第一组和第四组以及第五组和第八组的实验结果可以看出在模型中引入 WIoU-v2 损失函数后，mAP50-90 分别提升了 0.4 和 0.7 个百分点，而参数量和 FPS 均保持不变。总体来说，SRW-YOLO 模型相较于其它改进模型在 mAP50 和 mAP50-90 都具有优势，模型参数量适中，检测速度也完全满足电缆线芯数量实际检测的需求。

4.2.4 各算法对比结果

为了检验 SRW-YOLO 算法模型的检测精度，在实验环境相同的条件下选用了多个经典目标检测算法，包括有 YOLOv5、YOLOv6、YOLOv8 以及 YOLOv10 作为对比算法，模型检测曲线如图 4-4 所示，实验结果参数如表 4-4 所示。




图 4-4 不同模型精度指标对比

表 4-4 不同模型对比参数

Model	Precision(%)	Recall(%)	mAP50(%)	mAP50-95(%)	Param(M)	FPS
YOLOv5	99.4	99.3	99.5	79.8	4.2	210.4
YOLOv6	99.4	99.4	99.4	79.1	8.7	154.6
YOLOv8	99.5	99.5	99.4	79.1	6.1	205.9
YOLOv10	98.9	99.1	99.4	79.2	5.8	154.6
SRW-YOLO	99.6	99.6	99.6	81.2	5.0	191.5

从图 4-4 和表 4-4 可以看出,在自建的电缆截面数据集上,SRW-YOLO 模型相较于其它模型来说检测性能有着明显提升,从检测精度来看,准确率、召回率以及 mAP50 都达到了 99.6%的检测精度,特别是对 mAP50-95 的提升更为明显,表明该模型度高的小目标检测效果更好。从参数量上看,YOLOv5 的参数量更少,但是精度却有所下降,而 SRW-YOLO 模型能够兼顾检测精度提升的情况下减少了参数量,从 FPS 来看,SRW-YOLO 模型排名第三,相较于 YOLOv8 来说有所下降,但是下降的少许检测速度对模型整体性能来说影响不大,检测精度却得到显著的提升,这是具有极高的性价比的,综上各算法对比结果,SRW-YOLO 平均精度均值上具有明显的优势,另外在检测速度上也达到了实际电缆生产中需要实时监测的需求。

4.3 电缆线芯检测可视化结果分析

4.3.1 热力图分析

为了验证 SRW-YOLO 模型与 YOLOv8 模型对于电缆截面数据集的注意力聚焦情况,对两种模型进行了热力图可视化对比,结果如图 4-5 所示。热力图通过亮度分布直观地反映了模型对图像不同区域的关注程度,高亮度的区域表示模型在该图像中重点关注的特征区域。低亮度的区域则表示模型在图像中容易忽略的特征区域。通过对比分析可以发现,SRW-YOLO 模型对图像关键特征的注意力分布更加全面且均匀,尤其在全局注意力方面表现出显著优势。此外,SRW-YOLO 模型对线芯区域的关注度显著提升,能够生成更高置信度的检测结果,有效降低了线芯检测框重叠而造成误检的概率。




图 4-5 热力图可视化对比图

4.3.2 设置合适 IoU 值滤除

在使用 SRW-YOLO 模型对测试图片和视频进行检测时，发现在错检的图片中经常出现检测框重叠的情况，这就会导致检测结果比真实根数要多，而在实际中通常不会出现电缆线芯根数重叠在一起的情况。

基于电缆截面数据集的这种特点，进行了设置不同 IoU 值对 100 张测试图片进行推理，在实验过程中发现随着 IoU 的降低（原始版本的 IoU=0.7），检测框会减少，检测结果更接近真实值，这是由于置信度与 IoU 的相互作用，当 IoU 阈值较低时，这些低置信度的检测框可能会因为与高置信度检测框的重叠而被抑制；但当 IoU 阈值提高后，它们与其他检测框的重叠关系发生变化，由于没有足够的机制来正确评估其有效性，从而被保留下来，导致检测框增多，最终检验结果见表 4-5 所示。

表 4-5 不同 IoU 的 SRW-YOLO 模型检测情况

模型类型	样本总数量	单芯错误数量	三芯错误数量	正确率（%）
IoU=0.8	100	7	18	75
IoU=0.7	100	5	15	80
IoU=0.6	100	4	7	89
IoU=0.5	100	2	3	95
IoU=0.4	100	2	5	93
IoU=0.3	100	2	5	93

