♥圆縺ਫ਼ぉぉぇ 工程硕士学位论文



基于分布式光纤传感的风电地埋电缆安

全监测技术研究与应用

- 作者姓名: 黄森清
- **类别领域:** 电子信息(软件工程)
- 校内导师: 赵云波教授
- 实践导师: 胡峰高工
- 完成时间: 二〇二五年五月二十二日

University of Science and Technology of China

A dissertation for master's degree



Research on Wind Power Underground Cable Safety Monitoring System Based on Distributed Fiber Optic Sensing

Author: Huang Senqing

Speciality: Electronic Information (Software Engineering)

Supervisor: Prof. Zhao Yunbo

Practice supervisor: Mr. Hu Feng

Completion date: May 22, 2025

中国科学技术大学学位论文原创性声明

本人声明所呈交的学位论文,是本人在导师指导下进行研究工作所取得的 成果。除已特别加以标注和致谢的地方外,论文中不包含任何他人已经发表或撰 写过的研究成果。与我一同工作的同志对本研究所做的贡献均已在论文中作了 明确的说明。

作者签名: 黄森清 签字日期: 2025、5、23

中国科学技术大学学位论文授权使用声明

作为申请学位的条件之一,学位论文著作权拥有者授权中国科学技术大学 拥有学位论文的部分使用权,即:学校有权按有关规定向国家有关部门或机构送 交论文的复印件和电子版,允许论文被查阅和借阅,可以将学位论文编入《中国 学位论文全文数据库》等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、汇编学位论文。本人提交的电子文档的内容和纸质论文的内容相一 致。

控阅的学位论文在解密后也遵守此规定。



摘要

风电地埋电缆安全监测是保障风电站长距离输电安全的重要技术手段。如 何避免电缆遭受盗挖、误挖等地面活动破坏是安全监测的主要难点。分布式光纤 传感技术可以利用与电缆一同埋设的整条通信光纤作为传感器,实现对地面活 动的实时监测,因此在风电地埋电缆安全监测中逐渐得到应用。然而,该技术在 实际应用中存在传感数据规模庞大、地面活动特征复杂、计算资源受限等问题, 传统基于单一检测器的数据处理和检测方法很难同时满足实时性和检测精度的 要求。因此,迫切需要开发一套智能监测系统,且该系统可以融合侧重轻量化与 高精度的两种目标检测算法。

针对上述问题,本文开展了基于分布式光纤传感的风电地埋电缆安全监测 技术研究,提出了轻量化与高精度两种目标检测算法改进方法,并基于级联检测 策略开发了融合上述两种改进方法的智能监测系统。具体研究内容如下:

(1)针对快速检测阶段对模型轻量化的要求,提出了一种结合变体卷积和注意力机制的轻量化目标检测算法改进方法。该方法使用轻量化卷积取代普通卷积,从而有效减少网络参数量和计算成本,并融合本文提出的多感受野注意力,增强了模型对复杂目标特征的表征能力。在不明显牺牲精度的前提下,该方法将检测器模型的参数量降低约 20.88%,计算量减少约 14.60%,有效提高了检测效率。

(2)针对精细检测阶段对模型准确性的要求,提出了一种基于跨阶段过滤网 络架构的高精度目标检测算法改进方法。该方法通过本文设计的用于特征融合 和过滤的模块,实现了浅层纹理特征与深层语义特征的高效融合,增强了网络 对目标的多尺度特征表达能力。实验表明,在计算开销增加较少的情况下,该 方法可以将原检测器的 mAP@50:95 精度提升约 2%~5%, mAP@50 精度提升约 3%~6%。

(3) 开发了基于分布式光纤传感的风电地埋电缆安全监测系统,系统基于级 联检测策略实现了数据实时采集、分析处理、可视化展示和异常报警等功能。系 统集成经过轻量化改进与高精度改进后的两种检测算法,采用先进行高精度检 测器初筛,然后进行轻量化检测器复检的模式,有效缓解了监测系统的缓存压 力,降低了计算资源消耗,提升了系统的实时监测效率与对地面活动的精细识别 能力,具有良好的工程应用价值。

关键词:分布式光纤传感;电缆安全监测;目标检测;网络架构;注意力机制

Ι

ABSTRACT

Wind power underground cable safety monitoring is a crucial technological measure to ensure the safe long-distance transmission of electricity in wind farms. One of the main challenges in safety monitoring is preventing cable damage caused by ground activities such as theft excavation and accidental digging. Distributed optical fiber sensing technology utilizes the entire communication fiber buried alongside the cable as a sensor to achieve real-time monitoring of ground activities. As a result, it has been increasingly applied in wind power underground cable safety monitoring. However, in practical applications, this technology faces challenges such as massive sensor data, complex ground activity characteristics, and limited computational resources. Traditional data processing and detection methods based on a single detector struggle to simultaneously meet the requirements of real-time performance and detection accuracy. Therefore, it is urgently necessary to develop an intelligent monitoring system that integrates both lightweight and high-accuracy target detection algorithms.

To address the above issues, this dissertation conducts research on wind farm underground cable safety monitoring technology based on distributed optical fiber sensing. It proposes improved methods for lightweight and high-accuracy target detection algorithms and develops an intelligent monitoring system that integrates these two improvements based on a cascaded detection strategy. The specific research contents are as follows:

(1) To meet the requirement for model lightweighting in the fast detection stage, this dissertation proposes an improved lightweight target detection algorithm that combines variant convolution and attention mechanisms. The method replaces standard convolution with lightweight convolution, effectively reducing network parameters and computational costs. It also incorporates a multi-receptive field attention mechanism proposed in this dissertation to enhance the model's ability to represent complex target features. Without significantly sacrificing accuracy, this method reduces the parameter count of the detector model by approximately 20.88% and decreases computation costs by about 14.60%, thereby significantly improving detection efficiency.

(2) To meet the requirement for accuracy in the fine detection stage, this dissertation proposes an improved high-accuracy target detection algorithm based on a crossstage filtering network architecture. A feature fusion and filtering module designed in this dissertation enables efficient fusion of shallow texture features and deep seman-

ABSTRACT

tic features, enhancing the network's capability to represent multi-scale target features. Experimental results show that with minimal increase in computational overhead, this method improves the original detector's mAP@50:95 accuracy by approximately 2% to 5% and mAP@50 accuracy by approximately 3% to 6%.

(3) An intelligent wind farm underground cable safety monitoring system based on distributed optical fiber sensing has been developed. The system, utilizing a cascaded detection strategy, enables real-time data acquisition, analysis, visualization, and anomaly alarm functions. It integrates two improved detection algorithms—one optimized for lightweight efficiency and the other for high accuracy. The system first employs a high-accuracy detector for initial screening, followed by a refined re-detection using the lightweight detector. This approach effectively alleviates the buffering pressure of the monitoring system, reduces computational resource consumption, enhances real-time monitoring efficiency, and improves the precise identification of ground activities. The system demonstrates significant engineering application value.

KEY WORDS: Distributed Fiber Optic Sensing (DFOS), Cable Security Monitoring, Object Detection, Network Architecture, Attention Mechanism

目录

第1章 绪	者论	1
1.1 研算	充背景与研究意义	1
1.1.1	风电发展宏观背景	1
1.1.2	风电地埋电缆安全监测技术背景	2
1.1.3	风电地埋电缆安全监测研究意义	3
1.2 国	为外研究现状	3
1.2.1	分布式光纤传感技术现状	4
1.2.2	基于分布式光纤传感技术的监测研究现状	6
1.2.3	目标检测技术现状	9
1.2.4	研究现状总结1	1
1.3 本江	文工作和结构安排1	1
1.3.1	本文工作1	1
1.3.2	结构安排1	2
第2章 相	目关基础知识1	4
2.1 分	布式光纤传感系统及其信号数据1	4
2.1.1	分布式光纤传感系统原理1	4
2.1.2	分布式光纤传感数据特点1	6
2.2 YC	DLO 基本原理1	7
2.3 变位	体卷积与感受野1	9
2.3.1	四种卷积的对比1	9
2.3.2	CNN 中的感受野2	1
2.4 注范	意力机制2	2
2.4.1	SE 注意力	2
2.4.2	CBAM 注意力2	2
2.4.3	CA 注意力2	3
2.4.4	EMA 注意力 2	3
2.5 CN	N 网络架构2	4
2.5.1	ResNet	4
2.5.2	CSPNet	4
2.5.3	MobileNet	4
2.5.4	特征融合架构发展	5

第3章	重 基于变体卷积和多感受野注意力的检测算法改进	27
3.1	引言	27
3.2	基于变体卷积和多感受野注意力的检测算法设计	28
3.2	2.1 整体检测算法的设计	28
3.2	2.2 多感受野注意力的设计	29
3.2	2.3 多感受野快速融合模块的设计	34
3.3	分布式光纤传感数据采集与预处理	36
3.3	3.1 分布式光纤传感振动信号获取	36
3.3	3.2 风电地埋电缆安全监测现场数据集	37
3.4	算法验证与结果分析	38
3.4	4.1 实验设置	39
3.4	4.2 结果与分析	42
3.5	本章小结	45
第4章	ā 基于跨阶段过滤网络架构的检测算法改进	46
4.1	引言	46
4.2	基于跨阶段讨滤网络架构的检测算法改进方法	
4.3	基于特征讨滤视角的 DM 模块设计	48
4.3	3.1 DM 模块的插入方案	48
4.3	3.2 DM 模块具体结构和算法	49
4.4	算法验证与结果分析	50
4.4	4.1 数据集	50
4.4	4.2 主要实验结果	52
4.4	4.3 消融实验	54
4.5	本章小结	61
笠ヶ咅	5 其王公左式坐红住咸的冈中地拥中继空令收测系统	67
东 ∫ 早 5 1	』 奉了万仰式九纤传感的风电地连电缆女主血测示统 引言	02 62
5.1	5. 云纮雪求公析	02
5.2	□ □ □ □ □ □ □ □ □ □ □ □ □ □ □ □ □ □ □	05
5.2	2.1 功能而不	05
5.2	2.2 平功化而不	60
5.5 5 (31 丢 <u>综</u> 迎构	07
5.3	3.9 荷山分留	07
5.2	33 监测流程	60
5.3 5.3	3.2 模块分解	68 69

	目录	_
5.4	系统详细设计与实现	0
5.4.	1 数据采集模块	0
5.4.	2 级联检测模块	1
5.4.	3 数据传输模块	2
5.4.	4 前端可视化模块	3
5.5	系统测试及结果分析73	3
5.5.	1 功能测试	4
5.5.	2 非功能测试	4
5.6	本章小结75	5
第6章	总结和展望	7
6.1 i	论文工作总结7 [~]	7
6.2 Ì	可题与展望77	7
参考文献		
致谢		
在读期间取得的科研成果		

插图清单

图 1.1	2024年第一季度我国各类电源发电量及其占比(单位:亿千瓦时)[3].	. 1
图 1.2	三种不同类型的光纤传感器	. 4
图 1.3	分布式光纤传感的几种典型应用场景	. 6
图 1.4	管道安全预警(PSEW)系统 ^[46]	. 7
图 1.5	广义学习系统(MIFBLS)结构图 ^[47]	. 8
图 1.6	分布式光纤传感数据可视化后不同事件对应的二维和三维时空图	. 9
图 1.7	FPN ^[58] 的网络结构图	10
图 1.8	论文的主要结构	12
图 2.1	基于 RBS 相位法的振动测量原理 ^[16]	15
图 2.2	分布式光纤传感系统	16
图 2.3	YOLOv1 网络结构 ^[53]	17
图 2.4	YOLOv1 网络的输出张量	18
图 2.5	感受野的概念	21
图 2.6	SE 模块的结构图 ^[62]	22
图 2.7	CBAM 模块的结构图 ^[63]	23
图 2.8	CSPNet 思想改造 DenseNet 的结构图 ^[67]	24
图 2.9	Bottlenet 结构	25
图 2.10	C3 结构	25
图 2.11	C2f 结构	26
图 2.12	Gold-YOLO 采用的 low_GD 结构 ^[71]	26
图 3.1	基于变体卷积和多感受野注意力的检测方法	28
图 3.2	多感受野注意力(MRFA)	30
图 3.3	多感受野快速融合模块(Faster-MRFA)	35
图 3.4	8 类 DFOS 信号采集现场	37
图 3.5	8 类 DFOS 信号可视化结果	38
图 3.6	mAP@50收敛过程	44
图 3.7	mAP@50:95 收敛过程	44
图 4.1	基于跨阶段过滤网络架构的检测算法改进方法	47
图 4.2	将 DM 模块插入到 YOLOv8n 算法中的总体设计方案	48
图 4.3	DM 模块具体结构	49

插图清里	插	冬	清	单
------	---	---	---	---

图 4.4	不同时间分辨率下人工挖掘的信号	51
图 4.5	不同时间分辨率下挖掘石头的信号	52
图 4.6	VOC 数据集上跟踪训练过程	59
图 4.7	NEU-DET 数据集上跟踪训练过程	61
图 5.1	风机的地理位置	63
图 5.2	风电站光纤拓扑图	64
图 5.3	信号处理与分析功能用例图	65
图 5.4	数据可视化与实时监测功能用例图	65
图 5.5	监测系统架构图	68
图 5.6	监测过程流程图	69
图 5.7	深度级联检测流程图	71
图 5.8	系统的整体界面	73

附表清单

表 2.1	DAS 解调器型号与技术参数1	17
表 3.1	测试、训练、验证集划分的图片数量	39
表 3.2	训练参数设置	41
表 3.3	DFOS 数据集上模型性能对比	42
表 3.4	三种算法在 DFOS 数据集上各类别检测结果对比	43
表 3.5	VOC 数据集上模型性能对比	43
表 4.1	VOC 数据集上不同模型的性能对比	52
表 4.2	NEU-DET 数据集上不同模型的性能对比	53
表 4.3	不同模型在 DFOS 数据集上的性能评估	54
表 4.4	VOC 数据集上 DM 模块消融实验性能表	55
表 4.5	添加 DM 模块前后 VOC 数据集上各类别检测结果对比	55
表 4.6	NEU-DET 数据集上 DM 模块消融实验性能表	57
表 4.7	添加 DM 模块前后 NEU-DET 数据集上各类别检测结果对比	57
表 4.8	在 VOC 数据集上使用和不使用 MRFA 的性能比较	58
表 4.9	VOC 数据集上使用和不使用 MRFA 不同类别的检测结果比较	58
表 4.10	在 NEU-DET 数据集上使用和不使用 MRFA 的性能比较	50
表 4.11	NEU-DET 数据集上使用和不使用 MRFA 不同类别的检测结果比较.6	50
表 5.1	功能测试结果	74
表 5.2	响应性能测试数据	75
表 5.3	非功能测试结果	75

第1章 绪论

本章首先介绍了风电地埋电缆安全监测的研究背景和意义,然后阐述了分 布式光纤传感技术和目标检测技术在检测领域的相关研究现状,最后给出了全 文的主要工作和结构安排。

1.1 研究背景与研究意义

1.1.1 风电发展宏观背景

早在 2020 年 9 月,我国便提出了"3060"目标,旨在于 2030 年前实现二氧 化碳排放达到峰值,并于 2060 年前实现碳中和^[1]。实现碳中和的远大目标,离 不开风能、太阳能等新能源产业的发展。近年来,我国可再生能源的装机容量不 断取得新的突破,风电和光伏发电的装机容量已超过煤电。

整个 2024 年上半年全国的可再生能源发电量同比增长达到 22%,占全部发电量的比重超过 35%,发电量达到 1.56 万亿千瓦时。其中,里面有 9007 亿千瓦时是风电太阳能发电量,比重大约是 20%,同比增长 23.5%;就风电而言,全国风电发电量达到 5088 亿千瓦时,同比增长 10%,全国风电平均利用率 96.1%^[2]。

风能已成为我国第二大电力来源。根据国家能源局和中国可再生能源学会 风能专业委员会的相关数据,2024年第一季度风电发电量 2665 亿千瓦时,占总 发电量的 10.81%,水电为 2102 亿千瓦时,占比接近 9.39%,因此风电已取代水 电成为我国的第二大电力来源。图1.1展示了 2024年第一季度我国发电量及其比 重情况。



图 1.1 2024 年第一季度我国各类电源发电量及其占比 (单位: 亿千瓦时)^[3]

第1章 绪论

中长期发展而言,我国风电备受期待。国家能源局党组书记章建华曾在文章 中提到"为实现 2060 年前的碳中和目标,我国风电和光伏的总装机容量将超过 50 亿千瓦,是 2024 年规模的约五倍"^[3]。根据中国风能协会的预测,2025 年全 年我国新增风电装机容量将在 8500 万至 9500 万千瓦之间,而到 2030 年,有望 达到 1.5 亿千瓦以上^[3]。从当前的情况及未来的预期来看,风电的角色将变得越 来越举足轻重,成为推动我国社会绿色发展的关键力量。

1.1.2 风电地埋电缆安全监测技术背景

不同的地埋电缆具有不同的特点,主要体现在环境适应性、电压等级和耐用 性等方面。普通地埋电缆主要用于城市配电网,敷设环境较稳定,电压通常较低; 火电站的地埋电缆主要用于厂区内部供电,需具备耐高温、阻燃防火的特性;水 电站地埋电缆需具备防水耐潮、耐腐蚀的特性;相比之下,风电站的地埋电缆由 于需长距离敷设,需具备耐寒耐候、防雷击、耐扭曲等特性,并且电压等级较高。

风电地埋电缆的敷设环境复杂多变。由于风机分布广泛,电力传输通常需要 长距离输送,输电电缆必须穿越城镇、村庄、农田以及生态敏感区域(如自然保 护区、湿地等)。一些地质活动及人类活动(如施工挖掘、农业生产)可能对埋设 电缆造成直接破坏。相较于水电站大多位于水资源丰富区域、火电站集中于厂区 内部,风电场的地埋电缆往往分布范围更广,埋设深度更深,维护难度更大,这 使得传统输电电缆监测方法难以满足风电行业对高效、精准、实时监测的需求。

针对风电地埋电缆的特殊监测需求,分布式光纤传感(Distributed Fiber Optic Sensing, DFOS)技术凭借其独特优势,成为一种极具前景的监测手段^[4-5]。与传统电缆监测方法相比,分布式光纤传感技术具更有优势。首先是适应风电场的长距离输电需求:单根光纤可覆盖几十甚至上百公里,满足风电场大范围电缆监测需求。其次是抗电磁干扰,适应极端环境:风电场地处高海拔、强风、高寒或高湿环境,DFOS系统无需外部供电,具备优越的环境适应性。最后是成本效益高,减少维护投入:相比传统点式传感器或人工巡检,光纤传感技术能够降低运维成本,提高检测效率。

尽管分布式光纤传感技术在风电地埋电缆监测中展现出诸多优势,但其大 规模应用仍然面临数据处理、存储和传输等挑战。由于光纤监测系统可生成海量 数据(几十公里光纤每天可产生太字节级数据),如何在有限的计算资源下提高 监测系统的实时性、精度和数据处理能力成为关键技术难点。此外,为适应风电 场的特殊环境,开发高精度、轻量化的数据处理算法和智能监测系统,是提升风 电地埋电缆安全性和运维效率的关键方向。因此,本研究旨在结合分布式光纤传 感技术的优势,开发一套针对风电地埋电缆安全监测的实时检测系统,以提高电 缆监测的准确性、效率和经济性,为风电场的安全运行提供技术支撑。

2

1.1.3 风电地埋电缆安全监测研究意义

首先,在理论意义层面,本文通过将分布式光纤传感技术与目标检测算法相结合,为风电地埋电缆安全监测系统的设计提供了一种创新性的解决方案。本文通过引入轻量化变体卷积、优化网络架构、引入多感受野注意力机制等技术手段,提出了侧重轻量化与侧重高精度的适用于风电场输电电缆监测的算法框架。为分布式光纤传感技术在高采样率、远距离、高空间分辨率环境下的数据检测研究提供了一些参考。

其次,在实际工程方面,风电场输电电缆作为能源传输的关键通道,其运行 安全直接关系到风电场的发电效能与经济收益。本文结合风电场输电电缆地埋 布设的实际需求,设计了一套实时监测系统。该系统不仅能够实时获取监测数 据,还能通过智能化的分析算法实现对事件的预警和定位,进一步提升输电电 缆的维护效率。此外,所提出的监测系统可显著降低维护成本,减轻人工巡检负 担,满足现代风电场对于自动化、智能化运维的需求。

最后,在社会层面,本文方法的推广应用,有助于促进风电场等清洁能源设施的安全稳定运行,为我国"3060"目标的实现提供技术支持。通过提高风电场输电电缆的监测能力,可以进一步推动新能源行业的技术升级和智能化发展。本文方法对于实现能源结构优化、提升风电行业竞争力,进而保障我国能源安全具有重要意义。

随着基于分布式光纤传感的电缆安全监测技术进一步成熟和推广,未来其 在其他基础设施领域(如高速公路、地下管道)中的应用也将更加广泛,这将为 我国智能化基础设施建设提供相关的技术储备。

1.2 国内外研究现状

电力电缆的安全监测对于维护电力系统的正常运行具有重要意义,很多研 究者对电缆防破坏进行了大量的研究。

舒俊等人^[6]提出了一种地下电缆防破坏监测系统,该系统基于 Matlab 小波 降噪、EMD-AR 谱分析对地下电缆管廊周围环境振动信号进行监测和区分。他 们设计了一种可埋藏标桩的振动信号采集、识别与预警装置,用于监测电缆管廊 周围的环境振动信号。汪亮等人^[7]结合分布式光纤传感技术提出了一种电力电 缆实时监测与评估系统。该系统能够通过分析振动信号的幅度、频率和相位等 特征,准确判断故障位置,为电缆线路的故障监测和预警提供了强有力的技术支 持。熊川羽等人^[8]提出了一种基于分布式光纤传感的电缆安全状态在线监测方 法,利用拉曼散射信号监测电缆温度,瑞利散射信号监测振动情况,从而综合描 述电缆的安全状态。他们的实验表明,这种方法在各种天气干扰条件下仍能保持

3

高精度采集与监测,相较于其他方法,温度与振动监测的精度和准确性均显著提升。根据前人的研究可以发现,目前一些运用于输电电缆的电子监测设备安装和维护成本高,存在空间稀疏的问题,使得其难以满足风电地埋电缆的监测要求。相较于传统的监测方法,分布式光纤传感系统凭借其传感距离长、抗干扰能力强、时空分辨率高、铺设成本低、实时监测等优势,成为了一种颇具前景的新一 代监测方案^[9-10]。

