

分类号: TP391

密 级: 公开

学校代码: 10363

学 号: 2210330160



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 基于深度学习的汽车流水灯
缺陷检测策略研究

论 文 作 者 陈金城
校 内 导 师 柏受军（副教授）
校 外 导 师 王鸿浩（高级工程师）
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: 2024 年 5 月 31 日

分类号：TP391

单位代码：10363

密类级：公开

学 号：2210330160

题 目 基于深度学习的汽车流水灯缺陷检测策略研究

题 目 RESEARCH ON DEEP LEARNING-BASED
DEFECT DETECTION STRATEGY FOR
AUTOMOTIVE RUNNING LIGHTS

学 生 姓 名 ： 陈金城

校 内 导 师 ： 柏受军（副教授）

校 外 导 师 ： 王鸿浩（高级工程师）

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 ： 2024 年 5 月 19 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后果由本人承担。

学位论文作者签名：陈金城

日期：2024 年 5 月 28 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：陈金城

指导教师签名：柏爱军

日期：2024 年 5 月 28 日

日期：2024 年 5 月 28 日

基于深度学习的汽车流水灯缺陷检测策略研究

摘 要

近年来,越来越多的流水灯组件被应用于汽车车灯中,作为转向灯或装饰灯使用。随着汽车流水灯的使用逐渐广泛,流水灯的款式也随之逐渐繁杂多样。在汽车流水灯的质量检测过程中,由于不同款式的流水灯有着特点各异的缺陷形式,高效的汽车流水灯缺陷检测方法开始广受关注。深度学习有着较高的检测精度,且利用深度学习检测汽车流水灯缺陷,能够通过单个模型同时检测多种不同特点的流水灯缺陷,大幅度提高缺陷检测的效率。因此,本文将深度学习算法引入到汽车流水灯缺陷检测问题的研究中。通过训练深度学习模型,从矩形框和关键点两个角度分别对流水灯缺陷部分进行定位,并将模型迁移到小型嵌入式平台进行模型部署。本文的主要工作及创新点总结如下:

(1) 针对汽车流水灯款式多样,缺陷形式繁杂的问题,本文提出了一种基于矩形框定位的汽车流水灯缺陷检测方法。该方法以当前精度和速度都较为优异的 YOLOv7 目标检测算法为基础,用矩形框的形式定位出汽车流水灯缺陷的整体位置。并在 YOLOv7 的基础上进一步改进,以增加算法的检测精度。首先,在网络中加入了递归门控卷积和全局注意力机制,用以增强网络的特征提取能力。其次,引入了 Ghost 卷积和无参数注意力机制,用以减少冗余信息。最后,将基本的卷积计算 ELAN 模块替换为融合了注意力机制的并列结构

ELAN 模块。改进后的 YOLOv7 算法能够用单个模型精准识别出多种汽车流水灯缺陷，在自建的汽车流水灯缺陷数据集上精度表现达到 89.7%。

(2) 矩形框定位方法的特点在于能快速检测出多种流水灯缺陷的整体范围，但无法检测出缺陷部分的具体位置与形状。针对这项不足，本文提出了一种基于关键点定位的汽车流水灯缺陷检测方法，通过定位局部关键点的形式识别出汽车流水灯的缺陷部分。并且，在保留 YOLOv7 网络整体框架基础上，提出了适用于汽车流水灯缺陷的关键点检测网络 YOLO-kpt。首先，保留 PANet 特征金字塔结构，采用双 SPPCSPC 模块；然后，用融合了 PConv 卷积的残差结构 ResPC 模块作为基本卷积计算模块；最后，将所有预测关键点和实际关键点之间的欧氏像素距离平均值作为误差评价标准。用自建汽车流水灯缺陷数据集训练得到的 YOLO-kpt 模型进行测试，预测关键点的平均欧式像素距离误差仅为 1.8383。

(3) 为探究汽车流水灯缺陷检测模型的工业化应用效果，本文选用了英伟达系列的 Jetson Xavier NX 小型嵌入式平台，对本文提出的基于矩形框定位和基于关键点定位的汽车流水灯缺陷检测方法进行模型部署。

关键词：汽车流水灯，缺陷检测，深度学习，YOLOv7，关键点检测

RESEARCH ON DEEP LEARNING-BASED DEFECT DETECTION STRATEGY FOR AUTOMOTIVE RUNNING LIGHTS

ABSTRACT

In recent years, more and more running light components have been used in automobile lights as turn signals or decorative lights. As the use of automotive running lights is becoming more and more widespread, the styles of running lights are also becoming more and more diversified. In the quality inspection process of automotive running lights, due to the fact that different styles of running lights have different defects, efficient defect detection methods for automotive running lights have begun to attract widespread attention. Deep learning methods have high detection accuracy. The use of deep learning methods to detect defects in automotive running lights can simultaneously detect defects in running lights with multiple different characteristics through a single model, which greatly improves the efficiency of defect detection. Therefore, this paper introduces deep learning algorithms into the study of automotive running lights defect detection problem. By training the deep learning model, the defective part of the running lights is localized from two perspectives: rectangular box and key point, and the model is deployed to

a small embedded platform to verify the effect. The main work and innovations of this paper are summarized as follows:

(1) Aiming at the problem of automobile running lights with various styles and defects, this paper proposes a defect detection method for automobile running lights based on rectangular box localization. The method is based on the current YOLOv7 object detection algorithm, which has excellent accuracy and speed, and locates the overall position of the defects of the automotive running lights in the form of a rectangular box. Moreover, it is further improved on the basis of the original YOLOv7 to increase the detection accuracy of the algorithm. Firstly, recursive gated convolution and global attention mechanism are added to the network to enhance the feature extraction ability of the network; secondly, ghost convolution and parameter-free attention mechanism are added to reduce the redundant information; and lastly, the basic convolutional computation ELAN module is replaced by the juxtaposition-structured ELAN module that incorporates the attention mechanism. The improved YOLOv7 algorithm is able to accurately recognize multiple automotive running light defects with a single model, and achieves an accuracy of 89.7% on a self- built automotive running light defect dataset.

(2) The rectangular box positioning method is characterized by its ability to quickly detect a wide range of running light defects in the whole

part, but it is unable to detect the specific location and shape of the defective part. To address this deficiency, this paper proposes a defect detection method for automotive running lights based on key point localization. The method identifies the defective part of the automotive running lights in the form of locating localized key points. Moreover, based on retaining the overall framework of YOLOv7 network, YOLO-kpt, a key point detection network applicable to defects of automotive running lights, is proposed. First, the feature pyramid structure is retained and the dual SPPCSPC module is used. Then, the ResPC module, which is a residual structure that incorporates PConv convolution, is used as the basic convolutional computation module. Finally, the average Euclidean pixel distance between all predicted and actual key points is used as an error evaluation criterion. The average Euclidean pixel distance error of the predicted key points is only 1.8383 when tested with the YOLO-kpt model trained on the self-built automobile running light defect dataset.

(3) In order to explore the industrialized application effect of the defect detection model of automotive running lights, this paper selects the small embedded platform of Jetson Xavier NX. The applicability of the rectangular box localization-based and key point localization-based defect detection algorithms for automotive running lights proposed in this paper on a small embedded platform is verified.

Chen Jincheng (Electronic Information)

Supervised by Associate Professor Bai Shoujun

KEY WORDS: automotive running lights, defect detection, deep learning,
YOLOv7, key point detection

目录

摘 要	I
ABSTRACT	III
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 缺陷检测技术研究现状	3
1.2.2 基于深度学习的目标检测算法研究现状	4
1.2.3 汽车车灯检测技术研究现状	6
1.3 论文研究内容	7
1.4 论文章节安排	8
第 2 章 流水灯缺陷识别算法理论基础	10
2.1 问题分析与系统整体方案设计	10
2.2 卷积神经网络理论基础	11
2.3 深度学习目标检测算法	15
2.3.1 基于候选区域的目标检测算法	15
2.3.2 基于回归的目标检测算法	16
2.4 注意力机制原理	18
2.5 汽车流水灯缺陷检测策略整体技术路线	20
2.6 本章小结	22
第 3 章 基于矩形框定位的缺陷检测方法	23
3.1 YOLOv7 矩形框定位算法	23
3.2 改进矩形框定位算法的相关模块机理分析	24
3.3 改进的 YOLOv7 流水灯缺陷矩形框定位算法	27
3.4 流水灯缺陷的矩形框定位实验与分析	29
3.3.1 矩形框定位实验环境及评价指标	29
3.3.2 矩形框定位实验结果与分析	30
3.5 本章小结	34

第 4 章 基于关键点定位的缺陷检测方法	35
4.1 YOLOv7 关键点定位算法	35
4.2 改进关键点定位算法的相关模块机理分析	36
4.3 改进的 YOLOv7 流水灯缺陷关键点定位算法	40
4.4 流水灯缺陷的关键点定位实验与分析	42
4.3.1 关键点定位实验设置及评价指标	42
4.3.2 关键点定位实验结果与分析	43
4.5 本章小结	46
第 5 章 嵌入式平台部署与应用	47
5.1 Jetson Xavier NX 嵌入式平台硬件介绍	47
5.2 嵌入式系统环境搭建	48
5.3 汽车流水灯缺陷检测模型部署	50
5.3.1 基于矩形框定位的模型部署	50
5.3.2 基于关键点定位的模型部署	53
5.4 本章小结	55
第 6 章 总结与展望	56
6.1 工作总结	56
6.2 未来展望	57
参考文献	58
攻读硕士学位期间发表的学术论文	63
致谢	64