从表 4-5 中可以看出，相较于三芯电缆线芯检测来说单芯电缆的检测率要明显更高一点，这跟线芯的聚集程度有关，此外可以看出在检测测试图片时 IoU 值

设置为 0.5 时能够有效地滤除重叠的线芯根数，使得检测结果更接近真实值，更适用于电缆数字化工业检测上。

4.3.3 检测结果分析

为了进一步验证 SRW-YOLO 模型在电缆线芯检测的效果如何。本实验中分别选取了 YOLOv5、YOLOv6、YOLOv8、和 YOLOv10 四种经典目标检测算法对电缆测试图片进行对比实验，各模型对测试图像的检测结果如图 4-6 所示，具体的检测性能数据如表 4-6 所示。




图 4-6 SRW-YOLO 与其它 YOLO 系列模型检测结果图

表 4-6 不同模型检测参数结果

Image Type Model Type	(a)	(b)	(c)	(d)
YOLOv5	60	61	145	146
YOLOv6	60	60	144	146
YOLOv8	60	61	144	146
YOLOv10	60	62	144	147
SRW-YOLO	60	60	144	144

从上述图 4-6 和表 4-6 可以看出对于单芯电缆线芯检测来说，除了 SRW-YOLO 和 YOLOV6 没有出现误检情况，其它模型均出现了误检情况，对于三芯电缆线芯来说，只有 SRW-YOLO 模型可以准确无误的识别出正确的线芯根数，显示了该模型对电缆线芯根数检测相较于其它 YOLO 模型检测的优越性。更适合于电缆线芯根数的检测和计数工作。

4.4 本章小结

本章先是详细介绍了实验环境配置以及模型的关键参数配置，接着通过对比不同损失函数对检测结果的影响确定使用 WIoU-v2 作为模型损失函数。然后为了验证每个改进模块对模型检测性能的影响进行了消融实验，最后将 SRW-YOLO 模型与几种经典的 YOLO 检测模型进行对比实验，通过可视化分析表明改进模型对线芯的整体关注度更高，值得一提的是在实验过程中发现可以通过设置合适的 IoU 值来滤除多余检测框，进一步提高了模型对电缆芯数检测的准确率。

第 5 章 基于 SRW-YOLO 的电缆线芯数量检测系统

在当今数字化时代，桌面应用程序的开发需求持续增长。无论是企业级的管理软件，还是个人使用的小型工具，一个友好、高效且功能强大的图形用户界面（GUI）都是至关重要的。而在实际电缆生产过程中会存在生产缺陷从而影响到电缆的质量，其中电缆线芯缺陷是影响电缆质量的重要因素之一，传统的检测主要靠人工进行、效率低、劳动强度大、还容易产生漏检。为此本章设计了基于深度学习的 PyQt5 电缆线芯缺陷检测系统，采用所开发的 SRW-YOLO 检测模型对电缆线芯的数量进行实时检测，大大提高了检测工作效率和用户体验。

5.1 PyQt5 介绍

PyQt5 是利用 Qt 框架的 Python 语言进行实现的软件，可支持用户根据自己的需求进行界面设计。现由 The Qt Company 维护的跨平台 C++ 应用程序开发框架，里面提供了丰富的类库和工具，支持开发桌面应用、移动应用及嵌入式应用以及嵌入式系统等多种类型的应用程序。PyQt5 将 Qt 的功能开发与 Python 语言进行联系，使开发人员可以通过 Python 语言调用 Qt 的功能，同样也可以利用 Qt 模块的使用生成 Python 语言的代码，从而可以直观地开发 GUI 应用程序，增加开发效率。此外 PyQt5 还具有跨平台特性，可以支持 Windows、Linux 和 macOS 等多种操作系统，具备高度的可移植性。强大的功能和跨平台特性使 PyQt5 成为 Python 语言开发 GUI 的首选工具之一。可以广泛应用于物联网特别是智能汽车、智能制造等等的研发。