接下来将从分布式光纤传感技术现状、基于分布式光纤传感技术的监测研 究现状和目标检测技术现状三个方面依次介绍相关的研究现状。

1.2.1 分布式光纤传感技术现状

光纤传感器通过检测激光的相位、光强、频率等特征量,能够实现对温度、 应变、振动频率、反射光强度等基本量的监测,具有的优点包括能实现较高的灵 敏度、能够抗电磁干扰、无需供电^[11-12]。如图1.2所示展示了三种不同类型的光 纤传感器:点式、准分布式和分布式。其中,点式只能固定测量一个采样点,分 布式可以将整条光纤上的任意位置上的点位设置成采样点。在输电线路监测中,



图 1.2 三种不同类型的光纤传感器

如果采用点式类型,则会面临施工复杂,检测点密度难以调整的困难。如果采用 分布式光纤传感系统,上面的问题将变得简单,因为整条光纤既是信号的传输通 道,也是传感器本身。这种分布式特点使得系统能够实时监测光纤沿线各点位置 处的信息,测量范围也很广,几米至几十千米都可以^[13]。而且该系统在普通的 单模或多模光纤上都可以应用。 从技术上来说,分布式光纤传感是通过光纤内部的后向瑞利散射光束来识 别光纤链路上不同测量点的物理量变化^[14-16]。根据测量的物理量又可以更细分 为光纤分布式声波传感(Distributed optical fiber acoustic sensing, DAS)和分布 式光纤振动传感(Distributed optical fiber vibration sensing, DVS)两类。目前一 般都集成到一台 DAS 采样机中。

分布式光纤传感系统在光学系统方面的性能指标,主要是空间分辨率和传 感距离,其次是响应频率和应变分辨率。空间分辨率是指在光纤链路上,两个相 邻采样点之间的距离,用来评估系统的定位精度。传感距离是指在光纤链路上, 第一个和最后一个采样点之间的距离。通常来说追求长探测距离的情况下,实现 高空间分辨率变得更加困难。

2017年, Juan 等人^[17]提出了一种结合一阶拉曼放大的相位光时域反射(Φ-OTDR)技术,显著提升了分布式光纤传感系统的性能。该系统实现了 75 公里的 传感距离和 10 米的空间分辨率,能够以 1kHz 的更新速率和 1nc 的分辨率进行应 变扰动的线性单次测量。Zhang 等人^[18]提出并实验验证了一种基于单端接入的 混合干涉仪和 Φ-OTDR 的振动传感系统。该系统在 6.35 km 长的光纤上具有最 高 10m 的空间分辨率和高达 1.2 MHz 的频率响应能力。此系统具有高频振动事 件响应与定位的优异潜能,适用于土木、交通设施的健康监测领域。Masoudi 等 人^[19]提出了一种高空间分辨率的分布式光纤动态应变传感器,该传感器在 5km 长的感测光纤上实现了 5Hz 的频率分辨率和 50cm 的空间分辨率,其应变分辨率 达到 40nc,能够精确量化沿光纤的多重动态扰动。

2020 年 Wang 等人^[20]提出了一种应用多频率数据库解调方法的分布式应变 测量系统,该系统基于随机光纤光栅阵列,能测量很广范围的静态和动态应变。 2021 年 Qian 等人^[21]提出了一种基于脉冲转换算法的分布式动态应变传感方法, 用于 Φ-OTDR。该方法具有 4 米的空间分辨率、8 公里的传感范围、5kHz 的频率 响应以及 56pε/√Hz 的应变分辨率。2022 年 Xu 等人^[22]提出了一种基于压缩感知 的 Φ-OTDR 系统振动定位方法。该方法在 100Hz 和 500Hz 频率下,系统信噪比 分别提高至 40.41dB 和 30.62dB,空间分辨率达到 9 米,频率测量最大相对误差 仅为 8.1%。

2023 年 Li 等人^[23]提出了一种基于稀疏表示的瑞利散射信号去噪方法,显 著提升了 Φ-OTDR 系统的信号信噪比和振动定位性能。在不同的光纤长度的实 验中,该方法使系统信噪比平均提高 3.44dB,振动检测范围延伸至 80km,且信 噪比达到 3.27dB。2024 年杨鉴等人^[24]提出了一种基于分布式光纤振动传感的可 用于汽车尾气管的创新检测方法。该方法通过在汽车尾气管上安装传感器捕捉 泄漏引起的局部气压扰动,利用双马赫-曾德尔干涉结构的分布式振动传感系统 和微分交叉算法解调双端振动信号,并结合互相关时延算法实现高精度泄漏定

5

位。在实验中,通过2米光纤长度模拟泄漏情况,定位精度达到了0.01米。

分布式光纤传感技术已广泛应用于地球物理勘探与地震学领域^[25-26],同时 在油气资源勘探^[27]以及诸如高速公路、能源管道等各类线性基础设施的安全在 线监测^[28]方面展现出显著的技术优势和广阔的应用前景。此外,该技术的应用 范围仍在不断拓展^[29]。图1.3展示了分布式光纤传感的几种典型应用场景。



图 1.3 分布式光纤传感的几种典型应用场景

DFOS 系统因为可以连续测量沿光纤发生的振动,特别适用于远距离、全方 位、多点位场景下的非法入侵、非法破坏、结构损伤等事件的实时监测^[30-32]。研 充者们广泛探索了提高分布式光纤传感系统的传感长度、空间分辨率、频率响应 和定位精度的方法^[33-35]。分布式光纤传感技术研究取得飞速发展,为系统监测 提供了海量数据,但是在实际应用中,挖掘处理采集到的信号,识别里面的事件 也变得愈加困难^[36]。在风电地埋电缆安全监测任务背景下,当威胁事件发生时, 同时需要知道事件的位置和事件类型,以便及时采取应对措施,避免因处理不当 和不及时产生更大的损失。

1.2.2 基于分布式光纤传感技术的监测研究现状

许多学者提出了各种针对分布式光纤传感系统的事件监测识别方法^[37-39]。 传统的分类算法依赖于特定的功能或规则,不能满足实时性要求。相比之下深度 学习可以自发地从大量数据集中提取特征。近年来很多学者已经开始将深度学 习应用于分布式光纤传感系统中^[40-46]。

Zhu 等人^[41]针对能源运输管道面临的外部入侵威胁,提出了一种基于图像 编码和移位窗口 Transformer (SwinT)模型的入侵检测方法。研究中,将分布式 振动传感系统采集的时序信号转换为二维图像,以增强采样点间的相关性和时 间依赖性,并利用 SwinT 的窗口及移位窗口机制进行多尺度特征提取。Zhou 等 人^[42]针对分布式光纤振动传感系统的信号识别问题,提出了一种基于一维残差 学习卷积神经网络(1-D RL-CNN)与 OpenMax 算法的开放集事件识别模型。相 比传统方法,该模型能够同时识别已知和未知类别的事件,从而提高识别精度并 减少误分类问题。

Shi 等人^[43]也将神经网络应用于分布式光纤传感系统采集到的振动信号,不过他们使用的是精心改造后的更小巧灵活的 CNN 结构。该算法在 5 类 5644 个样本事件的数据集上实现了 96.67% 的准确率和 35.61 步/秒的超高速度。

为了解决高噪声监测环境中传感信号分类的困难,He等人^[44]设计了一个可以实现动物入侵、人类入侵和机械挖掘等一共五种不同类型入侵事件的双阶段 识别网络,最终的识别准确率达到97.04%。Wu等人^[45]的研究工作同样聚焦于 识别不同类型的机械入侵信号,他们探究了多种模式识别算法的效果。结果表 明,包括大挖机撞击地面、大挖机刮擦地面和小挖机行驶等多种类似的信号都可 以实现较好的分类效果。

此外,Yang 等人^[46]提出一种可以运用在低信噪比条件下的识别远程管道 入侵的半监督学习算法。如图1.4所示是他们结合该算法提出的管道安全预警 (Pipeline safety early warning, PSEW)系统。该系统基于分布式光纤传感器,旨 在识别和定位可能危害长距离能源输送管道的第三方事件。PSEW 系统的部署 成本低,具有较好的性能和可移植性。



2024年, Zhu 等人^[47]提出一种基于多维信息融合和广义学习系统(Multidi-

mensional information fusion and a broad learning system, MIFBLS)的管道径向威胁状态识别模型。如图1.5所示,他们设计了一种创新性方案:首先通过信息预处理提取多维时频特征,采用信息熵降维以减少数据冗余,并通过深度模块对特征进行时频融合,从而构建更为可靠的特征向量;最后引入BLS增量学习策略来加速模型更新,使其更具实时性和适应性。实验结果表明,该方法在准确性和实时性上均优于传统方案,在实时监控管道径向威胁状态方面展现出极大潜力。



图 1.5 广义学习系统(MIFBLS)结构图^[47]

上面提到的大部分研究集中在事件类型识别上,它们通过采集监测信号生成某类事件的二维图片,作为神经网络的输入,基于图片分类识别的基本思想去实现整个监测系统。这样的系统回避了直接根据分布式光纤传感数据进行定位识别的难题,底层模型只做分类任务,这导致了实际应用中无法从大量光纤传感数据中准确切分事件分片的问题。此外,目前分布式光纤传感系统已经能进行10km级别的长距离信号采集,但是关于长距离情况下进行事件定位的研究还较少。

总体而言,分布式光纤传感系统在电缆安全监测中能采集到海量的数据,这 些时空数据可以处理成二维的时空图或者三维的时空图。图1.6展示了数据可视 化后不同事件对应的二维和三维时空图。越来越多的研究者们借助于计算机视 第1章 绪论

觉中的深度学习方法,包括图片分类、目标检测等关键技术手段,试图从大量的 时空图中识别出不同的安全事件,并且最终实现对事件发生位置的确定。



图 1.6 分布式光纤传感数据可视化后不同事件对应的二维和三维时空图

1.2.3 目标检测技术现状

从分布式光纤传感系统采集到的海量复杂数据中提取出想要的监测数据,还 面临着很大的挑战^[14]。与此同时基于卷积神经网络的目标检测方法不断取得新 进展,为基于分布式光纤传感的风电地埋电缆安全监测提供了相关的技术参考。 以下将从经典方法、深度学习方法的演变等方面,系统综述目标检测技术的研究 现状。

首先是经典目标检测方法的发展和特点。在机器学习阶段,目标检测主要依赖于传统的分类算法。这些方法通常包括特征提取、分类和后处理三个步骤。常见的特征提取方法有尺度不变特征变换(SIFT)^[48]和方向梯度直方图(HOG)^[49],它们通过手工设计特征来捕获图像的边缘、纹理等信息。经典的目标检测框架如可变形部件模型(DPM)^[50]使用了多尺度建模来提升检测效果。然而,这些传统方法对复杂场景中的目标检测效果有限,尤其在面对目标姿态变化、遮挡和光照变化等情况下,鲁棒性不足。它们的性能很大程度上依赖于手工特征的设计,而这些特征无法充分表达目标的高维特征。

然后是深度学习方法的兴起与演变。深度学习方法的崛起带来了目标检测 技术的革命性发展。2012 年, AlexNet^[51]在 ImageNet 挑战赛中的成功标志着深 度学习的广泛应用。随后,卷积神经网络成为目标检测的主要工具。

以 R-CNN 系列为代表的两阶段(区域检测)方法开启了深度学习目标检测的研究热潮。R-CNN^[52]通过生成候选区域,然后对每个区域进行分类来完成检测。虽然该方法在性能上大幅超越了传统方法,但其计算开销较大,难以满足实时需求。后来提出的 Fast R-CNN 通过共享特征提取过程和引入区域提议网络(RPN)提升了检测速度和精度。

为了进一步提高实时性,单阶段检测器(one-stage detectors)应运而生。与 R-CNN 系列的两阶段方法不同,单阶段方法直接在全图像范围内进行目标定位 和分类。2016 年提出的 YOLO (You only look once)系列^[53]和 SSD^[54]是该类方 法的典型代表。YOLO 将目标检测问题转化为回归问题,其速度显著快于两阶段 方法,而 SSD 通过多尺度特征层进行检测,兼顾了速度和精度。2022 年提出的 YOLOv6^[55]是一种面向工业应用的单阶段目标检测框架。通过吸收不同的网络 设计、训练策略、测试技术、量化及优化方法,YOLOv6 系列模型在多样化的使 用场景中表现出色。2023 年提出的 YOLOv7^[56]通过高效灵活的训练工具、改进 的网络架构以及复合缩放方法,在目标检测技术领域实现了新的突破。2024 年 提出的 YOLOv11^[57]作为 YOLO 系列的新版本,在目标检测模型的架构设计上 引入了多项创新,包括 C3k2 (Cross Stage Partial with kernel size 2)块、SPPF(快 速空间金字塔池化)模块以及 C2PSA(并行空间注意卷积块)等组件。

很多目标检测的相关的改进方法不断被提出。为了更好地处理多尺度目标 检测问题,2019年特征金字塔网络^[58](Feature pyramid networks, FPN)被提出。 图1.7展示了 FPN 的网络结构图。



图 1.7 FPN^[58]的网络结构图

FPN 通过自顶向下的特征融合机制生成多尺度特征图,显著提升了检测器 对小目标的性能。随后,RetinaNet^[59]提出了 Focal Loss,专注于解决正负样本比 例失衡的问题,为单阶段检测器的发展提供了新的思路。然后是 Transformer 的 引入。近年来,Transformer 在自然语言处理中持续火爆,很快就在计算机视觉中 得到应用。2020年,Facebook 团队提出 DETR^[60],将目标检测任务建模为集合 预测问题,利用 Transformer 实现了端到端的目标检测。这种方法消除了传统检 测器中的冗余步骤,但其对小目标的检测效果仍需改进。

目标检测技术在近年来取得了跨越式发展,从基于传统特征的检测器到深度学习驱动的方法,再到 Transformer 的引入和多样化应用场景,展现了其广阔的研究前景。在实时目标检测领域,基于 CNN 的 YOLO 系列具有独特的天然优势,因此在本研究中,将基于前人对于 YOLO 的研究,在此基础上结合分布式光纤传感数据的特点展开进一步的探究。

1.2.4 研究现状总结

分布式光纤传感技术飞速发展,目前已经可以实现很高的时空分辨率,广泛 用于地球物理勘探、油气管道监测、交通基础设施安全监测等领域。目前在监测 领域,研究者们提出了多种信号分析和事件识别方法,以提高对破坏性事件的监 测能力。然而,由于监测数据量庞大,如何有效提取和分析振动信号仍是当前研 究的挑战之一。已有研究表明基于神经网络的智能识别可以提高事件识别的准 确率和智能化水平。实时目标检测技术的发展为光纤传感监测数据的分析处理 提供了更多可能。

为适应基于分布式光纤传感的风电地埋电缆安全监测场景,仍然需要一种 智能系统既能利用到高时空分辨率的数据,又能在无异常情况下只使用低时空 分辨率的数据。采用高时空分辨率的数据检测,地面活动检测难度较小,但是需 要处理的数据流量大,适合轻量化检测器;采用低时空分辨率的数据检测,地面 活动检测难度提高,但是需要处理的数据流量较小,适合高精度检测器。

1.3 本文工作和结构安排

1.3.1 本文工作

本文围绕基于分布式光纤传感的风电地埋电缆安全监测技术开展三个研究 内容,从检测算法的轻量化改进、高精度改进、软件系统架构创新三个不同方向 进行了相关的优化调整。具体而言,提出了结合变体卷积和注意力机制的轻量化 目标检测算法改进方法、基于网络架构优化的高精度目标检测算法改进方法以 及开发了基于级联检测策略的风电地埋电缆安全监测系统,系统实现了数据实 时采集、分析处理、可视化展示和异常报警等功能。

1.3.2 结构安排

论文的主要结构安排如图1.8所示。全文共六章,具体结构安排描述如下:



图 1.8 论文的主要结构

第1章阐述本文的研究背景和研究意义,介绍了基于分布式光纤传感技术 进行安全监测的相关进展,给出文章的主要工作和结构安排。

第2章介绍了相关的基础知识,具体包括分布式光纤传感和目标检测的相关知识。

第3章针对快速检测阶段对模型轻量化的要求,提出了一种结合变体卷积和 注意力机制的轻量化目标检测算法改进方法。该方法中融合了本文提出的基于深 度可分离卷积实现的多感受野注意力(Multi-Receptive Field Attention mechanism, MRFA)。MRFA 以新的跨空间学习方式获得了更好的特征表达效果。通过实验 验证了所提出的方法能够降低参数量、增强特征表达,获得不损失太多精度的轻 量化目标检测模型。

第4章针对精细检测阶段对模型准确性的要求,提出了一种基于跨阶段过 滤网络架构的高精度目标检测算法改进方法。该方法中融合了本文提出的一种 基于增强层间特征过滤的 DM 模块(Dialysis Module, DM)。DM 模块体现了分 层特征高效聚合、跨阶段部分连接等架构设计思想,通过建立多层次的分流网络 来构建浅层纹理和深层语义之间的依赖关系。它只将部分特征映射发送到深层 网络,从而避免过大的计算负担。通过实验验证了所提出的方法能够优化网络架 构,获得不增加太多参数量的高精度目标检测模型。

第5章开发了基于分布式光纤传感的风电地埋电缆安全监测系统,系统基于级联检测策略实现了数据实时采集、分析处理、可视化展示和异常报警等功能。提出了一种先进行高精度检测器初筛,然后进行轻量化检测器精细复检的策略。该策略先在第一级检测模型采用低分辨率的输入数据进行一次初筛。若检测到异常目标,则在第二级采用高分辨率的数据精确检测。测试结果表明,该系统通过分级处理,实现了检测时间和检测精度的平衡。

第6章总结全文的工作,同时根据工作中的不足之处给出了未来的研究展望。

13

第2章 相关基础知识

本章针对基于分布式光纤传感的风电地埋电缆安全监测技术所涉及的相关 概念和基础知识进行基础性的介绍。具体来说,本章首先对分布式光纤传感系 统、传感数据特点进行介绍与分析;然后再介绍目标检测模型的基本结构与流 程、当前存在的问题、以及可能改进的方向,对涉及到的相关理论基础进行解释 说明;最后以此作为本文研究工作的切入点。

2.1 分布式光纤传感系统及其信号数据

这部分主要介绍分布式光纤传感系统原理和传感数据特点。包括分布式光 纤传感采集信号的过程、映射成二维图片、数据处理以及随之带来的对检测算法 和系统的要求。

2.1.1 分布式光纤传感系统原理

光纤后向瑞利散射可以这么描述:整条光纤上分布着多个独立的反射点,其 反射位置和反射率呈随机分布。当外界振动作用于光纤时,会引起光纤长度和折 射率的变化,进而影响各个反射点的散射光相位关系。目前,主要有两种方法用 于恢复振动信号波形:第一种方法是基于相位法,该方法适用于光纤受力变形较 小的情况,利用后向瑞利散射相位变化量与应变之间的线性关系来重建振动信 号。另一种方法是基于频谱法,该方法通过调谐探测激光的频率来补偿应变引起 的相位差,从而保持后向瑞利散射光强度的稳定。由于激光频率的变化与光纤所 受应变呈正比关系,该方法可用于测量应变信息。值得注意的是,瑞利散射信号 的应变分析与定位技术是相互独立的,因此,无论采用何种光反射仪获取瑞利散 射信号,都可以通过相位法或频谱法进行解调,从而实现线性振动波形的提取。

假设存在一个在 z 处的光纤反射点,其反射光相位在没有额外施加应变前可用式(2.1)表示:

$$\boldsymbol{\Phi}(z,0) = 2 \int_0^z \beta n(x) \,\mathrm{d}x = 2\beta nz \tag{2.1}$$

其中, $\beta = \frac{2\pi}{\lambda}$ 表示真空中的波矢大小, λ 为波长, n(x) 表示折射率分布, 它同时 也是应变分布 $\epsilon(x)$ 的函数, 具体为 $n(x) = n + C_{\epsilon}\epsilon(x)$, 其中 C_{ϵ} 为光纤的光弹性 系数。

如图2.1所示,在光纤 (z_A, z_B) 区域施加大小为 ϵ 的应变时,位于光纤 $(0, z_A)$ 区域的散射光相位保持不变,而光纤 (z_A, z_B) 区域的散射光相位可用式(2.2)表示:

$$\Phi(z,\varepsilon) = 2 \int_0^z \beta n(x) \, \mathrm{d}x = 2\beta n z_A + 2\beta \left(n + C_\varepsilon \varepsilon\right) (1+\varepsilon) \left(z - z_A\right)$$
(2.2)





图 2.1 基于 RBS 相位法的振动测量原理^[16]

对于光纤 $z \in (z_B, z_F)$ (z_F 表示光纤总长度) 区域内的散射点,其反射光相 位可用式(2.3)表示:

$$\boldsymbol{\Phi}(z,0) = 2 \int_0^z \beta n(x) \, \mathrm{d}x = 2\beta n \left(z - z_B + z_A\right) + 2\beta \left(n + C_\varepsilon \varepsilon\right) \left(1 + \varepsilon\right) \left(z_B - z_A\right) \tag{2.3}$$

施加应变前,在光纤 (*z_A*, *z_B*) 区域内,任意两点之间相隔距离 *L* 的相位差可用式(2.4)表示:

$$\Phi_L(0) = \Phi(z,0) - \Phi(z-L,0) = 2\beta nL$$
(2.4)

而施加应变后,两点之间的相位差可用式(2.5)表示:

$$\Phi_{L}(\varepsilon) = \Phi(z,\varepsilon) - \Phi(z-L,\varepsilon) = 2\beta \left(n + C_{\varepsilon}\varepsilon\right)(1+\varepsilon)L$$
(2.5)

因此,在应变前后,两点间的相位差变化量可用式(2.6)表示:

$$\Delta \Phi_L(\varepsilon) = \Phi_L(\varepsilon) - \Phi_L(0) = 2\beta \left(n\varepsilon + C_{\varepsilon}\varepsilon + C_{\varepsilon}\varepsilon^2 \right) L$$
(2.6)

第2章 相关基础知识

当应变幅度较小时,可以忽略二阶项,从而简化为式(2.7):

$$\Delta \Phi_L(\varepsilon) = 2\beta \left(n + C_{\varepsilon} \right) \varepsilon L \tag{2.7}$$

由式(2.7)可以得出,瑞利散射光的相位变化量与振动引起的光纤轴向应变 ε 呈正比。在振动区域之外,相位差保持不变,即其变化量为零。利用这一特性, 可以精确识别并定位振动区域,从而实现高精度的振动监测与分析。

负责信号采集的光纤传感系统的结构如图2.2所示。窄线宽激光器(Narrow linewidth laser, NLL)是一种特殊设计的激光器,用于提供高度稳定的光源。声 光调制器(Acoustic optic modulator, AOM)通过声波的折射率变化来调制光信 号,用于改变激光的强度或频率。掺铒光纤放大器(Erbium-Doped fiber amplifier, EDFA)是一种用于放大光信号的设备,其中光信号通过掺有铒元素的光纤,从 而增强信号的强度。光纤环行器(Circulator)用于引导光信号流经不同的路径, 它能将光信号注入感测光纤并返回散射光。雪崩光电探测器(Avalanche photo detector, APD)是一种光电探测器,其工作原理涉及光电离引发的雪崩效应。数 据采集系统(Data acquisition system, DAQ)用于收集、存储和处理实验数据的 设备或系统。