第 1 章 绪论

1.1 研究背景及意义

在我国整体经济快速发展的大背景下，社会基础设施在不断地完善，国内的汽车制造行业也在蓬勃发展。在汽车产量与国内汽车保有量不断增长的背景下，交通事故的发生也在逐年增长^[1]。截止到 2023 年 6 月，国内机动车保有量大约为 4.26 亿，在交通事故中丧生的人数高达 6.1 万人。其中，夜间行车而导致的交通事故占据较大比例。因此，车灯作为汽车在夜间行驶时的主要光源，直接影响着交通安全。

自改革开放以来，国内的汽车制造企业得到快速发展^[2]。与此同时，与汽车制造相关的汽车零部件生产企业也在紧跟趋势^[3]。其中，汽车车灯的制造成为汽车产业链中不可或缺的一环，车灯零部件的装配位置和灯光亮度也逐渐规范化^[4]。当前大部分的车灯制造企业仍大量采用传统的图像处理方法进行车灯的灯光质量检测^[5]，但传统的图像处理方法检测精度不高，且难以用单个模型检测多种类型的缺陷。车灯检测是汽车零件检测中必不可少的一环，而且车灯有多种不同的类型，包括远光灯、近光灯、转向灯、雾灯、流水灯等等。这其中，汽车流水灯的款式繁杂，缺陷检测难度最高，且目前存在的智能化检测方法较少。图 1-1 所示为内置流水灯的汽车车灯组装部件。



图 1-1 车灯部件

由于汽车流水灯的应用较为新颖，流水灯缺陷的检测手段较为单一。在传统的流水灯缺陷检测中，往往利用传统模板匹配方法检测汽车流水灯缺陷部分^[6]。

利用模板匹配检测流水灯缺陷，只对单种流水灯款式有效。随着流水灯款式逐渐多样化，传统模板匹配方法的弊端日渐显露，无法通过单个模板同时匹配不同特点的流水灯缺陷。连续拍摄的运行中的汽车流水灯如图 1-2 所示。然而，我国的车企大都停留在传统的工业流水线生产模式中。大多数企业对智能化升级改造的主动性不强，每个阶段生产出的产品都是用传统的半自动化方法完成质量检测工作。特别是在汽车流水灯质量检测上，传统检测手段的劣势不言而喻。在流水灯的质量检测方面，传统图像处理方法检测效率较低，尤其是在面对复杂多变的流水灯款式时，传统方法的泛化性和鲁棒性较差。检测结果不够精准容易造成流水灯缺陷仍存在小部分漏检。加快企业的缺陷检测技术智能化转型，能更好地帮助企业提升产品生产线检测效率。



图 1-2 依次点亮的汽车流水灯

机器视觉技术在传统汽车制造企业中已经取得了一些应用，但其全面性仍存在不足^[7]。传统目标检测算法的准确度相对较低，且存在一定的局限性，对特定环境的要求较高，检测对象单一，泛用性差，需要根据具体检测需求进行定制。特别是在汽车零部件制造过程中，车灯缺陷类型和大小多种多样，而车灯位置的变化或外壳的特殊性可能导致灯光缺陷位置的不确定性，需要采用多种尺度的滑动窗口进行反复搜索，从而增加了计算难度。研究表明，机器视觉技术在缺陷检测上具有一定的有效性^[8]，但由于不同产品类型需要不同的缺陷检测算法和技术，传统机器视觉技术的可移植性较低，研发与应用存在一定的限制^[9]。为了解决这些问题，引入深度学习方法成为一种可行的选择。

在深度学习的框架下，特别是深度神经网络的应用，为解决汽车流水灯缺陷检测任务提供了更为先进和可行的途径。深度学习算法的不断成熟使得智能检测

变得更加可行,相较于传统机器视觉技术,深度神经网络在提取目标特征信息方面具有显著的优势,大大提高了检测和识别的效率^[10]。卷积神经网络相关理论的不断成熟,使得深度学习算法逐渐被广泛应用在机器视觉领域。深度神经网络的优势在于其能够高效提取目标特征信息,这使得对汽车流水灯的缺陷检测更为精准和高效。相较于传统技术,深度神经网络提取的特征信息有着更好的丰富性和鲁棒性,有助于应对复杂多变的汽车流水灯缺陷情况。