基于以上特性，PyQt5 常被用于开发实验数据可视化工具、算法演示系统以及交互式应用程序。其开源特性和丰富的文档资源为开发者提供了强大的支持，同时也为学术研究中的软件实现提供了可靠的技术基础。PyQt5 在 PyCharm 配置好后主要有两种调用方式，一种是作为外部部件直接调用，另一种就是在终端中输入唤醒代码进行使用，本文中采用的是第一种调用方法，在外部部件中添加 Qt_Designer、PyUIC、RyRcc 后进行设计，如图 5-1 所示。



图 5-1 PyCharm 中 PyQt5 调用位置

Qt_Designer 是 Qt 框架中的核心可视化界面设计工具。其具体功能是允许开发者通过拖放组件和设置属性的方式快速创建图形用户界面（GUI），大大减少了编写代码的工作量。除此之外使用 Qt_Designer，可以直观地对交互界面进行设计窗口、对话框、菜单、工具栏等各种界面元素，并可以根据设置的功能灵活的调整其布局、样式和属性，显著提升了界面设计的效率与质量。在降低 GUI 开发门槛的同时还为复杂界面的设计与调试提供了便利。如图 5-2 所示为 Qt Designer 的开发界面及其主要功能模块。




图 5-2 Qt_Designer 的开发界面

Qt_Designer 的使用步骤一般为：

- 1.) 按照图 5-1 所示选择 Qt_Designer 进行启动后选择“文件”->“新建”，可以创建一个新的界面文件；
- 2.) 在左侧的“控件箱”中选择需要的界面元素，如按钮、标签等，然后将

其拖放到工作区中；

- 3.) 选中一个界面元素后，在属性编辑器中可以设置其各种属性；
- 4.) 使用布局管理器可以快速调整界面元素的布局；
- 5.) 在信号/槽编辑器中，可以设置对象之间的信号与槽连接；
- 6.) 设计完成后，选择“文件”->“保存”，将界面文件保存为.ui 格式；

PyUIC 是 PyQt5 提供的另一个命令行工具。其主要功能是将 Qt_Designer 生成的.ui 文件转换为 Python 代码。来方便开发者后期可通过修改 Python 代码的方式对交互界面进行修改，.ui 文件是一种基于 XML 格式的文件，用于存储图形用户界面的设计信息，但由于 Python 程序与 XML 文件不互通，因此需要通过 PyUIC 将其转换为 Python 类。转换后的 Python 类可以直接导入到项目中，使开发者能够将界面设计与业务逻辑无缝结合，从而实现高效的 GUI 开发。

此外，PyQt5 还提供了另一个命令行工具 **RyRcc**。其主要功能是用于处理图形用户界面开发中的资源文件。在 GUI 设计过程中，通常需要加载外部资源，如图标、图片、样式表等。为了确保这些资源文件能够在不同的操作系统和环境中正确加载，RyRcc 将这些资源文件打包为 Python 模块，从而方便开发者在 Python 代码中直接调用。通过 PyUIC 和 RyRcc 的协同使用，开发者能够显著提升 GUI 应用程序的开发效率和可移植性。

5.2 系统设计及测试

5.2.1 系统设计

考虑到电缆线芯根数实时性检测系统主要用于在电缆生产、安装及维护过程中，需要快速、准确地确定电缆的线芯数量。为确保系统实际应用场景中能够高效、稳定地运行，检测系统设计需满足以下几方面的核心需求：（1）快速响应。系统需具备高效的检测速度，能够在短时间内完成线芯根数的检测，以此满足实时性检测的要求。（2）高精度检测。要能够精确识别不同规格电缆线芯根数。包括常见的圆形单芯及三芯，都能够准确的识别出电缆线芯数量。（3）数据展示与存储。检测系统应实时将检测出来的相关数据展示出来，比如检测时间、线芯位置、线芯根数等信息，方便操作人员随时监测。此外还应将这些记录储存下来，方便后续的质量追溯和生产数据分析。

基于以上设计要求，本文开发出了基于 SRW-YOLO 的电缆线芯数量检测系统。该系统所使用的设计软件是 PyCharm2023.2.1 版本，操作系统为 Windows11，处理器为 AMD 7 6800H，3.20 GHz 的 ThinkBook 16p NX 笔记本电脑。开发环境为 python3.9，界面开发通过 PyQt5 进行设计，检测系统使用流程如图 5-3 所示。