图 2.2 分布式光纤传感系统

2.1.2 分布式光纤传感数据特点

以宁波某公司推出的 DAS 设备为例,传感数据在传输和带宽方面具有显著特点。在传输上,采用 UDP 通信协议,模块 IP 固定,与远端上位机连接。UDP 数据包固定为 1410 字节,仅当内部缓存达到 1410 字节时才会发送,这保证了传输的稳定性和一致性。同时,对于低速指令(如心跳包或拆机报警),由于无法填满 1410 字节,系统会补发 820 个字节的 0,以确保完整性。此外,协议采用小端字节序处理,所有数据从低字节到高字节存储。在带宽方面,高速数据传输占用较大,主要由脉冲重复频率和数据包长度决定。例如,对于 10km 长度、10m 空间分辨率的设备,采样频率 10kHz 时,差分解调与振动解调输出数据的带宽均约占用 161.1Mbps,光强曲线与振动 RMS 输出数据的带宽约为 3.22Mbps。

第2章 相关基础知识

整体来看,DAS 设备传感数据具有极高的灵活性,既可以设置超高的采样 频率实现更精细的监测,也可以降低时空分辨率。当采用更高的时空分辨率的时 候,数据量非常庞大,不适合长期保存最高精度的原始数据,这就要求后续的数 据处理模块能够尽快处理。表 2.1是三种型号的分布式光纤传感解调器部分技术 指标。

表 2.1 DAS 解调器型号与技术参数

类型	xxDAS-M2005	xxDAS-M2020	xxDAS-M2050
检测物理量	振动	/声波(嵌入式相位角	裈调)
探测距离	5km	20km	50km
空间分辨率	5m	5m/10m	10m
底噪 (所有位置)	0.1rad	0.1rad	0.3rad
最大响应频率	10kHz	2.5kHz	1kHz
光纤接口	单芯单模光纤,FC/APC		
激光功率		< 0.5mW	
振动信号接口	千兆	以太网(UDP 传输技	办议)
供电及功耗	12VDC, 2	20W@ 单通道,25W	7@双通道

2.2 YOLO 基本原理

YOLOv1 是目标检测领域中单阶段检测算法的先驱^[53],开创了将目标检测转化为单一回归问题的全新思路。YOLOv1 网络结构如图2.3所示。YOLOv1 网络输入为 448×448×3 的彩色图片。中间层主要是卷积层和池化层,用于图片的特征提取。全连接层用来预测目标的位置和类别概率值。



Conv: 卷积层 Max pool: 最大池化操作 Conn: 连接层

图 2.3 YOLOv1 网络结构^[53]

YOLOv1 的核心过程为: 首先, 用 $S \times S$ 的网格(默认 S = 7) 划分输入图像。目标的中心点指定一个网格, 该网格负责预测该目标的类别和边界框信息。

接着,每个网格要预测 B 个边界框,每个边界框要预测 (x, y, w, h) 和置信度 共5个值。其中 (x, y) 是边界框的中心坐标, w 和 h 是边界框的宽与高。每个框 的置信度值 c 定义为式(2.8):

$$c = Pr(object) \cdot IOU_{truth}^{pred}$$
(2.8)

其中, *Pr*(object) 表示目标是否存在于该边界框中,值为0或1; IOU^{pred} 表示预测框与真实框的交并比。这样,置信度不仅表示框中是否有目标,还反映了预测框与真实框的重叠程度。如果在网格里没有物体存在,则 *Pr*(object) = 0,存在的意思是指物体的中心点在这个网格里面。

最后,每个网格还预测目标属于各类别的条件概率 *Pr*(class|object),即目标属于某类别的概率,记为 *C* 个类别概率。尽管一个网格给出两个边界框,但是只有一组分类概率,因此一个网格就只能识别同一个物体。例如,在 20 个类别的数据集中每个网格输出 20 个概率值。

如图2.4所示给出了 YOLOv1 网络的输出张量组成。对于 $S \times S$ 个网格,每个 网格要负责预测 B 个边界框和 C 个类别概率。网络输出就是一个 $S \times S \times (5 \times B + C)$ 的张量。在 YOLOv1 实际算法过程中,划分成 7×7 的网格,并且每个网格负 责预测 2 个预测框 (Box1 和 Box2), 20 个类别。所以实际上, S = 7, B = 2, C = 20。网络输出的张量形状即是 $7 \times 7 \times 30$ 。



图 2.4 YOLOv1 网络的输出张量

在推理预测阶段,需要执行几个步骤。首先是置信度筛选:将每个边界框的置信度与类别概率相乘,得到该框属于某类别的置信度得分。其次是阈值过滤:移除得分低于阈值(如0.2)的边界框。最后是非极大值抑制(Non-Maximum suppression, NMS):去除重叠度过高的冗余框,保留最佳框。

YOLOv1 的损失函数包括三部分:边界框位置损失、置信度损失和类别预测
损失。具体公式为式(2.9):

$$\begin{aligned} \text{Loss} &= \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^{B} \mathbb{I}_{ij}^{\text{obj}} \left[(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right] \\ &+ \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^{B} \mathbb{I}_{ij}^{\text{obj}} \left[\left(\sqrt{w_i} - \sqrt{\hat{w}_i} \right)^2 + \left(\sqrt{h_i} - \sqrt{\hat{h}_i} \right)^2 \right] \\ &+ \sum_{i=0}^{S^2} \sum_{j=0}^{B} \mathbb{I}_{ij}^{\text{obj}} (C_i - \hat{C}_i)^2 \\ &+ \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^{B} \mathbb{I}_{ij}^{\text{noobj}} (C_i - \hat{C}_i)^2 \\ &+ \sum_{i=0}^{S^2} \mathbb{I}_i^{\text{obj}} \sum_{c \in \text{classes}} \left(p_i(c) - \hat{p}_i(c) \right)^2 \end{aligned}$$
(2.9)

其中, 1_{ij}^{obj} 和 1_{ij}^{noobj} 表示二值指示函数,使用 1 表示指示符号。第一项和第二项 为边界框位置损失(坐标损失),用于衡量预测的中心坐标(x,y)以及宽高(w,h) 与真实值的误差, λ_{coord} 用于加权;第三项表示目标存在时的置信度损失,用于 衡量预测的置信度 C_i 和真实置信度 \hat{C}_i 的误差;第四项是无目标置信度损失,衡 量在无目标的网格单元中,模型对背景的置信度预测误差, λ_{noobj} 作为权重降低 其影响;第五项是类别预测损失,用于衡量分类概率 $p_i(c)$ 和真实类别 $\hat{p}_i(c)$ 之间 的误差,仅在目标存在时计算。

2.3 变体卷积与感受野

2.3.1 四种卷积的对比

在后文基于变体卷积和多感受野注意力的检测方法中,使用了新型卷积算 子进行模型的轻量化设计。下面对比普通卷积(Standard Convolution)、深度可 分离卷积(DWConv)、分组卷积(GConv)以及部分卷积(PConv)。

2.3.1.1 普通卷积

普通卷积每个卷积核作用于输入的所有通道,并生成一个单独的输出通道,因此计算量较大。对于一个输入特征图 $I \in \mathbb{R}^{c \times h \times w}$,卷积核大小为 $k \times k$,输出通 道为 c',普通卷积的计算量(FLOPs)和参数量(Parameters)分别可用式(2.10)和 式(2.11)表示:

$$F_{\rm std} = h \times w \times k^2 \times c \times c' \tag{2.10}$$

$$P_{\text{std}} = (k^2 \times c + 1) \times c' \tag{2.11}$$

其中, $P_{\rm std}$ 表示普通卷积的总参数量, $F_{\rm std}$ 表示普通卷积的计算量。

2.3.1.2 深度可分离卷积

深度可分离卷积对每个输入通道分别使用一个卷积核进行卷积,然后每个 卷积核只生成一个输出通道。这种方式与分组卷积类似,但分组卷积可以将通道 分为多个组,每组共享一个卷积核。深度可分离卷积的计算量比普通卷积大大减 少,但会有精度下降,因此通常在 DWConv 之后会接一个逐点卷积(Pointwise Convolution, PWConv)来补充特征融合能力。

对于一个输入特征图 $I \in \mathbb{R}^{c \times h \times w}$,卷积核大小为 $k \times k$,输出通道为 c',深 度可分离卷积将普通卷积拆分为两个步骤:

先是深度卷积,对每个输入通道 c 使用一个 $k \times k$ 的卷积核进行逐通道卷积。 则卷积核总数为 c,每个卷积核的大小为 $k \times k$,这一步的计算量和参数量分别 为: $F_{dw,depth} = h \times w \times k^2 \times c$ 和 $P_{dw,depth} = k^2 \times c$ 。

然后是进行一个逐点卷积。这一步使用 1×1 卷积核,将 c 通道映射到 c'输出通道。逐点卷积的计算量和参数量分别为: $F_{dw,point} = h \times w \times c \times c'$ 和 $P_{dw,point} = c \times c'$ 。

因此深度可分离卷积的计算量和参数量分别可用式(2.12)和式(2.13)表示:

$$F_{\rm dw} = F_{\rm dw,depth} + F_{\rm dw,point} = h \times w \times k^2 \times c + h \times w \times c \times c'$$
(2.12)

$$P_{\rm dw} = P_{\rm dw,depth} + P_{\rm dw,point} = k^2 \times c + c \times c'$$
(2.13)

2.3.1.3 分组卷积

假设分组数为g(即每组包含 $\frac{c}{s}$ 个通道),分组卷积的计算量和参数量分别可用式(2.14)和式(2.15)表示:

$$F_{\rm grp} = h \times w \times k^2 \times \frac{c}{g} \times c' \tag{2.14}$$

$$P_{\rm grp} = k^2 \times \frac{c}{g} \times c' \tag{2.15}$$

2.3.1.4 部分卷积

部分卷积仅在少数几个输入通道上应用卷积核,而其他通道保持不变^[61]。 部分卷积通过只对部分通道应用卷积核,减少了计算量。PConv的计算量介于普 通卷积和深度可分离卷积之间。

对于一个输入特征图 $I \in \mathbb{R}^{c \times h \times w}$,卷积核大小为 $k \times k$,输出通道为 c',如果仅在 c_n 个通道上进行卷积,部分卷积的计算量可用式(2.16)表示:

$$F_{\rm pconv} = h \times w \times k^2 \times c_p \tag{2.16}$$

部分卷积的参数量可用式(2.17)表示:

$$P_{\text{pconv}} = (k \times k \times c_p + 1) \times c_p \tag{2.17}$$

部分卷积可以设置比率 r 来调整参与计算的通道数量,比率可用式(2.18)表示:

$$r = \frac{c_p}{c} \tag{2.18}$$

当比率设置为 $r = \frac{1}{4}$ 时,相比于普通卷积,部分卷积计算量和参数量约下降到原来的 $\frac{1}{16}$ 。

2.3.2 CNN 中的感受野

感受野(Receptive Field, RF)在卷积神经网络中用于描述特定层级的神经 元所能感知的输入图像区域。随着网络层数的增加,感受野的范围也会逐渐扩 大,这意味着较高层的神经元能够感知更大范围的输入图像信息。图2.5展示了 感受野的概念。



图 2.5 感受野的概念

在卷积神经网络中,感受野的计算与卷积核的尺寸、步幅以及池化层的设置 密切相关。卷积核的尺寸决定了每次卷积操作所能覆盖的输入区域的大小。而步 幅则是指卷积核在图像上滑动时的移动距离,步幅越大,感受野的扩展速度也越 快。池化层会进一步增大感受野,因为池化操作会减少图像的空间尺寸,从而增 加感受范围。

假设网络结构为多层卷积层,假设初始感受野为1,对于第*i*层,感受野的 计算方法为式(2.19):

$$RF_i = RF_{i-1} + (K_i - 1) \times \prod_{j=1}^{i-1} S_j$$
(2.19)

其中, RF_i 表示第 *i* 层的感受野; RF_{i-1} 表示上一层(第 *i* – 1 层)的感受野; K_i 表示卷积核大小; $\prod_{i=1}^{i-1} S_i$ 表示从第 1 层到第 *i* – 1 层的步幅的累乘。

随着网络的深度增加,感受野的增大意味着每个神经元能够捕捉到更大范 围的输入信息,从而能够对更复杂的图像特征做出反应。

2.4 注意力机制

传统的卷积神经网络在特征提取过程中,主要依赖于整合局部感受野内的 空间信息与通道信息,因此在捕捉特征之间的全局依赖关系方面存在一定的困 难。为提升网络的表示能力,研究者们提出注意力机制(Attention Mechanism)。 注意力机制通过为重要特征分配更高权重,从而突出关键信息并抑制冗余或噪 声信息。

根据其作用范围,注意力机制可分为空间注意力和通道注意力两种类型。空间注意力旨在增强输入特征的空间相关性,关注不同空间位置的重要性,例如自注意力机制(Self-Attention)在图像分割任务中的应用。通道注意力则侧重于特征图中各通道之间的关系,通过动态调整每个通道的权重,以提高特征的区分能力。

2.4.1 SE 注意力

作为注意力机制的经典代表,Squeeze-and-Excitation(SE)模块通过显式建模特征通道之间的依赖关系,显著提升了卷积神经网络的表现力^[62]。如图2.6所示是 SE 模块的结构图。



图 2.6 SE 模块的结构图^[62]

SE 模块的核心理念为特征重校准,其结构主要包括两个关键步骤: Squeeze 操作和 Excitation 操作。Squeeze 操作通过在空间维度上对输入特征进行全局聚合,生成通道描述符,从而有效捕捉全局感受野的信息。这一过程使得网络能够充分利用全局上下文信息。Excitation 操作则通过自门控机制学习通道之间的依赖关系,并为每个通道生成相应的权重。这些权重用于对特征图的通道进行重新加权,以增强有用特征并抑制冗余特征。

2.4.2 CBAM 注意力

卷积块注意力模块(Convolutional Block Attention Module, CBAM)可以同时实现通道注意力和空间注意力,成为注意力机制领域的代表性成果^[63]。如图2.7所示是 CBAM 模块的结构图。



图 2.7 CBAM 模块的结构图^[63]

CBAM 首先通过通道注意力模块提取每个通道的全局特征,接着利用两层 全连接网络生成相应的通道权重。在完成通道注意力操作后,CBAM 进一步对 调整后的特征图应用空间注意力模块。该空间注意力模块通过对输入特征图在 通道维度上进行最大池化和平均池化操作,生成两种空间特征描述符。随后,这 两种描述符被拼接并经过卷积层处理,以生成空间权重图。最终,这些空间权重 与特征图在像素位置上逐点相乘,从而实现对空间显著性区域的增强。

2.4.3 CA 注意力

Coordinate Attention(CA)是一种新颖的注意力机制,旨在为用于移动端设备的网络模型引入位置信息,同时保持模型轻量化^[64]。CA首先通过沿水平方向和垂直方向分别进行一维全局池化,生成两个独立的方向感知特征图。这些特征图嵌入了特定方向上的全局信息,并通过进一步编码生成两组注意力权重,分别描述输入特征图在对应方向上的重要性。接着,这些权重被逐像素地应用于原始特征图,实现了对显著特征的强化和非相关信息的抑制。与传统的二维全局池化方法相比,这种一维分解的方法既避免了位置信息的丢失,也通过轻量化设计降低了计算成本。

2.4.4 EMA 注意力

2023年,欧阳等人^[65]提出了 EMA 注意力机制。EMA 通过引入跨空间学习 方法和多尺度并行子网络设计,实现了长短依赖关系的建模。在该设计中,部分 通道维度被重新配置为批次维度,并通过分组结构实现空间语义特征在每个特 征组内的均匀分布。此外,EMA 设计了一个轻量级的并行结构,其中一个分支 采用 1×1 卷积处理通道信息,另一个分支使用 3×3 卷积捕获更广泛的空间上 下文信息。这种设计既保留了不同尺度特征的多样性,又通过跨空间学习方法进 一步增强了特征表达。

EMA 模块的并行子结构使得网络能够减少顺序处理的需求,并降低网络的深度。通过在卷积操作中保持通道数不变,EMA 能够有效地学习通道描述,从而在高级特征映射中实现更为精确的像素级关注。

2.5 CNN 网络架构

卷积神经网络的架构设计会显著影响网络模型的性能。本节将对 ResNet、 CSPNet 和 MobileNet 为代表的高效架构进行介绍,同时还总结了一些 YOLO 目 标检测相关的架构发展。这些架构的设计理念为后文基于网络架构的检测算法 改进提供重要参考。

2.5.1 ResNet

增加卷积神经网络的深度是提高模型性能的重要方式,然而,随着网络层数的增加,训练深层网络变得愈加困难。针对这一问题,何凯明及其团队提出了 ResNet 框架^[66]。ResNet 的核心思想是通过引入残差学习来简化网络的传播优化 过程。这种残差学习的方式降低了优化的难度。

2.5.2 CSPNet

CSPNet 通过引入跨阶段分离的特征融合策略,在保持高精度的同时显著降低了计算复杂度,为轻量化和高效 CNN 设计树立了标杆。如图2.8所示是 CSPNet 思想改造 DenseNet 的结构图。



图 2.8 CSPNet 思想改造 DenseNet 的结构图^[67]

2.5.3 MobileNet

MobileNet 架构从 MobileNetV1 到 MobileNetV4 的不断演进,展现了在移动 设备和资源受限环境下实现高效深度学习的能力^[68]。MobileNetV1 核心创新是 引入了深度可分离卷积,显著降低了计算成本和模型参数量。MobileNetV2 进 一步优化了这一设计,加入了倒置残差块(Inverted Residual Block)和线性瓶颈 (Linear Bottleneck)的结构。MobileNetV3 在前两代架构的基础上,引入了自动化 网络架构搜索和硬件感知优化。MobileNetV4 的核心创新在于引入了通用倒置瓶 颈(Universal Inverted Bottleneck, UIB)和移动多量化注意力块(Mobile MQA)。

2.5.4 特征融合架构发展

在以 YOLO 为代表的目标检测器发展过程中,出现了很多用于特征提取,特征融合的网络架构。这些架构思想被应用到具体模块中,包括 YOLOv3^[69]中使用的 Bottlenet 模块、YOLOv5^[70]中使用的 C3 模块、YOLOv8 中使用的 C2f 模块和 Gold-YOLO^[71]中使用的 GD 模块。

图2.9展示了 YOLOv3 使用的 Bottlenet 结构。Bottleneck 层就像管道中的节 流阀,在通道维度上进行压缩和挤压,迫使信息在通道之间进行交互。它首先使用1×1卷积将输入通道数减半,然后使用3×3卷积将通道数恢复到原始值。



图 2.9 Bottlenet 结构

如图2.10所示, YOLOv5 中使用的 C3 结构不同于 YOLOv3 中使用的标准 Bottlenet 模块, C3 模块将改进后的 Bottlenet 用三个卷积进行了封装。相比于 YOLOv3 中的标准 Bottlenet 结构, C3 结构更加强调了信息导流的必要性。



图 2.10 C3 结构

第2章 相关基础知识

如图2.11所示,YOLOv8 中使用的 C2f 结构进一步强调了不同的感受野在类 Bottlenet 结构中的重要性,它用两个标准卷积来封装一个类似 Bottlenet 的结构。 最后通过一个1×1 的标准卷积进行通道变换,对所有通道进行滤波,得到通道 数满足输出要求的张量。



图 2.11 C2f 结构

如图2.12 所示是 Gold-YOLO 采用的 low_GD 结构。Gold-YOLO 提出了 GD 机制(Gather-and-Distribute),主要是为了增强不同尺度之间的特征映射的融合。他们独特的设计为后文的架构设计提供了重要的参考。



图 2.12 Gold-YOLO 采用的 low_GD 结构^[71]

YOLOv7^[56]的研究人员提出了一种对 ELAN 的扩展,来不断增强网络学习能力,同时又不破坏原有的梯度路径,同样为 YOLO 的架构设计提供了很大的参考。通过比较从 YOLOv3 到 YOLOv5 再到 YOLOv8 的 Bottlenet 的转变可以发现,Bottlenet 结构越来越像一个多层的特征金字塔结构,这为后文的架构设计提供了重要的参考。

第3章 基于变体卷积和多感受野注意力的检测算法改进

本章基于变体卷积和注意力机制提出一种目标检测算法轻量化改进方法。讨 论了如何将变体卷积与注意力机制相结合,从而弱化变体卷积所带来的消极影 响。具体而言设计了一个多感受野注意力和一套轻量化模型方案,同时进行了相 关的实验验证。

3.1 引言

由前面分布式光纤传感系统及其信号数据的介绍可以知道,基于分布式光 纤传感的监测系统可以采集到海量的监测信号。巨量的数据为后续的数据挖掘 工作带来了巨大的挑战。得益于目标检测技术的发展,越来越高效的检测模型可 以用于分布式光纤传感数据的智能检测。然而,为适应实际电缆监测场景中的严 苛需求,设计更为高效轻量化的检测模型仍然迫在眉睫。

模型轻量化的两个底层方向是使用更少计算量的变体卷积和使用更高效的 注意力机制。注意力机制可以提高模型的特征表达、特征提取能力,从而可以减 少模型的网络深度和宽度,进而缩小模型规模。常见的轻量化变体卷积包括深度 可分离卷积、分组卷积以及部分卷积,它们都是通过重新定义卷积运算的模式, 降低运算的复杂度,从而减少模型参数量。模型参数量下降的同时也带来了精度 损失。而注意力机制可以通过一种全局的视角进行取舍,通过全局信息再次编码 从而使得模型获得更好的特征表达。

本章的研究内容主要可总结为:首先研究一种多感受野注意力,该注意力机 制主要有两个特点:一个是足够轻量化,另一个是采用了一种层级结构以跨空间 学习的感受野,将捕获的深层特征用的全局的注意力权重编码。其次是本章给出 了一种融合部分卷积、深度可分离卷积和多感受野注意力机制的检测算法优化 方法,并且进行了实验验证。

本章的结构安排如下:第3.2节给出了基于变体卷积和多感受野注意力的检测算法改进方法,并将该方法应用在检测模型上,同时给出了多感受野注意力(MRFA)和多感受野快速融合模块(Faster-MRFA)的设计;第3.3节介绍了分布式光纤传感数据采集与预处理;第3.4节进行了算法验证与分析,这些不仅是对本章方法的验证,也为后面章节的研究提供了基础。

27

第3章 基于变体卷积和多感受野注意力的检测算法改进

3.2 基于变体卷积和多感受野注意力的检测算法设计

本章提出一种基于变体卷积和多感受野注意力的检测算法,如图3.1所示,算 法主要包括骨干网络模块、颈部特征融合网络以及检测头网络。其中在骨干网络 模块、颈部特征融合网络中使用了本章提出的一种基于变体卷积和多感受野注 意力(MRFA)的多感受野快速融合模块(Faster-MRFA)。这个模块的主要功能 是在检测模型中进行轻量化的特征融合,这对于迫切需要降低网络复杂度的分 布式光纤传感监测系统具有重要的意义。Faster-MRFA 中采用了部分卷积来控制 模型参数量,于此同时引入本章提出的多感受野注意力来削弱模型参数量下降 带来的精度下降。



图 3.1 基于变体卷积和多感受野注意力的检测方法

3.2.1 整体检测算法的设计

如图3.1所示,首先对于给定的任意一张输入图片,首先会经过两个步长为 2 的 Conv 卷积操作,经过这两次降采样以后通道数增加,这时候再通过一个 Faster-MRFA 模块进行特征融合。这里的 Faster-MRFA 模块不改变特征图维度。 接着再经过一个 Conv 卷积降采样,提升通道数,之后再通过一个 Faster-MRFA 模块,这时候的特征张量记作 ℝ₁^{C×H×W}。再经过一个 Conv 卷积和 Faster-MRFA 模块之后的张量记作 R^{C×H×W}。继续经过一个 Conv 卷积和 Faster-MRFA 模块以 及快速空间金字塔池化(SPPF)模块之后的张量记作 R^{C×H×W}。以上整个流程 是改进后的目标检测算法骨干网络,主要负责特征提取。

接着是颈部特征融合网络的具体设计。 $\mathbb{R}_3^{C \times H \times W}$ 经过一次上采样之后与 $\mathbb{R}_2^{C \times H \times W}$ 进行通道维度的 Concat 拼接,拼接之后依次通过一个 Faster-MRFA 和 上采样,之后与 $\mathbb{R}_1^{C \times H \times W}$ Concat 拼接,拼接之后通过 Faster-MRFA 之后的张量 记作 $\mathbb{R}_4^{C \times H \times W}$ 。它再经过一个 Conv 卷积、Faster-MRFA 之后记作 $\mathbb{R}_5^{C \times H \times W}$ 。最 后 $\mathbb{R}_5^{C \times H \times W}$ 经过一个 Conv 卷积之后与 $\mathbb{R}_3^{C \times H \times W}$ 进行 Concat 拼接,拼接之后经 过一个 Faster-MRFA 记作 $\mathbb{R}_6^{C \times H \times W}$ 。至此完成所有的特征融合过程。

最后是将抽取出来的 $\mathbb{R}_4^{C \times H \times W}$ 、 $\mathbb{R}_5^{C \times H \times W}$ 、 $\mathbb{R}_6^{C \times H \times W}$ 送到检测头网络进行不同尺度下的检测。

3.2.2 多感受野注意力的设计

接下来具体介绍本章提出的多感受野注意力。MRFA 的整体结构如图3.2所示。MRFA 将围绕如何高效为模型注入先验知识这一基本的目标进行设计。 MRFA 首先会进行特征分组,接着同组的特征图将经过一个 3 分支的并行子 网结构进行注意力权重运算。MRFA 通过三条平行路线来提取分组特征图的注 意力权重描述符。两条平行路径在1×1分支上,第三条路径在多感受野空间信 息学习分支上。

多感受野注意力首先是进行特征分组。对于任意给定的输入特征图 X ∈ ℝ^{C×H×W}, MRFA 先在通道维度方向上将 X 分成 C//G 个子特征,以学习不同的 语义,其中不同的组可以通过公式(3.1)来表示。

$$X = \begin{bmatrix} X_0, X_1, \cdots, X_{G-1} \end{bmatrix}, \quad X_i \in \mathbb{R}^{C//G \times H \times W}$$
(3.1)

采用这种特征分组的结构一方面可以使得不同分组之间可以同时进行后续的注意力权重运算,从而加快运算速率,另一方面只在组内进行注意力权重运算可以避免直接对整个 *X* ∈ ℝ^{C×H×W} 的通道进行全局的运算。这种全局的运算量与输入输出通道数的乘积成正相关。而在目标检测特征提取网络中,通道数通常随着网络层数以指数级速率增长,因此,通道数很快就能达到 1024、2048 这种典型值。避免这种全局的注意力权重运算对于控制整个 MRFA 的轻量化是很有必要的。此外,基于局部性原理,相邻通道之间的信息关联性是很大的,基于此生成注意力权重描述符是可行的。在具体的实验中将每 8 个通道作为一个小组。



图 3.2 多感受野注意力(MRFA)

3.2.2.1 建立跨通道信息交互

多感受野注意力通过两条平行的1×1分支建立跨通道信息交互。特征分组 之后,同组的特征图将分别经过两条1×1分支。两条平行的1×1分支在较轻的 计算预算下捕获组内所有通道之间的依赖关系,从而使得 MRFA 可以对跨通道 信息交互进行建模。这种建模主要采用了两个1D全局平均池化操作。用于在高 度 H 维度上编码全局信息的1D 全局平均池化可表示为式(3.2):

$$z_c^H(H) = \frac{1}{W} \sum_{0 \le i \le W} x_c(H, i)$$
(3.2)

其中, x_c 表示第 c 通道的输入特征; H 表示输入特征图的高度; W 表示输入特征图的宽度; $z_c^H(H)$ 表示对第 c 通道的输入特征图在高度维度 H 进行 1D 全局 平均池化后的结果。

这个分支的编码可以实现对水平维度方向上长距离依赖的捕捉,同时保留

了在垂直维度方向上的位置信息。于此同时,另一个1×1分支利用沿宽度 W 维度方向的 1D 全局平均池化来实现空间上的长距离交互,从而加强对感兴趣 通道的关注。用于在宽度 W 维度上编码全局信息的 1D 全局平均池化可表示为 式(3.3):

$$z_c^W(W) = \frac{1}{H} \sum_{0 \le j \le H} x_c(j, W)$$
(3.3)

其中, x_c 表示第 c 通道的输入特征图; H 表示输入特征图的高度; W 表示输入特征图的宽度; $z_c^W(W)$ 表示对第 c 通道的输入特征图在宽度维度 W 进行 1D 全局平均池化后的结果。

经过 1D 全局平均池化之后,获得两个二维的编码特征,将这它们沿高度方向连接起来,然后经过一个共同的 1×1 卷积,该卷积不改变 1×1 分支的维数,只是起到一个编码特征融合的作用。将 1×1 卷积的输出分解为两个向量后,再经过一个 Sigmoid 激活函数。最后 $X \in \mathbb{R}^{C//G \times 1 \times W}$ 和 $X \in \mathbb{R}^{C \times H \times 1}$ 的编码特征 相乘之后聚合成组内的一个 $X \in \mathbb{R}^{C \times H \times W}$ 通道注意力特征图。

3.2.2.2 多感受野跨空间学习

多感受野注意力将通过多感受野跨空间学习方法进行空间信息的提取。在 多感受野空间信息学习分支上,分组特征将经过多感受野空间信息注入和跨空 间信息融合实现跨空间学习。

在跨空间注入阶段,通过三条不同深度的平行路径来提取分组特征图的注意力权重描述符。一条支路在最浅的3×3分支上,一条支路在3×3、5×5分支上,最深支路的在3×3、5×5、7×7分支上。相比于只参考一层卷积层这种单感受野的策略,采用多层次感受野感知的策略,可以在多层卷积操作中不过分增加参数量和计算量的情况下获得更好的特征描述。

在跨空间信息融合阶段,仅以多感受野空间信息学习分支上的3×3分支为例子,5×5、7×7分支上与之类似。先引入两个张量,其中一个是1×1分支的输出,另一个是3×3分支的输出。然后使用2D全局平均池化对1×1分支的输出进行全局空间信息的编码,最后将最小分支的输出直接转换为相应的维度形状,即 ℝ₁^{1×C//G}×ℝ₃^{C//G×H×W}。2D 全局平均池化操作的具体公式为式(3.4):

$$z_{c} = \frac{1}{H \times W} \sum_{i=1}^{H} \sum_{j=1}^{W} x_{c}(i, j)$$
(3.4)

其中, *z_c* 用于全局信息编码和远程依赖关系建模。在 2D 全局平均池化的输出后 采用非线性函数 Softmax 处理。通过将上述计算处理的输出进行点积运算相乘, 得到第一个特征图。然后同样利用 2D 全局平均池化在 3×3 分支编码全局空间

信息上, 1×1 分支在通道特征联合激活机制前直接转换为相应的维度形状,即 $\mathbb{R}_{3}^{1 \times C / / G} \times \mathbb{R}_{1}^{C / / G \times H \times W}$ 。在此基础上,获得第二个空间注意特征图。

最后,将每组的输出特征叠加后采用 Sigmoid 激活函数处理。最终输出与 *X* 的大小相同。

3.2.2.3 MRFA 多感受野跨空间学习的优势

多感受野跨空间学习分支没有采用一个3×3的普通卷积进行跨空间信息的 注入,而是采用堆叠的3×3、5×5、7×7多层深度可分离卷积堆叠结构。这为 它带来了更大的感受野和更轻量的结构。

首先是具有更大的感受野,逐层计算 MRFA 跨空间学习分支的感受野,其中每层的步长 S 取默认的 1; $RF_0 = 1$ 表示初始输入感受野为 1; K_i 表示第 i 层的卷积核大小为 K。对于第一层感受野计算如式(3.5):

$$RF_1 = RF_0 + (K_1 - 1) \times 1 \tag{3.5}$$

代入具体值即: $RF_1 = 1 + (3 - 1) \times 1 = 3$ 。对于第二层感受野计算如式(3.6):

$$RF_2 = RF_1 + (K_2 - 1) \times 1 \prod_{j=1}^{1} S_j$$
(3.6)

代入具体值即: $RF_2 = 3 + (5 - 1) \times 1 = 7$ 。对于第三层感受野计算如式(3.7):

$$RF_3 = RF_2 + (K_3 - 1) \times 1 \prod_{j=1}^2 S_j$$
(3.7)

代入具体值即: $RF_3 = 7 + (7 - 1) \times 1 = 13$ 。

从上面的计算可以看到, MRFA 跨空间学习分支在学习空间特征描述时,相 比于只使用 3×3 标准卷积,该跨空间学习分支具有更丰富的感受野视野。三条 不同深度的平行分支使得在建模局部和全局特征描述时,分别获得 3×3、7×7、 13×13 的视野宽度,最大视野比之前扩大了约 18.7 倍。

其次是该跨空间学习分支的所需参数量更小。该结构的跨空间学习结构在 参数量上的优势相当明显。如果使用一个标准 k×k 卷积进行跨空间学习,参数 量如式(3.8):

$$P_e = k \times k \times c \times c' \tag{3.8}$$

其中, *P_e* 表示标准 *k*×*k* 卷积核在跨空间学习中的总参数量; *k*×*k* 表示卷积核的大小; *c* 表示输入通道数; *c'* 表示输出通道数。MRFA 中的跨空间学习分支使用了三个 3*x*3,5*x*5,7*x*7 深度可分离卷积,每个卷积参数量如式(3.9):

$$P_m = k \times k \times c + c \times c' \tag{3.9}$$

其中, P_m 表示标准 $k \times k$ 卷积核在跨空间学习中的总参数量; $k \times k$ 表示卷积核的大小; c 表示输入通道数; c' 表示输出通道数。在实际注意力的实现中通常设置 c = c',此时的参数量如式(3.10):

$$P_{m1} = \sum_{i=3,5,7} \left(k_i^2 \times c + c \times c' \right)$$
(3.10)

如果使用一个3×3标准卷积,参数量如式(3.11):

$$P_{e3} = k_3 \times k_3 \times c \times c' \tag{3.11}$$

通常在网络中输入通道 *c* 和输出通道 *c*' 会比卷积核 *k* 大得多,因此采用深度可 分离卷积堆叠的结构会带来参数量的显著减少。以 *c* = *c*' = 128 为例子,带入上 面的计算式: $\frac{P_{m1}}{P_{e3}} = \frac{\sum_{i=3,5,7} (k_i^2 \times 128 + 128 \times 128)}{k_3 \times k_3 \times 128 \times 128} = \frac{59776}{147456} \approx 40.54\%$,此时的深度可分离 卷积堆叠结构参数量仅仅只是单层视野 3×3 标准卷积结构参数量的 40.54%,大 大降低了的跨空间学习的参数代价。

可以看到,尽管 MRFA 使用了更复杂的结构,但是网络参数量反而是下降的,并且随着输入通道数的增加,下降的幅度更快。

3.2.2.4 MRFA 与其它注意力机制的对比

SE 注意力、CBAM 注意力、CA 注意力和 EMA 注意力是近年来卷积神经网络中常用的几种注意力机制,它们在结构设计与功能侧重上各具特色,同时在特征表达增强方面有一定的共通性。MRFA 在结构上借鉴了这几种注意力机制的思想,同时融合了变体卷积和新型的跨空间学习方法,它可以看做是 EMA 注意力的进一步发展。

SE 注意力模块通过对通道间关系进行建模,突出通道维度的重要特征,是 最早提出的通道注意力机制之一,结构简单、易于嵌入各类网络,但它仅关注通 道间的关系,忽略了空间信息。CBAM 在 SE 的基础上进一步引入空间注意力模 块,通过通道注意力和空间注意力的串联建模,不仅能捕捉通道间的重要性,也 能识别特征图中的关键空间区域,提升了特征表达的维度。

CA 注意力机制则引入坐标信息,通过在水平方向和垂直方向上分别进行一 维全局池化,保留空间位置感知能力。EMA 注意力机制则聚焦于长短依赖关系 建模与多尺度信息融合,采用跨空间学习方法和并行子网络结构,能够更细粒度 地进行像素级特征增强,并在保持通道信息完整的同时提升表达能力。MRFA 是 EMA 注意力机制的发展和延伸,通过多感受野跨空间学习融合空间信息,从而 增强了学习效果。

总体而言,这几种注意力机制都以提升特征选择性和表达能力为目标,但关注焦点不同: SE 和 CBAM 偏向通道与空间注意建模, CA 强化位置感知与轻量

化设计,EMA 则注重跨尺度与上下文信息整合,而 MRFA 通过轻量化的设计同时具有多感受野跨空间学习能力,适合更复杂的视觉任务。

3.2.2.5 MRFA 的具体算法

算法 3.1 展示了 MRFA 的具体实现步骤。在 MRFA 中,注意力权重是通过 每个空间中全局特征和局部特征描述符的相似性来引导的。MRFA 采用了一种 轻量级的多感受野跨空间信息聚合策略,这不仅能够有效建模远程依赖关系,还 能够将更广泛的空间视野信息嵌入到可学习的参数中。通过融合不同尺度的上 下文信息,MRFA 能够在生成高级特征图时,更好地关注全局特征。借助多感受 野的跨空间学习方法,结合轻量级多层网络并行结构,MRFA 展现出了一种更为 强大的上下文信息融合能力。

算法 3.1 MRFA 算法流程

Data: 一个维度为 $c \times h \times w$ 的三维张量

Result: 处理后维度仍为 c×h×w 的三维张量

- 1 初始化:将输入张量沿通道维度划分后记为 G₁;
- 2 对 G₁ 进行两个方向的平均池化操作;
- 3 将上一步的结果拼接后通过一个卷积操作;
- 4 将上一步的结果分为两部分,应用 Sigmoid 激活函数并重新加权,记为 R₁;
- 5 对 G₁ 分别应用三种不同深度的深度可分离卷积,记为 D₁、D₂ 和 D₃;
- 6 对 R₁应用 Group Norm (组归一化)后记为 G₂;
- 7 将 G₂ 分别与经过池化和 Softmax 处理后的 D₁、D₂和 D₃相乘,记为权 重 W₁、W₂和 W₃;
- 8 将 D₁、D₂和 D₃依次与经过池化和 Softmax 处理后的 G₂相乘,记为权重 W₄、W₅和 W₆;
- 9 将权重 W₁、W₂、W₃、W₄、W₅和 W₆求和后,应用 Sigmoid 激活函数, 记为 R₂;
- 10 将 G1 与权重 R2 相乘,结果记为最终的输出张量;

11 return 返回输出张量;

3.2.3 多感受野快速融合模块的设计

本节将设计一个基于变体卷积和多感受野注意力的多感受野快速融合模块。 在整个轻量化检测算法中,Faster-MRFA 起到的是特征融合、特征过滤的作用。 考虑到它将使用在骨干网络和颈部网络的多个关键位置,对整个检测模型的参 数量具有重大的影响,因此本节围绕 Faster-MRFA 的轻量化设计给出具体的说 明。

3.2.3.1 Faster-MRFA 的结构

Faster-MRFA 的结构如图3.3所示。图中输出特征图的颜色变化表示输入特征图经过特征融合后发生了变化。



图 3.3 多感受野快速融合模块(Faster-MRFA)

首先对于一个给定的输入特征图 $X \in \mathbb{R}^{C \times H \times W}$,先经过一个 split 分割操作 将特征图沿着通道方向划分为两部分。这样做有两个目的,一个是为了降低后续 需要深度特征融合的通道数量简化 Faster-MRFA 的计算复杂度,其次是为了保 留一些原始的通道特征传递到深层网络进行对比。将这两个 split 分割操作之后 的部分分别记为 $\mathbb{R}_1^{C \times H \times W}$ 和 $\mathbb{R}_2^{C \times H \times W}$,其中 $\mathbb{R}_2^{C \times H \times W}$ 复制成三份进行处理,第 一份直接流转到输出之前的最后一个 1×1 普通卷积块,第二份经过一个 3×3 部 分卷积块、通道数目扩张的 1×1 普通卷积块、通道数目缩小的 1×1 普通卷积 模块、MRFA 注意力块,第二份处理后的结果与第三份通过一个残差网络连接起 来,然后被送到输出前的最后一个 1×1 普通卷积块。在具体的实现细节设计中, split 操作通常设置成沿通道方向等分割,设置 3×3 部分卷积块不改变特征图维 度,设置 1×1 普通卷积块通道数目扩张缩小前后通道数不变,设置 MRFA 注意 力块前后张量维度不改变。至此,最后一个 1×1 普通卷积块的输入通道数就变 成了输入特征图 $X \in \mathbb{R}^{C \times H \times W}$ 通道数的 1.5 倍,该卷积块的输出通道数设置为 与输入特征图通道数相等。

Faster-MRFA 默认情况下输入输出的通道数相等,这样是为了能更方便的插入到目标检测网络框架中。同时为了满足输入输出通道数不等的情况,Faster-MRFA 的最后一个1×1 普通卷积块输出通道可以进行自定义。

3.2.3.2 Faster-MRFA 的具体算法

算法 3.2 展示了 Faster-MRFA 的具体实现步骤。Faster-MRFA 中因为采用了 PWConv 操作进行空间信息融合,使得整个结构更加的轻量化;其次 MRFA 的 应用,使得原本 PWConv 操作带来的精度下降得到了缓解,这是因为 MRFA 能 够重新结合全局信息进行特征编码,它具有更为强大的上下文信息融合能力。

算法 3.2 Faster-MRFA 的具体算法流程

Data: 一个维度为 $c \times h \times w$ 的三维张量

Result: 处理后维度仍为 $c \times h \times w$ 的三维张量

- 1 初始化:将输入张量沿通道维度划分得到的张量记为 G1 和 G2;
- 2 对 G₂ 进行一个 3×3 的 PWConv 操作,得到的张量记为 P₁;
- 3 将 P_1 通过一个 1×1 的 Conv 操作进行通道扩张,得到的张量记为 P_2 ;
- 4 将 P2 通过一个 1×1 的 Conv 操作进行通道缩小,得到的张量记为 P3;
- 5 将 P_3 通过一个 MRFA 操作,得到的张量记为 R_1 ;
- 6 将 R₁ 与 G₂ 相加,得到的张量记为 S₁;
- 7 将 S₁ 与 G₁ 和 G₂ 进行 Concat 拼接,得到的张量记为 C₁;
- 8 将 C₁ 通过一个 1×1 的 Conv 操作进行通道调整,记为最终的输出张量
 output;

9 return 返回输出张量 output;

3.3 分布式光纤传感数据采集与预处理

上一节介绍完整个基于变体卷积和多感受野注意力的检测算法改进方法以 后,在验证其有效性之前需要采集数据集。本节介绍基于分布式光纤传感的风电 地埋电缆安全监测数据采集与预处理过程。

3.3.1 分布式光纤传感振动信号获取

首先是风电地埋电缆安全监测中的振动信号的获取,包括相位解缠绕、带通 滤波和幅值计算。

分布式光纤传感设备采集的相位数据受 2π 周期限制,可能发生跳变,导致不连续性。解缠绕方法通过检测相位增量 $\Delta \phi = \phi_i^{\text{old}} - \phi_{i-1}^{\text{new}}$,若 $|\Delta \phi| > \pi$,则按照公式(3.12)进行修正:

$$k = \lfloor \frac{\Delta \phi}{2\pi} \rfloor, \quad \phi_i^{\text{new}} = \phi_i^{\text{old}} - k \cdot 2\pi$$
(3.12)

其中, ϕ_i^{old} 表示当前点的原始相位数据(可能存在跳变); ϕ_{i-1}^{new} 表示前一时刻已 解缠绕的相位值; $\Delta \phi$ 表示相位增量,用于检测跳变情况;k表示修正因子,确 保相位恢复到正确的范围; ϕ_i^{new} 表示修正后的无跳变相位数据。 信号中的低频漂移和高频噪声会影响测量精度,因此采用带通滤波器滤除 20Hz 以下和 800Hz 以上的成分。滤波器的传递函数如式(3.13):

$$H(z) = \prod_{i=1}^{N/2} \frac{b_{0i} + b_{1i}z^{-1} + b_{2i}z^{-2}}{a_{0i} + a_{1i}z^{-1} + a_{2i}z^{-2}}$$
(3.13)

其中, H(z) 表示滤波器的传递函数, 描述输入信号到输出信号的频率响应; z 表示复变量, 定义为 $z = e^{j\omega T}$, 其中 ω 是角频率, T 是采样周期; b_{0i} , b_{1i} , b_{2i} 表示滤波器的分子(Numerator)系数, 影响系统的零点位置; a_{0i} , a_{1i} , a_{2i} 表示滤波器的分母(Denominator)系数, 影响系统的极点位置; N 表示滤波器的阶数, 通常是偶数, 表示滤波器的复杂度。

幅值计算用于提取信号强度变化,方法是按照公式(3.14)计算信号均值:

$$A(t) = \frac{1}{N} \sum_{i=1}^{N} x_i, \quad \Delta A = A_t - A_{t-1}$$
(3.14)