图 5-3 检测系统使用流程

检测系统主界面如 5-4 所示。可支持图片、视频以及开启摄像头进行实时检测，界面可实时显示检测类别、目标位置、目标总数、置信度、用时等信息并且支持图片或者视频的检测结果保存。




图 5-4 检测系统主界面

5.2.2 系统测试

该检测系统操作步骤较为简单，在进行图片检测或者视频检测时，点击相对应的图片图标（或者点击文件夹图标，选择需要批量检测图片所在的文件夹）和视频图标，选择好需要检测的图片或者视频，就会自动显示检测结果。点击保存按钮，会对视频检测结果进行保存，图 5-5 为结果保存界面。



图 5-5 结果保存界面

实时检测则是点击摄像头图标后进行实时检测，再次点击可关闭摄像头。如图 5-6 所示为摄像头实时检测画面。



图 5-6 实时检测画面

通过对比第 4 章中的检测模型的检测结果，发现检测系统的速度和精度都要

略低于检测模型。这是因为二者的硬件平台不同，CPU 相较于 GPU 对于模型的计算能力较弱，此外由于检测系统在检测完后还要对处理结果进行显示，这也增加了整体的耗时。另外检测系统在实际环境运行时，面临着光照变化、遮挡、复杂背景等干扰因素，进而影响精准度。但总体而言，该检测系统无论是从检测时间还是检测精度上来看基本满足了实际电缆线芯检测的需求，解放了人工操作，可有效提高电缆线芯根数检测的效率。

5.3 本章小结

本章首先对 PyQt5 中常用的 Qt_Designer、PyUIC 以及 RyRcc 三种设计工具进行了简单介绍，随后根据电缆线芯实际检测需求设计出基于 SRW-YOLO 的电缆线芯数量检测系统并进行功能测试，实验结果表明，该系统能够满足智能制造场景中对检测精度与实时性的检测要求，为电缆生产缺陷检测提供了高效、准确的自动化解决方案。

第 6 章 总结与展望

6.1 总结

本文通过分析电缆生产及使用过程中对线芯数量准确检测的需求,对目前电缆缺陷检测研究现状以及深度学习的相关理论进行研究,提出了一种新的检测模型 SRW-YOLO,并通过 PyQt5 搭建了电缆线芯检测系统,实现对线芯进行精确检测和计数,为工业电缆线芯的质量检测提供了新的技术方向。主要研究内容如下:

(1) 本文首先对国内外近些年对电缆产业的需求和发展进行了分析,接着介绍了基于深度学习的目标检测算法,主要包括以 R-CNN 为代表的双阶段检测算法和以 YOLO 为代表的单阶段检测算法两种。最后介绍了常见的电缆缺陷检测方法以及基于深度学习的电缆缺陷检测的研究现状。

(2) 结合目前关于电缆线芯缺陷检测的公开数据集稀少的现状联合无为市尚纬电缆厂合作制作电缆截面数据集。接着为提升 YOLOv8n 检测模型在电缆截面数据集上的检测性能,提出了 SRW - YOLO 模型。其改进思想是针对电缆线芯在不同种电缆中的排列比较密集以及单个线芯较小的特点。将改进的特征提取 GCELAN 模块替换 Backbone 中的原有的 C2f 模块,以降低模型参数量;通过添加融合多尺度特征的 COMKER 模块提升模型检测性能,最后通过比较 WIoU - v1, v2, v3,三个版本的损失函数的检测效果后选择 v2 版本损失函数进一步提高对每个线芯的准确识别和定位。

(4) 对本文提出的 SRW-YOLO 模型进行消融实验以及与其它 YOLO 系列算法进行对比测试。结果表明,本文算法比原 YOLOv8n 模型的 mAP50-95 提升了 2.1 个百分点,其可视化结果显示可以通过应用 IoU 值的方式有效避免了因预测框过多产生重叠而导致错检的情况发生,有效提高了模型整体检测精度。

(5) 为了将检测模型应用到实际检测场景中,本文基于 PyQt5 搭建了电缆线芯数量检测系统,该系统支持图片、视频以及开启摄像头实时性检测。具有实时检测结果展示功能以及保存功能,检测速度上也能满足实际电缆工厂生产场景的需求,为电缆生产线上的线芯缺陷实时检测提供了新的解决方案。

6.2 展望

本文主要利用基于深度学习的检测方法对电缆线芯数量进行研究,提出了基于 SRW-YOLO 的检测模型,随后搭建了基于 SRW-YOLO 的电缆线芯数量检测系统,在电缆线芯数量检测领域取得了初步进展。但是在数据集的获取、SRW-YOLO 模型检测的泛化性以及运用到实际生产应用等方面还存在诸多不足,需要进一步改善:

(1)数据集在很大程度上会影响到检测模型的训练结果,数据集样本不足、样本质量较低以及样本的特征多样性较少等问题都会对训练结果产生影响。本文采用的数据集是联合工厂实际生产电缆所制成,具有很高的使用价值,但是也存在着样本数量较少的问题,后期考虑去电缆生产工厂获取较多的实际电缆线芯数据,然后重新对文中提出模型进行训练,从而提高模型的识别精度。

(2)虽然 SRW-YOLO 模型针对电缆数据集显示很好的检测效果,但是运用对象比较单一,后面为了迁移学习考虑将其应用到其它目标检测中,比如对工地上成堆的钢筋进行计数,可以很大程度上减少人工操作,提高工作效率。

(3)未来的工作重点是将 SRW-YOLO 模型部署到嵌入式系统中。可以进一步优化模型的计算效率和参数量,使其适应嵌入式设备的资源限制,实现电缆生产线的全流程自动化检测与监控。以实现电缆线芯根数的实时检测,从而推动电缆制造质量检测向数字化、智能化方向转型。

参考文献

- [1] 中商产业研究院. 2024 年中国电线电缆行业市场前景预测研究报告 [EB/OL].<https://www.seccw.com/Document/detail/id/29892.html>.2023-03-31
- [2] 界面快报. 市场监管总局. 2022 年电线电缆产品质量国家监督抽查不合格率为 2.8% [EB/OL]. <https://finance.sina.com.cn/jjxw>.2023-03-31
- [3] 陈科圻, 朱志亮, 邓小明, 等. 多尺度目标检测的深度学习研究综述[J]. 软件学报, 2021, 32(04): 1201-1227.
- [4] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2014: 580-587.
- [5] He K, Zhang X, Ren S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(9): 1904-1916.
- [6] Girshick R. Fast r-cnn[C]. Proceedings of the IEEE international conference on computer vision. 2015: 1440-1448.
- [7] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2016, 39(6): 1137-1149.
- [8] K. He, G. Gkioxari, P. Dollár, et al."Mask R-CNN," 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017, pp. 2980-2988.
- [9] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 779-788.
- [10] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 7263-7271.
- [11] Redmon J, Farhadi A. Yolov3: An incremental improvement[J]. arXiv preprint arXiv:1804.02767, 2018.
- [12] ZHANG L, LI J, ZHANG F. An Efficient Forest Fire Target Detection Model

- Based on Improved YOLOv5 [J]. Fire, 2023, 6(8): 291.
- [13]汪燕超,胡旭晓.基于改进 YOLOv6 电动单车违法停放的检测方法研究[J].智能计算机与应用,2023,13(09):172-175.
- [14]周宏威,纪皓文,吴羿轩,等.基于 YOLOv8 算法改进模型检测梢斑螟虫蛀树木[J].森林工程,2025,41(01):126-137.
- [15]Wang A, Chen H, Liu L, et al. Yolov10: Real-time end-to-end object detection[J]. Advances in Neural Information Processing Systems, 2024, 37: 107984-108011.
- [16]何维晟,吴照国,邓帮飞,等.高压电缆缓冲层烧蚀缺陷超声检测技术仿真研究[J].高压电器,2022,58(11):230-237+260.
- [17]王韵.基于超声检测的电缆局部放电信号特征分析与模式识别[D].重庆大学,2022.
- [18]方春华,孙奥琪,游海鑫,等.基于非线性超声的电缆硅橡胶界面压力检测方法[J].高电压技术,2024,50(01):313-321.
- [19]朱家豪,袁玲,吴川彬,等.激光超声在高压电缆检测中的应用研究[J/OL].激光技术,1-12[2025-03-17].
- [20]Yücel M K, Legg M, Kappatos V, et al. An ultrasonic guided wave approach for the inspection of overhead transmission line cables[J]. Applied Acoustics, 2017, 122: 23-34.
- [21]Wu Y, Lu P, Zhou W, et al. Ice monitoring of aluminum conductor steel-reinforced cables using guided waves[J]. Cold Regions Science and Technology, 2023, 210: 103835.
- [22]沈尹扩. 基于机器视觉检测技术的电缆导体截面积测量方法[D]. 华中科技大学, 2020.
- [23]刘硕. 基于机器视觉的电缆表面缺陷检测方法研究[D]. 哈尔滨理工大学, 2021.
- [24]王峰,程自豪,邹俊逸,等.基于机器视觉的电缆接头缺陷检测系统设计[J].电子设计工程,2024,32(24).
- [25]吴伟,查姿伊,刘晔,等.基于机器视觉的电缆局部绝缘材料老化缺陷检测研