其中, x_i 为信号幅值, ΔA 反映振动信号的变化趋势。

上面的方法可提高 DFOS 数据信号连续性,减少噪声干扰,接着将采集到 的流数据按照采样点数转换成二维数据,提取某个时间片的数据后转换为灰度 图像,以便于可视化。为了增强图像的可读性,接着将灰度图像映射为伪彩色图 像,采用热力图色彩映射方式,使得细微的地面活动特征更加明显。

3.3.2 风电地埋电缆安全监测现场数据集

为了模拟实际风电地埋安全监测场景下的地面活动威胁,利用 DAS 设备在 华能风电蒙城县某风电场进行了实际的现场数据采集,并且经过可视化后进行 了人工打标签。采集数据时设置时间分辨率 2000Hz,空间分辨率 0.4m;一共采 集了 8 类信号,如图3.4所示。



931挖掘石头

941挖掘泥土

951挖机行驶

961卡车行驶

图 3.4 8 类 DFOS 信号采集现场 37 编号为901的人工挖掘信号是指的在电缆沟上方的挖掘信号;编号为902的 人工挖掘信号是指的是在电缆线路上方的麦地进行的人工挖掘信号;编号为911 的正常信号是指的无异常活动情况下的某段道路附近的正常信号;编号为921的 正常信号是指的无异常情况下的某台风机附近的正常信号;编号为931的挖掘 石头信号是指的挖机在路基施工挖掘石块时候的信号;编号为941挖掘泥土信 号是指的挖掘机挖掘松软泥土的信号;编号为951的挖机行驶是指的挖机在道 路上沿着电缆线路方向行驶的信号;编号为961的卡车行驶信号是指的卡车拉 着挖掘机在道路上沿着电缆线路方向行驶的信号。

采集到的时空监测数据切割成 2000×2000 的数据矩阵,经过可视化后映射 成彩色图片,颜色越深表示该点信号越强烈,扰动越大。如图3.5所示是每类信 号的样例图。图片的长度方向表示空间坐标,从左向右表示远离光纤信号接收 端;图片的宽度方向表示时间坐标,从上往下表示采用时间由先到后。正常信号 通过无监督方法进行标注,其余信号人工标注。将最终获得的 1652 张分布式光 纤传感信号数据集,随机划分为 1239 张训练集,413 张验证集。



图 3.5 8 类 DFOS 信号可视化结果

3.4 算法验证与结果分析

为了评估本章所提出的基于变体卷积和多感受野注意力的检测算法改进方 法在监测任务上的有效性,本节在基于分布式光纤传感的风电地埋电缆安全监 测数据集(DFOS数据集)和其它数据集上进行相关的验证实验,通过实验结果 来证明本章所提方法的有效性。具体而言,首先对实验环境配置细节、所使用数 据集、具体的训练测试细节以及评价指标等进行相关的介绍。其次,将结合了 变体卷积和多感受野注意力方法的使用在基准检测器上进行一系列的对比实验。 最后,通过消融对比,评估所提方法中变体卷积、多感受野注意力对目标检测器 检测性能的影响。

3.4.1 实验设置

在本节中,将提供有关实验和结果的详细信息,以证明提出的变体卷积和多 感受野注意力方法的性能和效率。

3.4.1.1 实验环境

为了公平比较,所有训练都是在没有预训练权重的情况下进行的,所有模型都使用相同的随机分区训练、验证和测试集。所有实验均在配备四个 NVIDIA GeForce RTX 3090 GPU 的环境中进行,每个 GPU 的内存为 24260 MiB,使用 Python 3.9.18 和 torch 2.1.2+cu118。

3.4.1.2 数据集

除了使用 DFOS 数据集之外,为了验证所提方法的有效性,还使用了数据量 更大的数据集作为对比参考。PASCAL VOC(The PASCAL Visual Object Classes) 数据集是计算机视觉领域广泛使用的基准数据集。PASCAL VOC2012 是该系列 的重要版本,包含 20 个常见对象类,包括人类、动物(如猫、狗和马)、交通工 具(如汽车、自行车和飞机)和家居用品(如椅子、桌子和植物)。该数据集包 括 11530 张带注释的图像,共有 27450 个对象实例。图像丰富多样,涵盖了不同 照明条件和背景复杂性的各种日常场景。表 3.1 展示了具体的数据集划分。

划分数据集	Test	Train	Val
数量	2303	8077	1155

表 3.1 测试、训练、验证集划分的图片数量

3.4.1.3 基准方法

为了验证本章提出的变体卷积和多感受野注意力方法的性能和效率,选择 最典型的实习目标检测器 YOLOv8n 作为基准目标检测器。YOLOv8n 是 YOLO 系列目标检测算法中的轻量级版本(Nano版本),专为高效率和低资源消耗场景 设计。作为 YOLOv8 的子版本,它继承了 YOLO 系列的高精度、低延迟的特点, 同时通过轻量化的网络结构在性能与速度之间实现了良好的平衡。YOLOv8n 通 过改进的架构设计,例如更高效的主干网络(Backbone)和特征融合模块,进一 步提升了对小目标和复杂场景的检测能力。此外,YOLOv8n 引入了一些新的优 化技术,如动态标签分配和更高效的损失函数,从而进一步提高了检测精度。 YOLOv8n 的主要优势在于其极低的模型参数量和计算成本,非常适合在嵌入式设备或实时场景中部署。YOLOv8n 也非常适合处理分布式光纤传感数据,因此在它的基础上展开研究优化。

3.4.1.4 评价指标

本章对所提出方法各项性能表现的评估均采用目标检测任务中通用性能评价指标。在检测精度评估方面:主要采用目标类别平均精度均值(mAP)指标对目标检测器的检测精度进行评估。目标检测器计算复杂度评估方面:用所需模型前向传播的计算量(GFLOPs)来评估检测模型推理效率,GFLOPs的取值越大,说明模型推理的效率越低。目标检测器参数规模方面:用模型的参数量大小(Parameters)来评估,参数量越少,模型规模越小。

在目标检测领域,评估模型性能是了解其在实际应用中有效性的重要步骤。 平均精度(mean Average Precision, mAP)是一种广泛使用的性能评估指标。mAP 的计算基于精度(Precision, P)和召回率(Recall, R)的关系。

精度(Precision, P)的定义如公式(3.15)所示:

$$P = \frac{TP}{TP + FP} \tag{3.15}$$

其中,*TP* 表示正例表示模型正确识别的目标数量,*FP* 假正例表示被模型误识别为目标的数量。精度衡量模型检测出的目标是否准确;高精度意味着错误检测少,低精度则反映了模型对非目标区域的错误检测比例较高。

召回率(Recall, R)的定义如式(3.16):

$$R = \frac{TP}{TP + FN} \tag{3.16}$$

其中, FN 假负例表示模型遗漏的目标数量。召回率衡量模型检测出所有目标相关目标的能力。高召回率意味着模型能够覆盖绝大部分的目标,而低召回率表明模型遗漏较多。

AP 是模型对单一类别的性能衡量,其计算如式(3.17):

$$AP = \int_{0}^{1} P(R) \, dR \tag{3.17}$$

其中,其计算涉及绘制类别对应的精度 - 召回曲线 P(R),并取曲线下的面积。

mAP 通常衡量模型在特定 *IOU* 阈值下的性能,对于目标检测,交并比 *IOU*, 被广泛用于衡量预测框与真实框的重叠程度。对于 mAP@50 的定义如式(3.18):

mAP@50 =
$$\frac{1}{N} \sum_{i=1}^{N} AP(i)$$
 (3.18)

其中, N 表示类别的总数, AP(i) 是类别 i 的精度。

为了全面地评估性能,常使用 mAP@50:95,该指标计算了在 *IOU* 阈值从 0.5 到 0.95(步长为 0.05)范围内的平均精度,并取平均值。定义如式(3.19):

mAP@50:95 =
$$\frac{1}{10N} \sum_{i=1}^{N} \sum_{j=1}^{10} AP_{ij}$$
 (3.19)

mAP@50:95 指标能清晰体现模型在不同定位精度水平下的表现,因而被认为是 更严苛的模型性能评估指标。mAP@50 适合粗略评估检测能力,而 mAP@50:95 更能反映模型的精度和鲁棒性

3.4.1.5 训练策略

一些相关的训练参数设置如表3.2所示。实验中将训练轮数设置到 300 次,当进入最后十个轮次的时候关闭数据增强。

参数名	具体参数	具体说明
epochs	300	训练的最大轮数,即模型在训练集上循环多少次数据
batch	16	每次训练的批量大小,表示一次训练中输入到模型的样本数
imgsz	640	将所有输入图片统一缩放到 640×640 大小
optimizer	SGD	优化器类型,SGD 是随机梯度下降优化方法
close_mosaic	10	关闭 Mosaic 数据增强的轮次,用于更好地拟合最终训练数据
lr0	0.01	初始学习率,表示优化器的学习步幅大小
lrf	0.01	最小学习率,学习率随训练逐渐减小的下限
nbs	64	归一化批大小
hsv_h	0.015	HSV 色调增强因子,用于改变图片颜色的色调
hsv_s	0.7	HSV 饱和度增强因子,用于调整图片的饱和度进行数据增强
hsv_v	0.4	HSV 亮度增强因子,用于调节图片亮度进行数据增强
degrees	0	旋转增强角度,表示图片在数据增强中可旋转的最大角度
translate	0.1	平移增强范围,表示图片在数据增强中可平移的比例范围
scale	0.5	缩放增强范围,表示图片在数据增强中可缩放的比例范围
shear	0	剪切增强范围,表示图片在数据增强中可进行剪切变换的范围
perspective	0	透视变换增强范围,表示图片在数据增强中可进行透视变换的范围
flipud	0	上下翻转概率,表示图片在数据增强中上下翻转的概率
fliplr	0.5	左右翻转概率,表示图片在数据增强中左右翻转的概率

表 3.2 训练参数设置

3.4.2 结果与分析

变体卷积结构的引入和多感受野注意力方法为检测模型带来了良好的的性能和更高的效率。以下将从模型的各项参数、模型训练过程收敛情况等方面详细 介绍和分析实验结果。

DFOS 数据集上模型性能对比如表3.3所示。首先相比于基线模型 V8n,采用 变体卷积之后的模型被记作 V8n-Faster,该模型的参数量得到了显著的下降。参数量从 V8n 模型的 3.16M 下降到 2.45M,下降了 22.47%,于此同时浮点操作数 计算量从 8.9G 下降到 6.5G,下降百分比达到 26.70%,网络模型的复杂度下降得 非常明显。这得益于用部分卷积取代了在 V8n 原本模型中的部分结构。这说明 了整个监测模型中不同位置的卷积算子对模型的影响的是不一样的,在某些结构中的算子可以有优化空间。

Models	Parameters/M	Cost/GFLOPs	mAP@50	mAP@50:95
V8n	3.16	8.9	0.781	0.501
V8n-Faster	2.45	6.5	0.737	0.482
V8n-Faster- MRFA	2.50	7.6	0.752	0.491

表 3.3 DFOS 数据集上模型性能对比

其次,相比于基线模型 V8n 和 V8n-Faster 模型,本章提出的 V8n-Faster-MRFA 模型整体的检测精度介于两者之间。V8n-Faster 在加入 MRFA 注意力之后,模型 的性能得到了显著的提升。从 V8n-Faster 到 V8n-Faster-MRFA,模型的参数量只 增加了 0.05M,增加的百分比仅仅为 2.04%。这说明了 MRFA 注意力机制是可 以削弱部分卷积轻量化算子所带来的精度下降的,并且这个过程非常高效。在 DFOS 数据集上 V8n-Faster-MRFA 是综合性能最好的一款模型,达到了 49.1% 的 mAP@50:95 精度,75.2% 的 mAP@50 精度。

此外还针对 DFOS 数据集上每种不同类型的地面活动的检测结果进行了实验分析。表3.4所示展示了三种算法在 DFOS 数据集上的各类别检测结果对比。

就总体类别而言存在两种区分很困难的地面活动类别,901人工挖掘信号和 902人工挖掘信号。这是因为这两类信号的相似度很大,901与902最大的区别 是挖掘的频率,901挖掘频率更低;此外这两类人工挖掘信号与其它信号之间的 区分也不是很明显,它们都更像是信号噪点。此外,两类正常信号的识别准确率 都很高,这是因为一方面正常信号的数据样本最充足,另外是因为正常信号与其 它活动的信号有较大的区别。通过这个对比可以发现一方面,不同模型对不同种 类的地面活动的识别能力有细微的区别,本章提出的 V8n-Faster-MRFA 普遍对 所有类别都可以提升检测效果。考虑到它的规模优势,把它用在基于分布式光纤 传感的风电地埋电缆安全监测是有前景的。

Class		V8n	V8n-Faster-MRFA V8n-Faster			-Faster
	mAP@50	mAP@50:95	mAP@50	mAP@50:95	mAP@50	mAP@50:95
all	0.781	0.501	0.752	0.491	0.737	0.482
901	0.354	0.107	0.320	0.092	0.264	0.085
902	0.515	0.212	0.461	0.192	0.405	0.170
911	0.995	0.995	0.995	0.994	0.995	0.994
921	0.995	0.995	0.995	0.994	0.995	0.994
931	0.838	0.452	0.826	0.463	0.815	0.436
941	0.929	0.606	0.953	0.631	0.961	0.622
951	0.990	0.409	0.965	0.391	0.958	0.376
961	0.632	0.236	0.501	0.171	0.505	0.177

表 3.4 三种算法在 DFOS 数据集上各类别检测结果对比

通过上面在 DFOS 数据集上的各类别检测结果可以发现,在实际的现场数据集中具有很大的样本类别不均衡的问题。在大多数时候采集到的分布式光纤传感数据都是正常信号,只有很特别的时候才会收集到异常信号。

为了继续探究本章提出的方法是否可以使用在更广泛的场景之下,继续使用 规模更大的数据集进行相关的对比实验。VOC 数据集上模型性能对比如表3.5所 示。

Models	Parameters/M	Cost/GFLOPs	mAP@50	mAP@50:95
V8n	3.16	8.9	0.658	0.471
V8n-Faster	2.45	6.5	0.614	0.429
V8n-Faster- MRFA	2.50	7.6	0.629	0.446

表 3.5 VOC 数据集上模型性能对比

实验结果表明,V8n-Faster-MRFA 相比 V8n-Faster 以 0.05M 的参数量增加代价,换来了 1.7% 的 mAP@50:95 精度提升,0.15% 的 mAP@50 精度提升。结果可以验证所提出的方法既可以运用到 DFOS 数据集上,也可以应用到其它数据集上。是一种有效的目标检测算法轻量化改进方法。

训练过程中的 mAP@50 收敛过程如图3.6所示。蓝色线条表示 V8n 基线模型, 黄色线条表示轻量化模型 V8n-Faster, 中间的绿色线条表示 V8n-Faster-MRFA 模型。可以发现, 部分卷积的引入使得模型训练前期的精度波动变大了, 但是开始

变得平稳的轮次数比基线模型提前了。另外在训练开始的前面轮次, MRFA 的存在并没有之间拉开与 V8n-Faster 的差距, 而是 80 轮次左右开始明显影响模型的 学习效果。



图 3.6 mAP@50 收敛过程

训练过程中的 mAP@50:95 收敛过程如图3.7所示。mAP@50:95 是比 mAP@50 更为严苛的标准,它描述的是模型在更高交并比条件下的检测能力, 由图中可以看到, V8n-Faster-MRFA 模型在这个更高标准下的性能提升甚至比 mAP@50 指标的提升更显著,这说明了 MRFA 的引入使得模型定位到的目标更 精准。



图 3.7 mAP@50:95 收敛过程

3.5 本章小结

本章围绕基于变体卷积和多感受野注意力的检测算法改进这一核心内容展 开介绍。为了适应分布式光纤传感信号数据量大的特点,检测模型的轻量化成为 一个提升监测系统效率的一个重要途径。首先介绍了整个方案的大致情况,主要 是包括引入变体卷积和使用注意力机制提升模型性能。该方案中的变体卷积有 两个作用,一是直接带来模型的参数量下降,另外是它被用来设计多感受野注意 力的跨空间学习子网结构。基于此,本章详细介绍了多感受野注意力的实现过 程,以及多感受野快速融合模块的结构细节。最后将所提出的方法用于实际模 型中,并且采集了风电站现场的分布式光纤传感数据,同时补充了其它数据集共 同验证所提方法的效果。实验结果表明,在不明显牺牲精度的前提下,该方法将 检测器模型的参数量降低约 20.88%,计算量减少约 14.60%,有效提高了检测效 率。

第4章 基于跨阶段过滤网络架构的检测算法改进

本章将基于网络架构调整提出一种新的高精度目标检测改进方法。先总体 上介绍了基于跨阶段过滤网络架构的检测算法改进方法,然后引出该方法中使 用到的一个基于网络架构调整优化的新模块,之后详细介绍了该模块。最后是将 该方法运用到了各种检测算法中,通过实验验证了它的有效性。

4.1 引言

为了应对分布式光纤传感的监测系统采集到的大量监测数据,势必会考虑 降低检测模型的输入数据分辨率,这时候就需要更高精度的检测器。为了能适应 高精度检测的需求,仍然需要一些新架构优化,以便能够将更多的先验知识融入 目标检测器,从而使得模型更加简洁高效。近年来检测器架构思想在不断发展, 并且用于检测器架构的新模块也在不断创新迭代。

网络架构的优化贯穿整个目标检测技术的发展,CNN 网络独有的运算特性 使得网络架构成为检测效果的一个重要影响因素,相比于直接简单增加网络模 型的深度或宽度,一个合适的网络结构能带来更低成本的精度提升。尽管神经网 络的可解释性较差,但是仍然涌现了很多网络架构理论,本章将基于此,通过结 合不同的架构思想以及先验知识,提出一个基于架构设计的优化方法,目标是尽 可能用最少的代价获得更大的性能提升。

本章的研究内容可总结为:首先研究一种基于网络层间特征过滤的检测算 法优化方法。该方法通过建立多层次的分流网络来构建浅层纹理和深层语义之 间的依赖关系,并且结合分层特征高效聚合、跨阶段部分连接的思想,只将少部 分特征映射发送到深层网络,从而大大减少模型的参数量。此外将该方法运用到 多种不同的目标检测器中,并进行实验验证。

本章的结构安排如下:第4.2节给出了应用该优化方法的总体使用说明;第4.3节给出了跨阶段过滤网络架构中使用的 DM 模块的详细设计和应用方案;第4.4节进行了算法验证,在包括基于分布式光纤传感的风电地埋电缆安全监测数据集在内的几个数据集上进行了对比实验。

4.2 基于跨阶段过滤网络架构的检测算法改进方法

本章提出一种基于网络架构调整的检测算法改进方法,如图4.1所示。该方 法主要用到了 DM 模块,它是基于跨阶段过滤思想设计的一种可用于 CNN 网络 层与层之间特征过滤的模块。该模块可同时被用于检测器的主干网和颈部。围



图 4.1 基于跨阶段过滤网络架构的检测算法改进方法

绕 DM 模块的架构调整思想基于两个假设:特征融合结构可以帮助神经网络比较和区分不同通道的特征图;在需要向更深的网络层传递特征图之前,更深层的高级语义信息对于判定哪些特征图应该被过滤、哪些应该被保留是大有帮助的。 在多种数据集上的实验结果表明,这种架构调整思想可以为检测器带来检测精度与模型效率的新平衡。

在基于跨阶段过滤网络架构调整的检测算法改进方法中,DM 模块作为一种 即插即用的特征过滤模块,它可以被放置于任何检测算法的框架中。DM 模块用 于需要进行特征过滤的环节,例如在检测算法进行特征提取时可用于不同尺度 特征图之间的连接。它是一种调节通道方向信息流动的结构,通过建立多层次的 分流网络来构建浅层纹理和深层语义之间的依赖关系。

在将 DM 模块应用到具体的检测算法改进的时候,通常需要注意一些参数 的配置。DM 模块中具有一个重复 n 次的参数,这个重复系数用来控制内部通道 方向信息融合的轮次,默认参数为1次。通常在网络的浅层,特征图的通道数相 对较少,这时候可以设置较大的 n;但是在网络的深层,通道数急剧扩增,为了 控制整个 DM 模块的参数量,通常会设置较小的 n。

4.3 基于特征过滤视角的 DM 模块设计

4.3.1 DM 模块的插入方案

DM 模块的思想认为,特征在层与层之间的传输中缺乏简单而有效的过滤机制,阻碍了多层神经网络性能的进一步提高。因此,DM 模块主要是在特征拆分之前和聚合之后使用,同时尽可能保持原始算法结构,以避免在算法内部产生新的混沌信息流。称经过 DM 模块改造后的 V8n 检测模型为 V8n-DM,与 YOLO 系列的物体检测器类似,V8n-DM 采用 Backbone + Neck + Head 的检测范式。具体来说,只保留负责最终物体检测和输出的 Head 结构,然后在 Backbone 和 Neck 中需要负责特征提取、特征融合的网络层之间插入 DM 模块。

DM 模块可以插入其它主流的检测架构中。YOLO 系列中的不同具体模型会有一些不同的结构。例如 V8、V3 和 V5 具有类似的结构,结构很相似,在这几个算法模型上可以直接使用 DM 模块。V6 和 Gold-YOLO 模型有所不同,它们的结构有所不同,在它们之间插入 DM 模块的位置通常是在主干特征提取网络中,或者也可以主干网络与颈部网络同时插入 DM 模块。如图4.2所示,是将 DM 模块插入到 YOLO 系列 v8n 算法中的总体设计方案。



图 4.2 将 DM 模块插入到 YOLOv8n 算法中的总体设计方案

首先,在骨干网络中的每个特征图尺度变化后插入 DM 模块,以便能利用不

第4章 基于跨阶段过滤网络架构的检测算法改进

同尺度的特征图包含的不同级别的语义信息。插入 DM 模块增强了不同网络层 之间的信息流过滤。然后,在颈部网络中的每次特征图叠加之后插入 DM 模块。 目的是通过 DM 模块过滤两组信息流。在 YOLO 系列的检测算法中,这两组信 息流通常来自两个相邻的语义层次。

4.3.2 DM 模块具体结构和算法

DM 模块的具体结构如图4.3所示。DM 模块的输入为 $c_{in} \times h \times w$ 的三维张 量,首先会经过一个卷积模块,这个卷积块把张量的通道数重塑为 c_{out} 。然后分 成两个相同的张量,一个进入深度融合网络,另一个跳跃到输出前的最后一次卷 积运算。



图 4.3 DM 模块具体结构

橙色线框部分是这个深度融合网络,它的输入输出张量形状都一致,可以连续串联多次,重复系数为 n,可以根据具体的情况选择 n 的大小,默认为 1。在这个深度的融合网络中,张量会依次经过两次的卷积和分割操作,每次卷积以后拿出一半通道之间跳跃到输出出口前的卷积,一半通道送到下一层处理。这样,两层以后通道数变为 0.25cout,这时候将其中一个 0.25cout 的张量通过一次 MRFA 注意力机制处理,得到调整权重之后的紫色张量块。最后,将黄色、绿色、蓝色和紫色块通过 Concat 操作拼接,再通过最后的一个卷积块就得到输出张量。DM