- 究[J].自动化技术与应用,2024,43(06):156-160.
- [26]Li B, Thomas G, Williams D. Detection of ice on power cables based on image texture features[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 67(3): 497-504.
- [27]Gou S, Huang D, Liao S, et al. Online defect detection method of optical cable pitch based on machine vision technology and deep learning algorithms[J]. Optics & Laser Technology, 2024, 171: 110344.
- [28]Xie Y ,Zhang J ,Zhang L , et al. Deep Learning Method for Buffer Layer Defect Detection in High Voltage Cable[J].Journal of Physics: Conference Series,2021,1792(1):012010-.
- [29]Zhou Z, Luo Y, Zhang X, et al. Surface Damage Detection for Bridge Cables Based on YOLOv7[C]//2022 International Conference on Service Robotics (ICoSR). IEEE, 2022: 126-132.
- [30]Zhang B, Luo Z, Hong X, et al. Deep learning-based corrosion-like defect localization technique for high-voltage cable aluminum sheaths using guided waves[J]. Measurement Science and Technology, 2023, 34(8): 084006.
- [31]Min S, Lee Y, Byun Y H, et al. Merged LSTM-based pattern recognition of structural behavior of cable-supported bridges[J]. Engineering Applications of Artificial Intelligence, 2023, 125: 106774.
- [32]Wang W, Cui D, Ai C, et al. Target-free recognition of cable vibration in complex backgrounds based on computer vision[J]. Mechanical Systems and Signal Processing, 2023, 197: 110392.
- [33]Maeng J, Heo Y, Lee K. Automatic Corona Discharge Detection for Cable Safety Inspection[C]//International Conference on Intelligent Autonomous Systems. Cham: Springer Nature Switzerland, 2023: 117-126.
- [34]Chen W, Dong L, Chen Z, et al. Application of YOLO Algorithm in Monocular Visual Positioning of Cable Trench Inspection Robot[C]//2024 30th International Conference on Mechatronics and Machine Vision in Practice (M2VIP). IEEE, 2024: 1-5.
- [35]Liu Q, He D, Z, et al. ViTR-Net: An unsupervised lightweight transformer

- network for cable surface defect detection and adaptive classification[J]. Engineering Structures, 2024, 313: 118240.
- [36] Jiang T, Hu C, Li L. Complex background segmentation for noncontact cable vibration frequency estimation using semantic segmentation and complexity pursuit algorithm[J]. Journal of Civil Structural Health Monitoring, 2024, 14(6): 1533-1554.
- [37] Yang W ,Pinjia Z ,Guanghui L .Detection and Location of Aged Cable Segment in Underground Power Distribution System Using Deep Learning Approach[J].IEEE TRANSACTIONS ON INDUSTRIAL INFORMATICS,2021,17(11):7379-7389.
- [38] Huang Z, Guo B, Deng X, et al. Trans-DCN: A high-efficiency and adaptive deep network for bridge cable surface defect segmentation[J]. Remote Sensing, 2024, 16(15): 2711.
- [39] Qu X, Long Y, Wang X, et al. Research on the Cable-to-Terminal Connection Recognition Based on the YOLOv8-Pose Estimation Model[J]. Applied Sciences, 2024, 14(19): 8595.
- [40] Chen D, Y. AWUCD-Net: The armored wire umbilical cable surface defect detection algorithm based on improved YOLOv7[J]. IEEE Access, 2024.
- [41] Xu X, Ding J, Ding Q, et al. A study on the detection of conductor quantity in cable cores based on YOLO-cable[J]. Scientific Reports, 2024, 14(1): 31107.
- [42] 马永杰, 程时升, 马芸婷, 等. 卷积神经网络及其在智能交通系统中的应用综述[J]. 交通运输工程学报, 2021, 21(4): 48-71.
- [43] 章咸斌. 基于深度学习的目标检测系统设计与实现[D]. 安徽工程大学, 2024.
- [44] Szandała T. Review and comparison of commonly used activation functions for deep neural networks[J]. Bio-inspired neurocomputing, 2021: 203-224.
- [45] Scabini L F S, Bruno O M. Structure and performance of fully connected neural networks: Emerging complex network properties[J]. Physica A: Statistical Mechanics and its Applications, 2023, 615: 128585.
- [46] Zhang L, Li J, Zhang F. An efficient forest fire target detection model based