第4章 基于跨阶段过滤网络架构的检测算法改进

模块的最后一步是将通过深度的融合网络的部分和跳跃部分拼接,通过卷积得 到最终的输出张量。算法 4.1给出了 DM 模块算法具体的流程。

算法 4.1 🗌	DM 模块算法流程
----------	-----------

Data: 一个维度为 $c_{in} \times h \times w$ 的三维张量

Result: 一个维度为 $c_{out} \times h \times w$ 的三维张量

- 初始化:将输入张量通过卷积操作,记为两份相等的特征图 t₁ 和 t₂,其 维度均为 c_{out} × h × w;
- 2 for i = 1 to n do
- 3 将 t₂ 通过卷积操作并进行通道划分,分别记为特征图 s₁和 s₂,其维度为 0.5c_{out} × h × w;
- 4 将 s₂ 通过卷积操作并进行通道划分,分别记为特征图 s₃和 s₄,其维度均为 0.25c_{out}×h×w;
- 5 | 将 **s**₄ 通过卷积操作,记为特征图 **t**₃,其维度均为 0.25*c*_{out} × *h* × *w*;
- 6 使用 MRFA 模块处理 **t**₃,记为特征图 **m**,其维度为 0.25*c*_{out} × *h* × *w*;
- 7 将 s₁, s₂, s₃, m 通过卷积操作合并,记为特征图 t₄,其维度为
 1.5c_{out}×h×w;
- 8 将 t₄ 通过卷积操作映射到与 t₂ 相同的维度,其维度为
 1.0c_{out}×h×w,并将其记为新的 t₂ 重新进入循环;

9 end

10 结束循环;

n 将 t_1 和 t_2 合并后通过卷积操作,记为输出张量 output;

12 return 张量 output;

4.4 算法验证与结果分析

本节通过在实际风电场采集的 DFOS 数据集和一些其它数据集来设计实验 验证所提出的方法是否有效。

4.4.1 数据集

本章将使用三个数据集进行交叉验证,分别是 PASCAL VOC 数据集、NEU-DET 数据集和上一章中的 DFOS 数据集。只是这章中的 DFOS 数据集包含了对 它本身进行低分辨率化后的数据,但是因为处理过程中标签仍然沿用的同一个 标签,因此本章还是称为 DFOS 数据集。

PASCAL VOC 数据集:继续使用上一章的 PASCAL VOC2012 数据集作为其中一个数据集。NEU-DET 数据集:它是专门针对热轧钢带缺陷检测而设计的高质量数据集,包含六种典型的热轧钢带缺陷,包括轧入氧化皮(RS)、斑块(Pa)、

裂纹(Cr)、麻面(PS)、夹杂(In)和划痕(Sc)。每个缺陷类别有 300 张样本 图像,共计 1800 张灰阶图像。这些缺陷类型代表了钢铁生产中的常见问题,具 有很高的工业应用价值。NEU-DET 数据集中的图像均为灰阶图像,采集自实际 生产环境,能够准确反映热轧钢带表面缺陷的特征。

继续沿用上一章中风电站现场采集到的地埋电缆 DFOS 数据集。但是,在上 一章的高分辨率数据集基础上,将每十张高分辨率时空图结合成一张低分辨率 时空图,并将合成后的数据集仍然与之前的混合在一起进行训练、测试。低分辨 率时空图在实际场景中不仅可以降低系统处理大量数据的压力,还能帮助网络 模型捕抓地面活动在时间维度上的特征,使得网络更加智能。

如图 4.4 所示,展示了两种时间分辨率下人工挖掘信号的不同特征,沿着高度方向是时间方向,沿着宽度方向是空间方向。低分辨率下事件的短时间细节被弱化,更强调长时间跨度上的特征。对于两类人工挖掘信号而言,在高分辨率下能够更直观的看到两种不同的挥动铁铲挖掘频率,并且在安静的背景对比下挖掘信号显得更加突出;在低分辨率下可以看到被平滑后的挖掘信号在更大的背景下显得更加模糊,能展示的细节比较少,能对比的时空区域更广。



(a)低分辨率人工挖掘信号

(b)高分辨率人工挖掘信号

图 4.4 不同时间分辨率下人工挖掘的信号

如图 4.5 所示,展示了两种时间分辨率下挖掘石头的信号。从图中可以看出,低时间分辨率下的信号特征是减弱的,高时空分辨率下的信号倾斜与表达长时间上的特征。对于挖掘机挖掘石头的信号而言,在高分辨率下能够很直观的看到波形特征,每次机械撞击石头产生的冲击地震波会从碰撞中心向四周扩散,冲击波抵达传感光纤采样点的时间有先后,因此会形成独特的扩散信号;而在低分辨率下会弱化细节,强调整个行为的持续时间,能够减少需要处理的数据流量。

在实际的风电地埋电缆安全监测系统中,采用先使用低分辨率的输入数据

在高精度模型上进行检测的策略是必要的。因此将上一章中的高分辨数据集转 换成对应的低分辨率数据集,投入到本章的高精度模型验证中。



(a)低分辨率挖掘石头的信号

(b)高分辨率挖掘石头的信号



4.4.2 主要实验结果

4.4.2.1 PASCAL VOC 上的结果

PASCAL VOC 上的结果如表4.1所示,与所有基线模型 V8n、V3n、V5n、V6n 相比,采用 DM 模块后,mAP@50 和 mAP@50:95 均有显著改善。必须强调的 是,在更严格的 mAP@50:95 标准下,个别模型甚至达到了下一个尺度水平。例 如 V5s 与 V5n-DM 相比,V5n-DM 的 mAP@50:95 仅落后于竞争对手 0.3%,但模 型所需的参数数量仅为竞争对手的 68.8%,计算成本仅为竞争对手的 70.5%。表中展示了不同模型在 PASCAL VOC 数据集上的性能。它比较了在各种基线模型中插入 DM 模块之前和之后的性能指标,以及相同条件下其他高级模型的性能指标。

Models	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs
V8n	0.6473	0.4635	3.16	8.9
V8s	0.7001	0.5092	11.17	28.8
V8n-DM(ours)	0.6875	0.4984	6.30	15.8
V3n	0.6361	0.4457	3.88	11.2
V3s	0.6962	0.5042	14.60	40.3
V3n-DM(ours)	0.6660	0.4730	6.42	18.7

表 4.1 VOC 数据集上不同模型的性能对比

	续表 4.1 VO	C数据集上个同转	望的性能对比	
Models	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs
V5n	0.6280	0.4340	2.51	7.1
V5s	0.6939	0.4910	9.13	24.1
V5n-DM(ours)	0.6840	0.4940	6.28	17.0
V6n	0.6387	0.4639	4.24	11.9
V6s	0.6929	0.5110	16.31	44.2
V6n-DM(ours)	0.6720	0.4900	6.66	19.2
Gold-YOLOn	0.6566	0.4700	6.02	10.5
Gold-YOLOs	0.6880	0.5000	13.66	30.3
Gold-YOLOn- DM(ours)	0.6790	0.4930	8.96	17.9

第4章 基于跨阶段过滤网络架构的检测算法改进

.

4.4.2.2 NEU-DET 上的结果

通用的 VOC 数据集替换为专门针对工业缺陷检测任务设计的 NEU-DET 数据集,结果如表4.2 所示,加入 DM 模块后,与所有基线模型(包括 V8n、V5n 和 V6n)相比,mAP@50 和 mAP@50:95 都有显著提升。加入 DM 模块的 V5s 和 V5n 在这两个指标上都超越了竞争对手,V8n-DM 也全面超越了 V8s 和 V8n。

Models	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs
V8n	0.743	0.400	3.01	8.2
V8s	0.746	0.411	11.14	28.7
V8n-DM(ours)	0.763	0.416	6.07	16.0
V3n	0.746	0.394	4.06	12.1
V3s	0.739	0.405	15.33	44.1
V3n-DM(ours)	0.735	0.399	6.78	20.6
V5n	0.728	0.394	2.51	7.2
V5s	0.718	0.401	9.12	24.1
V5n-DM(ours)	0.746	0.408	6.27	16.9
V6n	0.752	0.408	4.24	11.9
V6s	0.746	0.416	16.45	44.9
V6n-DM(ours)	0.757	0.413	6.91	19.5

表 4.2 NEU-DET 数据集上不同模型的性能对比

总体来说,表4.2中比较了在各种基线模型中插入 DM 模块之前和之后的性

能指标,以及相同条件下其他高级模型的性能指标。结果表明,采用 DM 模块可以提高模型性能。

4.4.2.3 DFOS 数据集上的结果

表4.3展示了不同模型在真实的分布式光纤传感数据集上的性能表现。加入 DM 模块后,与基线模型(包括 V8n 和 V8s 相比,mAP@50 和 mAP@50:95 两 个指标均有显著提升。特别是在更严格的 mAP@50:95 标准下,V8n-DM 的性能 已经接近了更高参数规模的模型。例如,V8n-DM 的 mAP@50:95 达到了 51.2%, 相比基线模型 V8n 提升了 1.4%,同时几乎持平了参数更大的 V8s(51.4%)。这 表明,在保持较高效率的同时,DM 模块在实际的光纤传感数据集上依然能够有 效提升模型的精度,实现了效率与精度之间的良好平衡。

Models	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs
V8n	0.772	0.498	3.16	8.9
V8s	0.811	0.514	11.17	28.8
V8n-DM(ours)	0.807	0.512	6.30	15.8
V3n	0.765	0.489	4.06	12.1
V3s	0.789	0.491	15.33	44.1
V3n-DM(ours)	0.772	0.491	6.78	20.6
V5n	0.759	0.490	2.51	7.2
V5s	0.772	0.491	9.12	24.1
V5n-DM(ours)	0.780	0.502	6.27	16.9
V6n	0.785	0.501	4.24	11.9
V6s	0.779	0.512	16.45	44.9
V6n-DM(ours)	0.790	0.514	6.91	19.5

表 4.3 不同模型在 DFOS 数据集上的性能评估

4.4.3 消融实验

为了验证各个模块对模型性能的影响,本节在多个数据集上进行了消融实验。探究了 DM 模块对模型的影响,以及这种影响是否是与类别相关;探究了 DM 模块中 MRFA 注意力块的影响。

4.4.3.1 DM 模块的影响

DM 模块的影响将从两个方向进行探索。一是将 DM 模块插入多个基线算法之前和之后的比较。另一个是以 V8n 基线算法为代表,跟踪将 DM 模块插入 V8n 基线算法之前和之后每个类的检测结果变化。
首先是在 PASCAL VOC 数据集上探究。表4.4展示了几种基线算法在 PAS-CAL VOC 数据集上插入 DM 模块前后的性能对比。

	DM	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs
Ven		0.647	0.464	3.16	8.9
V 811	1	0.687	0.498	6.30	15.8
W3n		0.636	0.445	3.88	11.2
v JII	1	0.666	0.473	6.42	18.7
¥75		0.628	0.434	2.51	7.1
V JII	1	0.684	0.494	6.27	17.0
V6n		0.639	0.464	4.24	11.9
V OII	1	0.672	0.490	6.66	19.2
Cold VOI On		0.657	0.470	6.02	10.5
	1	0.679	0.493	8.96	17.9

表 4.4 VOC 数据集上 DM 模块消融实验性能表

可以看出,所有基线模型在加入 DM 模块后都表现出了明显的提升。特别是 V5n 插入 DM 模块前后 mAP@50:95 指标的性能提升达到了惊人的 6%。哪怕与 类似大小的模型中比较效果也十分明显。插入 DM 模块后的 V5n 与 Gold-YOLOn 模型大小类似,但是 Gold-YOLOn 的 mAP@50:95 指标落后了 2.4%,再次证实 了 DM 模块对模型的性能影响是很大的。

表4.5展示了 v8n 基线算法在 PASCAL VOC 数据集上插入 DM 模块前后对 每个类别的检测结果对比。可以观察到,在 20 个类别中,几乎所有类别的检测 准确率都有所提升。VOC 数据集的类别更充分,而且标签质量也很好,里面涵 盖了各种各样的类别,数据表明插入 DM 模块的模型具有很好的鲁棒性。

Class	Images & Instances	V8n		V8n-DM	
	8	mAP@50	mAP@50:95	mAP@50	mAP@50:95
all	1155 / 3263	0.648	0.463	0.686	0.498
person	1155 / 1052	0.773	0.498	0.798	0.522
bird	1155 / 123	0.653	0.453	0.709	0.487
cat	1155 / 102	0.833	0.637	0.889	0.711
cow	1155 / 43	0.593	0.454	0.624	0.489

表 4.5 添加 DM 模块前后 VOC 数据集上各类别检测结果对比

Class	Images & Instances		V8n	V8n-DM	
		mAP@50	mAP@50:95	mAP@50	mAP@50:95
dog	1155 / 150	0.714	0.543	0.723	0.563
horse	1155 / 88	0.774	0.628	0.809	0.657
sheep	1155 / 80	0.587	0.383	0.678	0.446
aeroplane	1155 / 88	0.818	0.603	0.824	0.656
bicycle	1155 / 58	0.710	0.568	0.761	0.609
boat	1155 / 57	0.416	0.231	0.557	0.286
bus	1155 / 76	0.825	0.700	0.829	0.689
car	1155 / 294	0.688	0.491	0.698	0.499
motorbike	1155 / 85	0.866	0.621	0.856	0.638
train	1155 / 60	0.705	0.520	0.783	0.587
bottle	1155 / 159	0.359	0.215	0.416	0.252
chair	1155 / 350	0.476	0.308	0.491	0.322
diningtable	1155 / 101	0.560	0.374	0.557	0.400
pottedplant	1155 / 124	0.386	0.216	0.418	0.240
sofa	1155 / 74	0.635	0.377	0.656	0.432
tvmonitor	1155 / 99	0.597	0.444	0.638	0.466

第4章 基于跨阶段过滤网络架构的检测算法改进

续表 4.5	添加 DM 模块前后	VOC 数据集	上各类别检测结	果对比
->->->				

其次在 NEU-DET 数据集上探究。表4.6展示了在 NEU-DET 数据集上插入 DM 模块之前和之后几种基线算法的性能比较。可以看出,部分基线模型在加入 DM 模块后都表现出了的性能提升。首先是 V8n 加入 DM 模块前后的比较,在 宽松的 mAP@50 指标上,改进后提升了 2%;在严苛的 mAP@50:95 指标上,改 进后也可以获得 1.6% 的明显提升。然后就 V5n 加入 DM 模块前后的比较而言, 也获得了 1.8% 的 mAP@50 指标性能提升,以及 1.4% 的 mAP@50:95 指标性能 提升。然而其它两个模型在加入 DM 模块前后的 mAP@50 指标性能提升并不明 显,但是 mAP@50:95 指标性能提升都达到了 0.5%。

	表 4.6 NEU-DET 数据集上 DM 模块消融实验性能表							
	DM	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs			
V8n		0.743	0.400	3.012	8.2			
	1	0.763	0.416	6.069	16.0			
V3n		0.746	0.394	4.059	12.1			
	1	0.735	0.399	6.777	20.6			
V5n		0.728	0.394	2.509	7.2			
	1	0.746	0.408	6.274	16.9			
V6n		0.752	0.408	4.240	11.9			
	✓	0.757	0.413	6.910	19.5			

表4.7展示了 v8n 基线算法在加入 DM 模块前后各类别的检测结果对比。可 以看出,在6个类别中,所有类别的 mAP@50 精度都有所提升,只有一个类别 的 mAP@50:95 精度没有提升,其余五个类别的 mAP@50:95 精度都获得了提升。 可以看到,没有提升 mAP@50:95 精度的这个类别的实例数量是最少的,对比其 它实例类别多的类别可以发现实例数量越多越有助于 DM 模块发挥效果。

Class	Images & Instances		V8n		V8n-DM	
	C	mAP@50	mAP@50:95	mAP@50	mAP@50:95	
all	360/835	0.743	0.400	0.763	0.416	
crazing	360/133	0.349	0.124	0.414	0.145	
inclusion	360/178	0.902	0.583	0.925	0.611	
patches	360/184	0.823	0.413	0.827	0.421	
pitted-surface	360/75	0.85	0.507	0.856	0.499	
rolled-in-scale	360/154	0.649	0.288	0.657	0.318	
scratches	360/111	0.885	0.487	0.898	0.499	

表 4.7 添加 DM 模块前后 NEU-DET 数据集上各类别检测结果对比

4.4.3.2 MRFA 模块的影响

为了验证 DM 中的 MRFA 模块的影响,本节对多个模型进行了消融实验。先后从原始 DM 模块中删除 MRFA 注意力组件,并在相同的实验条件下对模型进行相同轮次的训练。

首先在 PASCAL VOC 数据集上探究。如表4.8所示,在 PASCAL VOC 数据集

上,可以观察到移除 MRFA 注意力会导致 DM 模块性能指标的下降。MRFA 在增加有限参数的情况下实现了显著的性能提升。从最终结果来看,未加入 MRFA 的 V8n-DM 在两个关键指标上均有所下降,mAP@50 下降了 0.87%,而 mAP@50:95 下降了 0.625%。在目标检测领域,这些下降都是明显的性能下降。

	MRFA	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs
Ven DM	1	0.688	0.498	6.30	15.8
v 8n-DM		0.679	0.492	6.00	15.0
V3n_DM	1	0.666	0.473	6.42	18.7
V 3II-DIVI		0.663	0.472	6.42	18.5
V5n_DM	1	0.684	0.494	6.28	17.0
V 5n-DM		0.679	0.497	6.27	16.7
V6n-DM	\checkmark	0.672	0.490	6.66	19.2
		0.667	0.485	6.66	18.9

表 4.8 在 VOC 数据集上使用和不使用 MRFA 的性能比较

此外,如表4.9所示,在 PASCAL VOC 数据集上,可以观察到移除 MRFA 注意力机制后,V8n-DM 模型中很多类别的检测结果都变差。就总体所有类别 而言,MRFA 能带来大约 1% 的 mAP@50 指标提升,以及 0.5% 的 mAP@50:95 指标提升。尽管不是在每个类别上都能看到 MRFA 带来的明显的效果,但是在 20 个类别中仍然有 13 个类别的 mAP@50 指标获得提升,并且有 11 个类别的 mAP@50:95 指标得到提升。

Class	Images & Instances	V8n-DM	(NOMRFA)	V8n-DM	
		mAP@50	mAP@50:95	mAP@50	mAP@50:95
all	1155 / 3263	0.679	0.493	0.686	0.498
person	1155 / 1052	0.804	0.524	0.798	0.522
bird	1155 / 123	0.691	0.483	0.709	0.487
cat	1155 / 102	0.869	0.700	0.889	0.711
cow	1155 / 43	0.644	0.496	0.624	0.489
dog	1155 / 150	0.720	0.550	0.723	0.563
horse	1155 / 88	0.765	0.622	0.809	0.657
sheep	1155 / 80	0.666	0.425	0.678	0.446

表 4.9 VOC 数据集上使用和不使用 MRFA 不同类别的检测结果比较

Class	Images & Instances	V8n-DM	(NOMRFA)	V8n-DM	
		mAP@50	mAP@50:95	mAP@50	mAP@50:95
aeroplane	1155 / 88	0.821	0.635	0.824	0.656
bicycle	1155 / 58	0.752	0.618	0.761	0.609
boat	1155 / 57	0.552	0.299	0.557	0.286
bus	1155 / 76	0.825	0.703	0.829	0.689
car	1155 / 294	0.714	0.506	0.698	0.499
motorbike	1155 / 85	0.849	0.634	0.856	0.638
train	1155 / 60	0.762	0.552	0.783	0.587
bottle	1155 / 159	0.418	0.247	0.416	0.252
chair	1155 / 350	0.510	0.334	0.491	0.322
diningtable	1155 / 101	0.593	0.407	0.557	0.400
pottedplant	1155 / 124	0.362	0.221	0.418	0.240
sofa	1155 / 74	0.668	0.443	0.656	0.432
tvmonitor	1155 / 99	0.604	0.453	0.638	0.466

续表 4.9 VOC 数据集上使用和不使用 MRFA 不同类别的检测结果比较

VOC 数据集上跟踪训练过程,可以发现 MRFA 的存在有效提升了模型的收敛速度。如图4.6所示,可以观察训练过程的收敛情况。





图中展示的实验以 V8n-DM 和 V8n-DM (NOMRFA)两种模型为代表,监测模型的收敛情况。实线在 100 个 epoch 后掩盖了虚线,证实了 MRFA 注意力可以在训练过程中加速模型收敛。

其次在 NEU-DET 数据集上探究。为了验证所提出的 MRFA 注意力对 DM 模块的影响与数据集无关,同样在 NEU-DET 数据集上进行消融实验。如表4.10 所示,可以观察到移除 MRFA 注意力会导致 DM 模块性能指标下降。除了 V3n-DM 的 mAP@50 指标在加入 MRFA 注意力后没有提升之外,其它模型的 mAP@50 指标均获得了提升;在更严苛的 mAP@50:95 指标上所有 4 个模型的性能都获得提升。

	MRFA	mAP@50	mAP@50:95	Parameters/M	Cost/GFLOPs
V8n DM	1	0.763	0.416	6.07	16.0
v oli-Divi		0.751	0.395	6.06	15.8
V3n DM	1	0.735	0.399	6.78	20.6
v 3n-Divi		0.755	0.375	6.77	20.3
V5n-DM	1	0.746	0.408	6.27	16.9
v 5n-Divi		0.735	0.407	6.27	16.7
V6n DM	1	0.757	0.413	6.91	19.5
v on-Divi		0.756	0.413	6.91	19.2

表 4.10 在 NEU-DET 数据集上使用和不使用 MRFA 的性能比较

表4.11 展示了移除 MRFA 注意力前后 V8n-DM 模型中每个类的检测结果比较。从最终结果来看,未加入 MRFA 的 V8n-DM 在两个关键指标上均有所下降, mAP@50 下降了 1.2%,而 mAP@50:95 下降了 2.1%。

表 4.11 NEU-DET 数据集上使用和不使用 MRFA 不同类别的检测结果比较

Class	Images & Instances	V8n-DM(NOMRFA)		V8n-DM	
	ges et 1	mAP@50	mAP@50:95	mAP@50	mAP@50:95
all	360/835	0.751	0.395	0.763	0.416
crazing	360/133	0.420	0.150	0.414	0.145
inclusion	360/178	0.907	0.594	0.925	0.611
patches	360/184	0.839	0.431	0.827	0.421
pitted-surface	360/75	0.847	0.512	0.856	0.499
rolled-inscale	360/154	0.638	0.317	0.657	0.318
scratches	360/111	0.854	0.363	0.898	0.499

跟踪训练过程,可以发现 MRFA 的存在有效地降低了训练后期的收敛波动。 如图4.7所示,在 NEU-DET 数据集上,该图展示了在插入完整 DM 模块或不加 入 MRFA 注意力的 DM 模块后,基线模型的训练周期数与关键指标之间的关系。 经过 150 个周期后,可以观察到 MRFA 注意力有助于降低准确率的波动。实线 在后期覆盖虚线表明 MRFA 注意力有助于训练过程中模型的收敛。



图 4.7 NEU-DET 数据集上跟踪训练过程

4.5 本章小结

本章围绕基于跨阶段过滤网络架构的检测算法改进这一核心内容展开介绍。 考虑到分布式光纤传感数据量大,因而降低传感数据的分辨率势必是一个缓解 压力的方法,这就需要检测模型能有更高的检测精度。本章围绕架构调整优化 提出了改进检测算法的方案,具体来说,设计了基于特征过滤视角的 DM 模块, 给出了 DM 模块插入基线模型的方案、DM 模块具体结构和算法。实验表明,在 计算开销增加较少的情况下,该方法可以将原检测器的 mAP@50:95 精度提升约 2%~5%,mAP@50 精度提升约 3%~6%。

第5章 基于分布式光纤传感的风电地埋电缆安全监测系统

前两章进行了轻量化与高精度两类算法的设计以及实验验证。本章将以搭 建一个基于分布式光纤传感的风电地埋电缆安全监测系统为核心目标,将两种 算法用于实际的系统中,通过采用级联检测策略缓解系统的运行压力。具体将按 照系统需求分析、系统概要设计、系统详细设计与实现、系统测试这个结构展开 说明。

5.1 引言

在实际风电地埋电缆安全监测任务中,为了平衡检测精度与系统效率,级联 检测成为一种重要的检测策略。其核心思想是利用多个检测器分级筛查,将任务 划分为不同粒度的检测阶段,以适应分辨率、数据量及计算资源的限制。

检测器的检测效果依赖于训练样本的规模和准确性。在实际工程中,以最高的时间分辨率进行地面活动样本的原始数据采集。原始样本按照两种不同的时间分辨率进行人工打标签处理,最终高分辨率样本数量大约是低分辨率样本的10倍。这种数据处理方式既能保证高精度检测器有足够的训练样本,又能为后续的精细检测提供丰富的特征信息。

该系统中的第一个高精度检测器主要用于快速筛选,其模型在小规模数据 集上训练,输入数据分辨率较低,数据量相对有限,检测难度较大但是数据流量 较小。为了提高检测器的泛化能力,系统设计中引入了模型预训练和参数冻结等 技术,以在有限训练样本的情况下实现初步筛选的目标。由于第一个检测器的 时间分辨率较低,系统可以有更长的时间窗口处理数据,并将非异常样本提前剔 除,从而减少后续检测器的计算负担。这个环节将采用第四章提出的高精度算法 作为第一级的检测器。

在初步筛选之后,第二个轻量化检测器则针对细粒度的超清原始数据进行 精细检测。该检测器输入分辨率更高、细节更丰富的图像,检测难度较小但是数 据流量大。通过一级检测器提供的信息,可以寻找对应的更高时间分辨率的待检 测图片,这些图片含有更为详细的特征。二级检测器便能在更微观的视角有效识 别细粒度的异常情况。在极端情况下,二级检测的数据量将是一级检测的10倍, 因此这个环节将采用第三章提出的轻量化算法作为第二级的检测器。

本章的研究内容可总结为:基于级联检测的思想,完成基于分布式光纤传感 的风电地埋电缆安全监测系统搭建。

本章的结构安排如下:第 5.2 节给出了具体的系统需求分析,其中包括功能 需求和非功能需求两部分;第 5.3 节是系统概要设计,在该节给出了系统的整体 架构、各个模块的结构,最后给出了整个监测系统的详细流程;第 5.4 节是系统详细设计与实现,在该部分还给出了检测模型的训练细节;第 5.5 节进行整个系统的功能需求和非功能需求测试。

5.2 系统需求分析

本节通过对基于分布式光纤传感的风电地埋电缆安全监测系统任务的深入 分析,明确系统设计的目标,进一步明确系统的各项需求,以确保系统能在满足 检测精度的基础上,优化资源的使用并实现高效运行。

整个项目基于 Flask 框架开发一个 Web 监测系统 APP, 主要用于数据采集、 处理、可视化及实时监测。系统通过 PCIE6920 分布式光纤传感采集卡进行数据 获取,结合相关的信号处理算法实现数据分析,并通过 WebSocket 实现实时数据 传输。以下是系统的主要需求分析。

5.2.1 功能需求

功能需求将从数据采集与传输功能、信号处理与分析功能、数据存储与日志记录功能、数据可视化与实时监测功能四个方面展开。

5.2.1.1 数据采集与传输功能

分布式光纤传感系统采集数据需要一条无环的光纤链路通道。风电站输电 电缆与通信光纤埋在相同的电缆沟中,这使得通讯光纤可以天然的作为传感器 对可能威胁电缆到电缆安全的地面活动进行监测和预警。如图5.1和5.2分别展示 了实际生产环境中风机的地理位置和光纤拓扑图。



图 5.1 风机的地理位置

可以看到在实际的风机电缆布设中,并不存在直接的一条通路把所有风机 都串联在一起。这就要求设计的监测系统需要考虑如何才能兼顾不同支路上的 监测数据采集。



图 5.2 风电站光纤拓扑图

更具体而言,数据采集与传输功能要求系统可以通过 PCIE6920 采集卡获取 高频振动信号,同时要求支持多通道数据输入。此外,受实际风电场风机之间的 通讯光纤布设线路限制,需要在结点布设光开关切换器,用于扫描不同的光纤链 路。串口通信采用 PySerial,用于控制外部设备。最后,要求采用 Flask-SocketIO 实现 WebSocket 实时数据推送,提高数据传输效率。

5.2.1.2 信号处理与分析功能

传感器采集到最原始的数据以后先要进行一系列的数据处理、最后进行相关检测。首先是初步的去噪处理,要求采用 IIR 滤波器(带通 20Hz-800Hz)对信号进行去噪,以提升原始信号质量。其次是对信号进行平滑处理,通过计算平均振幅,去除短时突变信号。然后考虑到需要能够快速判断光纤链路是否完整,要求有快速链路检测,使得可以基于阈值判断和连续低值检测识别信号异常情况。最后是更为深度的异常检测,要求系统能基于检测算法在线识别和定位电缆周围活动。由于分布式光纤传感数据量很大,要求在实现检测分析时要考虑处理速度和缓存大小。信号处理与分析功能的用例图如图5.3所示。



图 5.3 信号处理与分析功能用例图

5.2.1.3 数据存储与日志记录功能

要求最终的系统在服务器端提供 API,以支持日志文件存储;监测数据可自动保存到本地日志文件,并支持未来数据库扩展;记录异常情况,如信号丢失、 传感器故障等,方便后续分析与维护。

5.2.1.4 数据可视化与实时监测功能

数据可视化与实时监测功能的用例图如图5.4所示。



图 5.4 数据可视化与实时监测功能用例图

该功能要求监测系统可以采用 JavaScript + WebSocket 在前端绘制实时信号

第5章 基于分布式光纤传感的风电地埋电缆安全监测系统

曲线,支持动态刷新;能提供历史数据回溯功能,支持用户手动调整时间窗口进行信号回放;系统具有异常报警机制,当信号超过阈值时,自动弹出警告提示。

5.2.2 非功能需求

为了保证系统的稳定性、实时性和可扩展性,监测系统需满足以下非功能需求:

5.2.2.1 性能需求

首先在数据采集速率方面,系统需具备高效的数据采集能力,能够持续以2000Hz的频率采集数据。这要求系统在硬件和软件方面都经过优化,以确保在高负载下仍能保持信号的完整性,避免任何数据丢失和丢帧现象。此外,系统应具备数据缓冲机制,以应对突发的流量高峰。

其次在服务器响应时间方面,为了保障用户体验,系统的服务器响应时间需 控制在 200ms 以内。这不仅包括从用户请求到数据处理的时间,还需考虑后端 数据库查询和数据传输的延迟。同时,WebSocket 传输时延应严格控制在 50ms 以内,以确保实时数据交互,满足应用场景对低延迟的要求。

最后是多线程并行处理方面,系统应支持多线程处理技术,以最大化利用服 务器的计算资源。通过并行处理数据,系统可以显著提升数据处理效率,从而确 保在高并发情况下仍能快速响应用户请求和实时数据更新。

5.2.2.2 可靠性需求

首先是在系统稳定性方面,在长时间运行时,系统必须保持高稳定性,避免 因采集卡故障或其他意外因素导致的数据丢失。应建立监控机制,实时检测系统 状态,及时发现并处理潜在问题,确保数据的连续性和完整性。

其次是需要有异常退出保护机制,系统需具备自动保护机制,在发生断电或 异常关闭时,能够确保采集卡安全关闭,避免数据损坏或丢失。该机制应包括自 动保存当前状态和数据的功能,以便下次启动时能够正常恢复。

最后是要有自适应的链路检测算法,设计一种智能的链路检测算法,该算法 能够根据实时数据流的波动情况自动调整检测阈值,从而降低误判率,提高系统 的可靠性。通过分析历史数据,算法能够动态学习和优化,以适应不同的环境和 应用场景。

5.2.2.3 可用性需求

首先是简单直观的前端设计,系统前端界面应设计得简单直观,确保非专业 人员能快速上手操作。通过清晰的布局和易于理解的控件,用户可以轻松完成数 其次是可视化界面,提供动态可视化界面,支持实时数据展示和异常数据标 注。用户可通过图表、仪表盘等形式直观地理解数据趋势和变化,并能够对异常 情况进行快速标注和处理,提升用户的操作效率。

最后是要有监测日志导出功能,系统需提供监测日志的导出功能,支持 CSV 格式导出,便于后续的人工二次分析。用户可以根据需求自定义导出的数据内 容,提升数据分析的灵活性和便捷性。

5.2.2.4 扩展性需求

首先是增加传感器通道支持,系统应设计为可扩展架构,未来能够方便地增加更多的传感器通道,支持多种数据源的融合分析。通过模块化设计,用户可以 根据实际需要添加新传感器,增强系统功能。

其次是数据库存储支持,系统应支持多种数据库存储解决方案,如 MySQL 或 MongoDB,以提升数据管理能力。通过合理的数据模型设计,确保数据的高 效存取和管理,同时支持大规模数据的处理和分析。

最后要求模块化设计,便于后续的二次开发与功能升级。每个模块应具备清晰的接口设计,使得开发人员能够快速理解和修改代码,支持新功能的快速集成。同时,模块化设计也有助于系统的维护和扩展,降低后续开发的复杂性。

5.3 系统概要设计

这部分主要介绍监测系统的整体架构,包括系统架构设计、模块功能划分 以及数据处理的流程设计。系统采用 Flask 框架进行 Web 后端开发,并结合 PCIE6920数据采集卡获取振动信号。通过 SocketIO 实现数据的实时传输,并采 用信号处理算法对数据进行预处理、分析和异常检测。该系统可广泛应用于风电 地埋电缆安全监测等场景,实现对目标区域的高效监测和数据可视化。

5.3.1 系统架构

本系统的架构采用前后端分离的模式,主要包含四个核心部分:数据采集模块、级联检测模块、数据传输模块和前端可视化模块。系统架构如图5.5所示。

基于该架构的整个系统的工作流程如下:首先启用数据采集模块,通过 PCIE6920数据采集卡进行信号采集,使用 Python 的 ctypes 库调用传感设备动 态链接库(DLL)完成数据读取,并通过 PySerial 控制外部设备。

67



第5章 基于分布式光纤传感的风电地埋电缆安全监测系统

图 5.5 监测系统架构图

接着通过级联检测模块,该模块首先会采用 IIR 滤波器进行带通滤波(20Hz-800Hz),计算信号的短时均值变化趋势,并对异常情况进行初步分析;其次经 过去噪、滤波、平滑之后的信号数据会被推送到一级检测器进行检测;最后如果 一级检测器异常,则会启动二级检测器。

然后是数据传输模块,后端使用 Flask-SocketIO 推送数据至前端,并支持日志存储。最后是前端可视化模块,前端基于 JavaScript,通过 WebSocket 实时接收数据,并绘制信号曲线,提供异常报警功能。

5.3.2 模块分解

本系统主要由数据采集模块、级联检测模块、数据传输模块和前端可视化模 块四大核心模块组成,各模块的详细功能如下:

数据采集模块。该模块通过 PCIE6920 数据采集卡获取振动信号,并支 持多个通道的数据采集;使用 DLL 接口与硬件通信,调用 pcie6920_open()、 pcie6920_set_scan_rate()等 API 完成设备初始化和参数配置;通过 PySerial 控 制传感器切换,支持多种传感器的监测模式。

级联检测模块。它先采用 IIR 滤波器进行信号去噪,保证信号的清晰度;通 过计算短时均值变化趋势,分析信号的稳定性,并结合滑动窗口技术提升异常检 测的准确率;通过级联检测方法进行目标检测,一级检测器主要负责筛选异常信 号,二级检测器负责精细识别,以提高检测效率。对于深度检测,采用先进行高 精度检测器初筛,然后进行轻量化检测器复检的模式,有效缓解了监测系统的缓 存压力,降低了计算资源消耗。

数据传输模块。服务器端提供 WebSocket 接口,使用 Flask-SocketIO 进行数据推送,实现低延迟数据传输。提供 REST API,支持日志存储功能,异常数据可保存至服务器。

前端可视化模块。通过 JavaScript WebSocket 接口接收后端推送的数据,实时更新信号曲线;提供异常报警功能,当信号超过设定阈值时,触发报警通知用户;允许用户调整时间窗口,回放历史数据并进行数据分析。

5.3.3 监测流程

为了保证系统的高效运行,整个监测系统按照以下流程工作,详细流程如 图5.6所示。整个流程可分为以下几个阶段:



图 5.6 监测过程流程图

系统初始化: Flask 服务器启动,加载 PCIE6920 驱动并初始化采集卡。设定

信号采样率、滤波器参数等系统关键参数。WebSocket 监听前端请求,等待数据 传输。

数据采集:采集卡开始采样,读取通道数据,并存入缓存区。通过串口发送 指令控制不同传感器的工作状态。采集数据后,进行基本格式化处理。

信号预处理:采用 IIR 滤波器进行信号去噪,滤除无效频率范围的干扰信号。 计算平均振幅,去除短时突变信号,提高数据稳定性。

异常检测:采用级联检测方法,首先筛选出可能的异常信号,然后进行细粒 度分析,提高检测精度。通过滑动窗口计算信号的短时均值变化趋势,判断是否 发生异常。记录异常数据,并存入日志文件。

数据传输:通过 WebSocket 推送处理后的数据至前端,实现实时信号监测。 REST API 提供数据存储功能,支持日志下载和分析。

前端可视化:前端接收 WebSocket 数据,并绘制实时信号曲线。用户可回放 历史数据,查看不同时间段的信号情况。当信号超过预设阈值时,前端触发报警 提示,提醒用户关注异常信号。

5.4 系统详细设计与实现

在上一节,本文完成了系统概要设计,包括系统总体架构、功能模块的划分 和整个监测系统的监测流程。本节将给出对应的模块设计与具体实现。

5.4.1 数据采集模块

数据采集模块是风电地埋电缆安全监测系统的基础,它负责高频振动信号 的采集,并确保数据输入的可靠性。该模块的核心功能依赖于 PCIE6920 分布式 光纤传感采集卡,用于多通道信号获取,同时结合光纤开关切换器,通过 PySerial 串口通信控制通道切换,从而实现多段光缆的监测。数据采集卡默认 2000Hz 采 样率,支持多通道输入,每次切换通道后都会重新初始化串口通信,确保信号稳 定传输。此外,系统内置 Flask WebSocket 服务器,实现实时数据流推送,使前 端能够即时获取采集到的数据。

在数据采集流程方面,系统首先会初始化 PCIE6920 采集卡,设定采样率与通道数,并建立串口通信来控制光纤切换。随后,通过串口指令选择监测通道,读取采集卡中的信号数据,并存入缓存区。采集到的原始信号会经过 IIR 滤 波器(20Hz-800Hz 带通)进行降噪,处理后的数据会通过 Flask-SocketIO 进行 WebSocket 传输,使监测中心能够实时接收并分析数据。

该数据采集模块采用多通道切换策略,以便可以适应实际的风电地埋电缆 拓扑结构。整体来看,该模块能够满足风电地埋电缆监测的实时性、高效性和稳

70

定性,为后续的级联检测提供高质量的输入数据。

5.4.2 级联检测模块

级联检测模块在风电地埋电缆安全监测系统中承担着核心的异常识别任务, 主要包括快速链路检测和深度级联检测两个部分。这种深度级联检测方法如 图5.7所示。快速链路检测用于初步筛选异常信号,以提高响应速度,而深度级 联检测则基于目标检测方法,实现对电缆周围活动的精准识别,从而提高系统的 检测精度和鲁棒性。



图 5.7 深度级联检测流程图

在快速链路检测部分,系统通过计算短时均值变化趋势来分析信号的稳定 性,从而实现初步筛选。当信号出现长期剧烈波动,且信号强度超过设定阈值 时,系统会触发告警机制,用于快速识别可能的入侵或破坏行为。若检测到信号 出现突发性中断,系统也会判断可能存在的光纤已经被挖断的情况,并及时发出 预警。这种方法具有低计算量、高响应速度的优势,适用于实时监测需求。

在深度级联检测部分,系统采用目标检测模型,对电缆附近的地面活动进行

智能识别。在不同的时间分辨率下进行分步推理,以兼顾检测精度与计算效率。

该方法的核心思想是:首先,在较低时间分辨率下进行初步检测,若未发现 异常,则直接丢弃当前数据帧,从而减少计算开销;若检测到疑似异常,则定位 到高时空分辨率数据,采用更高时间分辨率的模型进行二次检测,以确保异常信 号的准确识别。这样一来,系统既能在大尺度时间窗口下捕捉整体趋势,又能在 微观尺度上进行精细分析,保证不同类型威胁行为的有效识别,同时减少不必要 的计算负担。

此外,在深度级联检测模型的训练过程中,采用了标签复用策略,即在不同 时间分辨率下使用相同的标注数据。这种方法保证了高低分辨率数据的标签一 致性,使得监督信息可以在不同检测级别间共享,进而提高模型训练的兼容性。 这一策略的优点包括:第一,减少数据标注的重复工作,只需对高分辨率数据进 行一次标注;第二,提高模型的跨分辨率泛化能力,确保检测的连续性和稳定性; 第三,增强两级检测模型之间的协同作用,避免第一级检测出的异常在第二级检 测中消失的问题。

为了进一步优化模型的学习能力,系统引入了参数冻结和领域自适应预训 练技术。由于风电地埋电缆监测的实际数据较难大量获取,因此采用了迁移学习 的方式,先在大规模公共数据集(如 VOC)上进行预训练,再针对光纤传感数 据进行特定优化。在微调过程中,部分神经网络参数会被冻结,以保留预训练模 型的特征提取能力,同时减少模型遗忘,提高检测精度。

综合来看,该级联检测模块通过快速检测与深度检测的结合,实现了对风电 地埋电缆的高效监测。快速检测确保系统对异常信号的即时响应,而深度级联检 测则利用多层次时间分辨率分析,提高了系统的精确性和适应性。通过标签复 用、参数冻结和预训练等优化策略,模块在保证计算效率的同时,也具备了良好 的泛化能力,为风电电缆的安全监测提供了可靠的智能检测方案。

5.4.3 数据传输模块

数据传输模块采用 Flask-SocketIO 实现低延迟实时通信,同时结合 REST API 对采集数据及告警日志进行存储。模块设计将实时监控数据与历史归档数据分 离,实时数据经缓冲后通过 WebSocket 迅速推送至前端,实现毫秒级响应;异常 信息则通过 HTTP 接口写入服务器,便于后续分析。为提高传输稳定性,模块引 入多线程并行处理和心跳检测机制,确保网络断连后自动重连并重发数据。同 时,采用数据分包与校验策略,有效防止网络拥堵和数据丢失。模块还实现分层 传输结构,底层负责数据打包与校验,中间层处理异步传输,上层为前端提供接 口,确保各层高效协同工作,为整个监测系统提供稳健、可靠的数据通信保障。

72

5.4.4 前端可视化模块

前端可视化模块采用 HTML + JavaScript,结合 Flask-SocketIO 实现低延迟实 时监测,主要包括实时数据可视化、历史数据查询和异常报警三大功能。前端通 过 WebSocket 监听后端数据刷新事件,动态更新绘制的信号曲线,并支持多通道 数据展示。用户可手动选择时间窗口,调用 Flask REST API 查询历史数据,实现 信号回放。系统内置异常报警逻辑,当信号超过设定阈值时,自动触发警报弹窗 并高亮异常点。为优化性能,采用 Debounce 防抖机制减少不必要的渲染,并结 合 Bootstrap + CSS 设计简洁直观的 UI,支持移动端适配。该模块提供流畅、高 效的监测体验,确保风电地埋电缆状态的可视化与实时预警。

5.5 系统测试及结果分析



如图5.8展示了系统初步的整体界面。完成基本功能以后对系统进行测试。

图 5.8 系统的整体界面

系统的测试主要通过以下的步骤开展功能测试和非功能测试。首先,确保数 据采集模块、级联检测模块、数据传输模块和前端可视化模块能够协同工作,实 现完整的数据处理流程。其次,验证 WebSocket 实现的实时数据推送功能是否稳 定,是否存在数据延迟或丢失的情况。再次,确保 IIR 滤波、短时均值计算和异 常检测功能符合系统需求,能够有效减少噪声干扰,提高监测的准确性。然后, 检测日志存储功能是否正常,日志数据能否正确存储并供后续分析。最后,验证 系统在不同硬件环境和不同负载条件下的性能表现,确保其在高并发情况下仍 能稳定运行。

5.5.1 功能测试

表5.1展示了功能测试结果。

功能需求	需求1	需求 2	需求 3	需求 4
数据采集与传输	支线 1 数据采 集	支线 2 数据采 集	支线 3 数据采 集	数据推送
测试结果	\checkmark	\checkmark		
信号处理与分析	滤波	平滑	快速链路检测	深度异常检测
测试结果		\checkmark		
数据存储	原始信号存储	告警日志存储	异常片段存储	
测试结果			×	
数据可视化	实时信号曲线	地图显示	自动弹出警告	告警解除按钮
测试结果		\checkmark		