- on improved YOLOv5[J]. Fire, 2023, 6(8): 291.
- [47]Cheng Z, Gao L, Wang Y, et al. Ec-yolo: Effectual detection model for steel strip surface defects based on yolo-v5[J]. IEEE Access, 2024.
- [48]Khanam R, Hussain M. What is YOLOv5: A deep look into the internal features of the popular object detector[J]. arxiv preprint arxiv:2407.20892, 2024.
- [49]Chitraningrum N, Banowati L, Herdiana D, et al. Comparison study of corn leaf disease detection based on deep learning YOLO-v5 and YOLO-v8[J]. Journal of Engineering and Technological Sciences, 2024, 56(1): 61-70.
- [50]Geetha A S. What is yolov6? a deep insight into the object detection model[J]. arxiv preprint arxiv:2412.13006, 2024.
- [51]Li N, Wang M, Yang G, et al. DENS-YOLOv6: A small object detection model for garbage detection on water surface[J]. Multimedia Tools and Applications, 2024, 83(18): 55751-55771.
- [52]Wei J, Qu Y, Gong M, et al. Ve-yolov6: A lightweight small target detection algorithm[C]//2024 4th International Conference on Neural Networks, Information and Communication (NNICE). IEEE, 2024: 873-876.
- [53]Wang H, Luo S, Wang Q. Improved YOLOv8n for foreign-object detection in power transmission lines[J]. IEEE Access, 2024.
- [54]Li G, Chen J, Li H, et al. A Novel Model of Partial Discharge Initiation in Cable Insulation[J]. IEEE Access, 2022, 10: 47837-47845.
- [55]Li J, Wu J, Shao Y. FSNB-YOLOV8: Improvement of Object Detection Model for Surface Defects Inspection in Online Industrial Systems[J]. Applied Sciences, 2024, 14(17): 7913.
- [56]Wang A, Chen H, Liu L, et al. Yolov10: Real-time end-to-end object detection[J]. Advances in Neural Information Processing Systems, 2024, 37: 107984-108011.
- [57]Guan S, Lin Y, Lin G, et al. Real-time detection and counting of wheat spikes based on improved YOLOv10[J]. Agronomy, 2024, 14(9): 1936.
- [58]Mao M, Lee A, Hong M. Efficient Fabric Classification and Object Detection

- Using YOLOv10[J]. Electronics (2079-9292), 2024, 13(19).
- [59]Chi J, Guo S, Zhang H, et al. L-GhostNet: Extract better quality features[J]. IEEE Access, 2023, 11: 2361-2374.
- [60]Alaftekin M, Pacal I, Cicek K. Real-time sign language recognition based on YOLO algorithm[J]. Neural Computing and Applications, 2024, 36(14): 7609-7624.
- [61]Cui Y, Ren W, Knoll A. Omni-kernel modulation for universal image restoration[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024.
- [62]Kong F, Zhang Y, Zhan L, et al. Cable Conduit Defect Recognition Algorithm Based on Improved YOLOv8[J]. Electronics, 2024, 13(13): 2427.
- [63]Li J, Wu J, Shao Y. FSNB-YOLOV8: Improvement of Object Detection Model for Surface Defects Inspection in Online Industrial Systems[J]. Applied Sciences, 2024, 14(17): 7913.
- [64]Lv Z, Dong S, He J, et al. Lightweight Sewer Pipe Crack Detection Method Based on Amphibious Robot and Improved YOLOv8n[J]. Sensors, 2024, 24(18): 6112.
- [65]Yu C, Lu Z. YOLO-VSI: An Improved YOLOv8 Model for Detecting Railway Turnouts Defects in Complex Environments[J]. Computers, Materials & Continua, 2024, 81(2).
- [66]Liu L, Chu C, Chen C, et al. MarineYOLO: Innovative deep learning method for small target detection in underwater environments[J]. Alexandria Engineering Journal, 2024, 104: 423-433.
- [67]Zhang C, Zhang Y, Chang Z, et al. Sperm YOLOv8E-TrackEVD: A Novel Approach for Sperm Detection and Tracking[J]. Sensors, 2024, 24(11): 3493.
- [68]Zhang T, Zhang J, Pan P, et al. YOLO-RRL: A Lightweight Algorithm for PCB Surface Defect Detection[J]. Applied Sciences, 2024, 14(17): 7460.
- [69]Yu X, Yin D, Xu H, et al. Maize tassel number and tasseling stage monitoring based on near-ground and UAV RGB images by improved YoloV8[J]. Precision Agriculture, 2024, 25(4): 1800-1838.