表 5.1 功能测试结果

在数据采集与传输功能模块,主要是利用光开关切换光纤链路实现三条支 路轮询监测,这样就使得可以仅用一台采集卡就实现三条链路的监测。分时复用 的代价是对每条支路的检测是有一定的时间间隔的。在信号处理与分析功能方 面,完全实现了对原始数据的滤波和平滑,并且设计了快速链路检测算法,以及 采用神经网络识别地面活动的功能。在数据存储方面,提供了两类数据接口,包 括采集卡采集到的原始信号和告警日志。未来还需要做的是将异常数据流片段 截取下来,同时将深度异常检测中检测到的异常时空图切片存储下来。数据可视 化方面,实现了实时监测信号曲线展示、地图显示、告警按钮等基本的功能键。

5.5.2 非功能测试

本节给出部分非功能测试的简要测试过程与具体测试数据。对于采样率测试:通过后端控制台打印语句记录实际采样频率;在随机的1000次抽样下,采样频率在1984Hz至2017Hz之间波动,均值为1999.95Hz,整体波动范围小于±1%的误差范围。连续运行测试:系统在24小时不间断运行情况下,记录CPU、内存、磁盘占用情况,统计平均CPU占用率为13.6%,内存占用稳定在2.94GB,无崩溃或内存泄漏。异常关闭保护测试:通过人为断电实验,系统在重启后能自动恢复,并成功记录断电前最后一条日志数据。前端可视化测试:在不同分辨率(1920×1080,1280×720)下测试界面显示情况,确保布局自适应;90%的测试者反馈认为界面直观,操作简单。

对响应性能测试:通过 Apache JMeter 模拟前端请求,测量服务器响应时间; 如表5.2所示,第三组数据表明在吞吐量在每秒 200 个请求内时最大延迟远小于

 $200 ms\,{}_{\circ}$

组别	总样本	Ramp-Up	95% 百分位	最小值	最大值	吞吐量	异常率
组1	10000	10s	2292ms	2ms	2686ms	474.8req/sec	14.79%
组 2	10000	25s	2188ms	2ms	2549ms	292.7req/sec	11.01%
组 3	10000	50s	35ms	0ms	95ms	200.1req/sec	0%

表 5.2 响应性能测试数据

表5.3展示了总体的非功能需求测试结果。在性能需求方面,支持最高采样率 2KHz,服务器端响应时间小于 200ms,并且启用多线程并行的方式进行异常检测,快速检测和深度异常检测在不同线程中进行。在可靠性需求方面,系统的连续运行时长大于 24h,具备异常退出保护机制,确保断电、异常关闭时,采集卡自动关闭;链路检测算法需具有自适应性,可自动调整检测阈值,降低误判率。可用性需求方面,系统前端设计简单直观,非专业人员可快速上手操作;提供交互界面,可动态展示数据、导出监测日志。在扩展性需求方面,整个系统支持传感器通道拓展、后期支持联合摄像头的数据源融合分析。

非功能需求	需求1	需求 2	需求 3
性能需求	采样率 2KHz	响应时间 < 200ms	多线程并行处理数据
测试结果	\checkmark	\checkmark	\checkmark
可靠性需求	连续运行时长 > 24h	采集卡异常关闭保护	链路检测算法具备自 适应性
测试结果	\checkmark	\checkmark	\checkmark
可用性需求	前端设计简单直观	可视化界面动态展示 数据	监测日志可导出 CSV 格式,支持人工二次 分析
测试结果	\checkmark	\checkmark	\checkmark
扩展性需求	传感器通道可拓展	支持多数据源融合分 析	模块化设计
测试结果	\checkmark	×	

表 5.3 非功能测试结果

5.6 本章小结

本章搭建了基于分布式光纤传感的风电地埋电缆安全监测系统,并且进行 了一些相关的测试。利用前面章节提供的模型完成了先进行高精度检测器初筛, 然后进行轻量化检测器精细复检的级联检测系统搭建。具体来说先是按照基本

第5章 基于分布式光纤传感的风电地埋电缆安全监测系统

的监测背景进行了系统需求分析,接着基于级联检测策略做了系统的概要设计, 之后给出系统的详细设计,重点介绍了级联检测模块的详细设计,最后在功能基 本实现以后进行了系统测试。结果表明该系统具有一定的工程应用价值。

第6章 总结和展望

6.1 论文工作总结

本文面向风电地埋电缆安全监测应用场景,基于分布式光纤传感技术的海 量监测数据特性,围绕智能检测算法的轻量化改进、高精度改进、基于级联检测 策略的检测系统设计展开了研究,并将其应用于实际的电缆安全监测任务。总体 而言,论文的主要工作可概括为三个方面:

(1)针对快速检测阶段对模型轻量化的要求,提出了一种结合变体卷积和注意力机制的轻量化目标检测算法改进方法。首先通过结合轻量化变体卷积,极大地降低了模型的参数量;然后设计了 MRFA 注意力模块,提升了网络的特征表达能力。实验结果表明,变体卷积与 MRFA 注意力可以用较小的检测精度下降代价换来明显的模型轻量化效果,为后续的系统部署节约了计算资源并增强了 鲁棒性。

(2)针对精细检测阶段对模型准确性的要求,提出了一种基于跨阶段过滤网络架构的高精度目标检测算法改进方法。该方法采用本文所提出的 DM 模块,通过对深浅层特征进行分流、仅保留最有区分度的特征映射来传递到更深网络,既减少了冗余计算,又增强了语义层次的融合,从而在多个数据集上有效平衡了模型复杂度与检测性能。该方法以较小的参数量代价获得了显著的检测精度提升。

(3) 开发了基于分布式光纤传感的风电地埋电缆安全监测系统,系统实现了 数据实时采集、分析处理、可视化展示和异常报警等功能。系统集成经过轻量化 改进与高精度改进后的两种检测算法,采用先进行高精度检测器初筛,然后进行 轻量化检测器精细复检的模式。一级检测模型利用低分辨率数据进行大批量快 速筛查;二级检测模型则在更精细的时空数据上进行深度识别。该两级检测模式 在现场测试中获得了较好的运行效率与精度平衡,为实地部署分布式光纤传感 监测系统提供了可行的方案。

6.2 问题与展望

虽然本文工作在分布式光纤传感监测与目标检测模型结合方面取得了初步 成效,但仍有若干方面有待深入研究和完善,主要体现在以下几个方面:

(1)数据多样性与标注规模尚显不足。分布式光纤传感所采集到的原始信号 形式多样,可能因环境噪声、温度变化、传感线路铺设方式等因素而出现模式差 异。当前在标注数据稀缺的情况下,采用领域自适应预训练能部分缓解模型训练 困难,但依然需要更多高质量、细粒度的标注样本来进一步增强模型的鲁棒性与 准确性。未来可以尝试通过主动学习或无监督或者弱监督方式,利用大量未标注数据补充训练样本,提升检测效果。

(2)多模态信息融合与表征欠缺。本文对分布式光纤传感信号主要进行了 "时空信号一图像映射"的单一模态处理,对温度场、环境声学、现场视频等可 能有助于威胁行为识别的多模态信息尚未充分挖掘。后续可以探索与光纤光栅 传感、声发射检测以及监控视频等数据的融合,通过多模态特征联合学习与互 补,提高对不同种类威胁行为的感知与识别精度。

(3)更大规模在线实时检测仍然面临很多挑战。为了应对大规模在线数据流,需进一步研究实时推理和轻量化部署,如利用模型剪枝、量化与分布式计算框架,来满足高吞吐量、低延迟的实际监测需求。

(4)缺乏基于先验知识与规则推理的综合决策。现有系统主要依赖基于数据驱动的深度学习模型对威胁进行检测与定位,还缺乏对既有地理信息、施工风险域等先验知识的整合与推理,以进一步过滤误报或对突发异常进行快速处置。后续可以结合知识图谱等技术,将管线走向、施工计划、历史故障场景等信息纳入推理引擎,在检测模型输出结果的基础上进行高层次的业务逻辑分析与决策,提升整体系统在复杂真实场景下的准确性与稳定性。

总而言之,针对风电地埋电缆安全监测的分布式光纤传感与智能检测结合 仍有广阔的研究空间。随着传感技术、数据采集与算法手段的持续演进,通过进 一步引入可解释性、知识推理、多模态融合与实时分布式架构优化,未来有望实 现更加全面、精准和智能化的地埋电缆安全监测与故障预警,在风电及其他长线 式关键基础设施的运行维护中展现出更大的应用潜力与研究价值。

参考文献

- [1] 人民网. 习近平: 实现"双碳"目标, 不是别人让我们做, 而是我们自己必须要做[EB/OL].
 (2022-05-23)[2025-03-26]. http://politics.people.com.cn/n1/2022/0523/c1001-32428031.htm
 l.
- [2] 国家能源局. 我国风电光伏发电装机规模超过煤电[EB/OL]. (2024-08-02)[2025-03-26]. https://www.nea.gov.cn/2024-08/02/c 1310783697.htm.
- [3] 国际风力发电网. 风电已成为我国第二大电源[EB/OL]. (2024-07-08)[2025-03-26]. https://wind.in-en.com/html/wind-2451903.shtml.
- [4] 马喆,张明江,江俊峰,等.基于线性调频脉冲的光纤分布式声波传感技术[J]. 激光与光
 电子学进展, 2023, 60(11): 24-43.
- [5] 周向成. 基于分布式光纤测振的侵入智能识别方法研究[D]. 电子科技大学, 2024.
- [6] 舒俊, 叶帆, 姚峰林. 基于小波降噪和 EMD-AR 谱的地下电缆防破坏监测系统[J]. 电气 传动, 2024, 54(11): 91-96.
- [7] 汪亮. 基于智能传感技术的电力电缆实时监测与评估系统[J]. 办公自动化, 2024, 29(21): 94-96.
- [8] 熊川羽,明月,熊一,等.基于分布式光纤传感的电缆安全状态在线监测[J].自动化技术 与应用,2023,42(06): 20-23.
- [9] 李念达. 基于 BP 神经网络模型的光纤传感数据处理与目标识别算法研究[D]. 华中科技 大学, 2022.
- [10] 贺韬. 基于分布式光纤传感的周界入侵事件高精度识别算法研究[D]. 华中科技大学, 2024.
- [11] 张旭苹, 张益昕, 王亮, 等. 分布式光纤传感技术研究和应用的现状及未来[J]. 光学学报, 2024, 44(01): 11-73.
- [12] 孙浩益. 基于深度神经网络的光纤周界安防系统信号分析技术研究[D]. 北京邮电大学, 2023.
- [13] XIE L, LI Z, ZHOU Y, et al. Railway track online detection based on optical fiber distributed large-range acoustic sensing[J]. IEEE Internet of Things Journal, 2024, 11(4): 6469-6480.
- [14] 胡洲畅. Φ-OTDR 传感技术在铁路安全监测中的应用[D]. 中国科学技术大学, 2021.
- [15] 蔡海文,叶青,王照勇,等. 基于相干瑞利散射的分布式光纤声波传感技术[J]. 激光与光
 电子学进展, 2020, 57(05): 9-24.
- [16] 何祖源,刘庆文. 光纤分布式声波传感器原理与应用[J]. 激光与光电子学进展, 2021, 58 (13): 11-25.
- [17] PASTOR-GRAELLS J, NUNO J, FERNÁNDEZ-RUIZ M R, et al. Chirped-pulse phase-

sensitive reflectometer assisted by first-order raman amplification[J]. Journal of Lightwave Technology, 2017, 35(21): 4677-4683.

- [18] ZHANG Y, XIA L, CAO C, et al. A hybrid single-end-access MZI and $\boldsymbol{\Phi}$ -OTDR vibration sensing system with high frequency response[J]. Optics Communications, 2017, 382: 176-181.
- [19] MASOUDI A, NEWSON T P. High spatial resolution distributed optical fiber dynamic strain sensor with enhanced frequency and strain resolution[J]. Optics Letters, 2017, 42(2): 290-293.
- [20] WANG Y, LU P, MIHAILOV S, et al. Strain measurement range enhanced chirped pulse φ -OTDR for distributed static and dynamic strain measurement based on random fiber grating array[J]. Optics Letters, 2020, 45(21): 6110-6113.
- [21] QIAN H, LUO B, HE H, et al. Distributed dynamic strain sensing in coherent Φ -OTDR with a pulse conversion algorithm[J]. Optics Letters, 2021, 46(7): 1668-1671.
- [22] GAO X, HU W, DOU Z, et al. A method on vibration positioning of Φ-OTDR system based on compressed sensing[J]. IEEE Sensors Journal, 2022, 22(16): 16422-16429.
- [23] LI J, WANG Y, LIU X, et al. SNR improvement for Φ-OTDR with sparse representation denoising method[J]. Optical Fiber Technology, 2023, 76: 103231.
- [24] 杨鉴,陈明. 基于分布式光纤振动传感技术的汽车排气管漏气检测方法研究[J]. 汽车工程师, 2024(11): 20-24.
- [25] 孙艺玫,赵雷,罗斐,等.分布式光纤传感器原理及在地震监测中的应用研究现状[J].防 灾减灾学报,2022,38(01): 67-73.
- [26] 王照勇, 卢斌, 叶蕾, 等. 分布式光纤声波传感及其地震波检测应用[J]. 激光与光电子学 进展, 2021, 58(13): 83-94.
- [27] 孙琪真, 范存政, 李豪, 等. 光纤分布式声波传感技术在石油行业的研究进展[J]. 石油物 探, 2022, 61(01): 50-59+77.
- [28] ZHU H H, LIU W, WANG T, et al. Distributed acoustic sensing for monitoring linear infrastructures: Current status and trends[J]. Sensors, 2022, 22(19): 7550.
- [29] LI D, YI D, ZHOU X, et al. Multisource threatening event recognition scheme targeting drone intrusion in the fiber optic DAS system[J]. IEEE Sensors Journal, 2024, 24(20): 32185-32195.
- [30] HE T, ZHANG S, LI H, et al. An efficient separation and identification algorithm for mixed threatening events applied in fiber-optic distributed acoustic sensor[J]. IEEE Sensors Journal, 2023, 23(20): 24763-24771.
- [31] JIAO W, HU X, GUPTA R, et al. Open set intrusion event recognition using anchor point learning for distributed optical fiber system[J]. IEEE Transactions on Instrumentation and Measurement, 2024.
- [32] WANG Y J, ZHUO W, LIU B, et al. GASF-ConvNeXt-TF algorithm for perimeter security

disturbance identification based on distributed optical fiber sensing system[J]. IEEE Internet of Things Journal, 2024.

- [33] LI J, YAO R, ZHANG J, et al. Pipeline threat event identification based on GAF of distributed fiber optic signals[J]. IEEE Sensors Journal, 2023, 23(21): 26796-26803.
- [34] MA G M, SHI C, QIN W Q, et al. A non-intrusive electrical discharge localization method for gas insulated line based on phase-sensitive OTDR and michelson interferometer[J]. IEEE Transactions on Power Delivery, 2019, 34(4): 1324-1331.
- [35] SUN M, YU M, WANG H, et al. Intelligent water perimeter security event recognition based on NAM-MAE and distributed optic fiber acoustic sensing system[J]. Optics Express, 2023, 31(22): 37058-37073.
- [36] HUANG S, CHAI Q, JIA M, et al. A recognition method of less databases by using decoupling parallel CNN based on multiple feature with DAS[J]. Measurement Science and Technology, 2023, 34(11): 115118.
- [37] LI G, ZENG K, ZHOU B, et al. Vibration monitoring for the West-East Gas Pipeline Project of China by phase optical time domain reflectometry (phase-OTDR)[J]. Instrumentation Science & Technology, 2021, 49(1): 65-80.
- [38] JIA H, LIANG S, LOU S, et al. A k-nearest neighbor algorithm-based near category support vector machine method for event identification of φ-OTDR[J]. IEEE Sensors Journal, 2019, 19(10): 3683-3689.
- [39] WU H, LIU X, XIAO Y, et al. A dynamic time sequence recognition and knowledge mining method based on the hidden markov models (HMMs) for pipeline safety monitoring with Φ-OTDR[J]. Journal of Lightwave Technology, 2019, 37(19): 4991-5000.
- [40] LIEHR S, JÄGER L A, KARAPANAGIOTIS C, et al. Real-time dynamic strain sensing in optical fibers using artificial neural networks[J]. Optics express, 2019, 27(5): 7405-7425.
- [41] ZHU C, PU Y, YANG K, et al. Distributed optical fiber intrusion detection by image encoding and SwinT in multi-interference environment of long-distance pipeline[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-12.
- [42] ZHOU Z, JIAO W, HU X, et al. Open-set event recognition model using 1-D RL-CNN with openmax algorithm for distributed optical fiber vibration sensing system[J]. IEEE Sensors Journal, 2023, 23(12): 12817-12827.
- [43] SHI Y, WANG Y, ZHAO L, et al. An event recognition method for Φ -OTDR sensing system based on deep learning[J]. Sensors, 2019, 19(15): 3421.
- [44] HE T, LIU Y, ZHANG S, et al. High accuracy intrusion pattern recognition using a dual-stagerecognition network for fiber optic distributed sensing system[C]//Conference on Lasers and Electro-Optics. Optica Publishing Group, 2021: JW1A.119.

- [45] WU H, CHEN J, LIU X, et al. One-dimensional CNN-based intelligent recognition of vibrations in pipeline monitoring with DAS[J]. Journal of Lightwave Technology, 2019, 37(17): 4359-4366.
- [46] YANG Y, ZHANG H, LI Y. Long-distance pipeline safety early warning: a distributed optical fiber sensing semi-supervised learning method[J]. IEEE sensors journal, 2021, 21(17): 19453-19461.
- [47] ZHU C, PU Y, LYU Z, et al. Multidimensional information fusion and broad learning systembased condition recognition for energy pipeline safety[J]. Knowledge-Based Systems, 2024, 300: 112259.
- [48] ZHANG J, XIU Y. Image stitching based on human visual system and SIFT algorithm[J]. The Visual Computer, 2024, 40(1): 427-439.
- [49] ZHANG X, ZHANG L, LOU X. A raw image-based end-to-end object detection accelerator using HOG features[J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2022, 69(1): 322-333.
- [50] ZHANG L, LI H, ZHANG X, et al. RAW images-based motion-assisted object detection accelerator using deformable parts models features on 1080p videos[J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2024, 71(11): 5054-5066.
- [51] CHEN Y, PENG X, WANG H, et al. Partial discharge pattern recognition based on morphological features and Faster R-CNN-AlexNet for generator stator[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2024, 31(6): 2956-2965.
- [52] ZAMANIDOOST Y, OULD-BACHIR T, MARTEL S. OMS-CNN: Optimized multi-scale CNN for lung nodule detection based on Faster R-CNN[J]. IEEE Journal of Biomedical and Health Informatics, 2025, 29(3): 2148-2160.
- [53] 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 (CVPR). IEEE, 2016: 779-788.
- [54] XIONG S, FAN Z. Research on pedestrian detection technology based on SSD algorithm[C]//
 2021 International Conference on Digital Society and Intelligent Systems (DSInS). IEEE,
 2021: 352-356.
- [55] GOEL L, PATEL P. Improving YOLOv6 using advanced PSO optimizer for weight selection in lung cancer detection and classification[J]. Multimedia Tools and Applications, 2024, 83 (32): 78059-78092.
- [56] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. Yolov7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2023: 7464-7475.

- [57] ZHOU Z. Traffic accident detection based on YOLOv11[C]//2024 IEEE 2nd International Conference on Electrical, Automation and Computer Engineering (ICEACE). IEEE, 2024: 363-369.
- [58] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 2117-2125.
- [59] ROSS T Y, DOLLÁR G. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision (ICCV). IEEE, 2017: 2980-2988.
- [60] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers [C]//European conference on computer vision (ECCV). Springer, 2020: 213-229.
- [61] CHEN J, KAO S H, HE H, et al. Run, don't walk: Chasing higher flops for faster neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2023: 12021-12031.
- [62] HU J, SHEN L, SUN G. Squeeze-and-Excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018: 7132-7141.
- [63] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]// Proceedings of the European conference on computer vision (ECCV). Springer, 2018: 3-19.
- [64] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2021: 13713-13722.
- [65] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]//ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2023: 1-5.
- [66] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016: 770-778.
- [67] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops. IEEE, 2020: 390-391.
- [68] QIN D, LEICHNER C, DELAKIS M, et al. MobileNetV4: universal models for the mobile ecosystem[C]//European Conference on Computer Vision. Springer, 2025: 78-96.
- [69] REDMON J, FARHADI A. Yolov3: An incremental improvement[EB/OL]. (2018)[2025-03-10]. https://arxiv.org/abs/1804.02767.
- [70] KIM J H, KIM N, PARK Y W, et al. Object detection and classification based on YOLO-V5 with improved maritime dataset[J]. Journal of Marine Science and Engineering, 2022, 10(3):

377.

[71] WANG C, HE W, NIE Y, et al. Gold-yolo: Efficient object detector via gather-and-distribute mechanism[J]. Advances in Neural Information Processing Systems, 2023: 51094-51112.

致谢

在研究学习期间,我有幸得到了三位老师的教导,他们是:我的导师,中国 科大赵云波教授,人工智能研究院胡峰老师以及中国科大的吕文君老师。三位深 厚的学术功底,严谨的工作态度和敏锐的科学洞察力使我受益良多。衷心感谢他 们多年来给予我的悉心教导和热情帮助。

感谢赵云波老师在实验方面的指导以及教授的帮助。赵老师的网络化智能 控制实验室为我的学习提供了很多科研资源,实验室内部的很多资料对我都帮 助巨大,另外实验室提供了很好的学术交流平台,非常感谢实验室的同学老师。 感谢吕文君老师在分布式光纤传感、目标检测方面的科研指导以及教授的帮助。 仍然记得吕老师在我刚接触科研的时候,非常耐心的帮助我入门,给出了很多基 础知识的深刻解释。比如说关于目标检测中交并比和损失函数的概念和发展,至 今回想起来还是很深刻。感谢胡峰老师对我的指导和帮助,胡老师在专业实践过 程中给予了很多支持。

感谢科大的夏奇久、齐振宇等同学的帮助,他们给了非常多的具体指导,在 此深表谢意。感谢父母家人在我求学期间的支持和帮助。感谢室友胡天胜、黄 帅、葛一烽在我生活学习工作等方面的帮助和照顾。感谢所有其他小伙伴对我的 帮助和陪伴。

85

在读期间取得的科研成果

发明专利:

- (1) 吕文君; 黄森清; 康宇; 赵云波. 一种轻量级分布式光纤感知图像目标检测 方法与系统. 授权号: CN118521853B, 2025-02-14.
- (2) 吕文君;黄森清;夏奇久;康宇.分布式光纤传感信号处理方法和系统.授权 号: CN118314513B, 2025-02-07.

会议论文:

(1) 黄森清; 夏奇久; 齐振宇; 祁凯; 吕文君; 赵云波. Cable security state detection based on multi-scale information fusion and distributed fiber optic sensing, 第四 届检测技术与智能系统国际学术会议 (DTIS2024), 2024,12.