攻读学位期间发表的学术论文和科研成果

一、发表学术论文

- 【1】 XU X, DING J, XIAO P, et al. ALSSA-PID control-based wheel-side motor control system for four-wheel-drive electric vehicles [J]. Electrical Engineering, 2024.
- 【2】 XU X, DING J, DING Q A, et al. A study on the detection of conduct or quantity in cable cores based on YOLO-cable [J]. Scientific Reports, 2024, 14(1).

二、参与的科技项目

- 【1】 安徽未来技术研究院企业合作项目（参与）
- 【2】 安徽省重点研究与开发计划项目（参与）
- 【3】 安徽工程大学-鸠江区产业协同创新专项基金项目（参与）

致谢

时光荏苒，我的硕士生涯已接近尾声。在完成这篇硕士论文之际，心中五味杂陈。这段学术探索之旅，充满挑战与突破，而我能走到终点，离不开众多师长、亲人和朋友的支持与帮助。

我要诚挚地感谢我的导师徐晓光教授。在整个研究过程中，导师如启明星般照亮我前行的道路。从最初确定以电缆线芯数量检测为研究方向，到对国内外电缆产业需求与发展进行深入分析，导师都给予了我高屋建瓴的指导。尤其是当我构建电缆数据集时，导师积极帮我联系到电缆厂，使我能够顺利采集到样品制作数据集。在论文撰写过程中，从结构布局到语句措辞，导师都一丝不苟地审阅，提出诸多宝贵意见，使论文质量得以提升。导师严谨的治学态度、渊博的学术知识和无私的奉献精神，将永远激励着我在学术道路上不断奋进。

我要感谢我的同门师兄弟们。特别是已经毕业的丁奇安师哥，是他给我梳理了论文的整体脉络和研究顺序。此外还要感谢我同门王淼、王奇恺，我们常常会针对遇到的困难问题展开热烈讨论。给我提供了许多宝贵的建议，帮助我少走了许多弯路。师弟们以活力和新思路为我的研究注入了新的灵感。在这里还要感谢我的室友李鸿飞、李鹏飞以及我的朋友孔德辉和卓鹏，在我长时间埋头于实验室和文献资料中时，是你们的陪伴与鼓励，让我在疲惫时能放松身心。当我因实验结果不理想而沮丧时，是你们耐心倾听我的烦恼，给予我精神上的支持，让我重新振作，鼓起勇气继续攻克难题。你们的存在，让我的研究生生活变得丰富多彩，也成为我坚持下去的动力之一。

我更感恩我的家人。在我多年的求学生涯中，家人始终是最坚强的后盾。他们默默承担起生活中的琐碎事务，让我能够心无旁骛地投入到学习和研究中。在我为了获取更准确的实验数据而日夜忙碌时，家人给予我充分的理解和包容。他们的关爱与牵挂，跨越距离，一直陪伴着我，是我在学术道路上不断前行的情感支柱。

在此，我向所有帮助过我的人表示最衷心的感谢。这份论文不仅是我个人学术成果的体现，更凝聚着大家的智慧与支持。未来，我将带着这份感恩，继续在学术领域深耕，努力为相关领域的发展贡献自己的力量。

尚德敏学 唯实惟新