因此,深度学习算法为传统汽车车灯制造企业带来了新的解决方案,通过提高缺陷检测的精度和效率,有助于优化汽车零部件生产线,加速产业自动化升级改造。这不仅解决了传统机器视觉技术的局限性,还提升了产品质量,从而在汽车行业中提高品牌的竞争地位,满足国内企业的生产需求。本研究拟采用当下常用的深度学习算法实现汽车流水灯缺陷智能检测,针对车灯制造企业的视觉检测研发需求,在现有的深度学习目标检测算法的基础上进行改良迭代,研究适用于汽车流水灯的智能化缺陷检测方法。因此,本文提出基于深度学习的高效汽车流水灯缺陷检测策略,为流水灯缺陷的智能化检测提供扎实的理论和技术基础。

1.2 国内外研究现状

1.2.1 缺陷检测技术研究现状

缺陷检测技术在工业化生产线的质量监控中起着重要的作用。最早的缺陷检测主要依靠人工对产品进行缺陷筛查,准确度低且效率不高。随着计算机视觉领域中图像处理技术的发展,通过机器视觉类装置来拍摄图像进而判断缺陷部分的方法随之兴起。机器视觉方法的引入使得工业产品生产线质量监控阶段的人工操作大量减少,大幅提升了质量检测过程的整体自动化水平^[11]。缺陷检测技术可以分为传统图像处理方法和深度学习方法两个发展阶段。

当使用传统的图像处理方法进行缺陷检测时,一般需要包括图像采集、图像预处理、图像特征提取和缺陷目标分类识别等步骤^[12]。首先,采用工业相机对待检测的缺陷目标进行图像拍摄。拍摄图像时需要尽可能突出待测缺陷的特征,同时还需要弱化复杂的背景干扰和抑制额外的噪声干扰。对于特殊的缺陷目标,还需考虑设计特殊的光照补偿。图像采集完成后,需要经过预处理操作,主要为

去噪、滤波和图像增强等步骤。目的是尽可能将图像中的重要特征信息保留下来，得到高质量的缺陷图像。图像特征提取操作包括了阈值分割、边缘检测和区域生长等方法。阈值分割需要设置一个或多个阈值，判断待测缺陷部分是否在阈值范围内，最终图像像素分成黑白两类。边缘检测的原理是利用边缘算子将待测缺陷与背景进行区域分割，常见的边缘算子包括 Sobel 算子^[13]和 Canny 算子^[14]。区域生长方法需要先划定生长区域，再分配不同的种子像素，利用该种子合并领域里的其它像素。传统的图像处理方法需要根据不同的缺陷目标而有针对性的应用，鲁棒性较差。

近年来深度学习方法在缺陷领域的应用越来越普及。利用深度学习理论，可以构建卷积神经网络模型，通过大量带有缺陷目标的图像数据集进行模型训练。从而实现缺陷目标的检测或分割任务。杨宏飞等人^[15]利用全卷积神经网络对钢轨表面的缺陷进行像素级的自动分割，以获得钢轨表面缺陷的准确轮廓和形状信息。曹锦纲等人^[16]提出了基于两级注意力特征融合的卷积神经网络，用于复杂环境下的表面缺陷检测。基于深度学习方法的缺陷检测模型可以通过卷积神经网络自动提取特征，相对于传统图像处理技术有着更优异的准确性和鲁棒性。

1.2.2 基于深度学习的目标检测算法研究现状

目标检测属于计算机视觉领域，在工业生产制造中具有重要应用。其核心内容是对待测目标进行定位和分类。通常使用矩形边界框的显示形式，对预测到的目标进行定位与分类。将目标检测算法按技术划分，可分为基于传统图像处理的算法和基于深度学习理论的算法。

传统目标检测算法的基本架构主要分为区域选择器、特征提取器和分类器。区域选择器主要使用不同大小和比例的滑动窗口，在图像上按一定的步长滑动，通过滑动窗口裁剪的图像块形成具有统一大小的图像。特征提取器主要使用 SIFT^[17]、Haar^[18]、HOG^[19]等算法直接从图像中提取出特征。最后，分类器使用 SVM 和 Adaboost 等算法来识别对象类别。虽然传统的目标检测比较成熟，但面对复杂情况时的检测效果不好，鲁棒性较差。卷积神经网络 (Convolutional Neural Networks, CNN) 可以学习图像从低级到高级的特征，因此深度学习算法提取目标特征方便快捷，泛用性强，逐渐取代传统方法成为目标检测领域的主流算法。

随着计算机算力的强化，基于深度学习理论的目标检测逐渐得到重视^[20]。2012年，Krizhevsky 等人^[21]提出了一个名为 AlexNet 的深度学习卷积神经网络，这项成果直接让卷积神经网络的相关研究趋于热门。2014年，R. Girshick 等人^[22]提出了 R-CNN，这是深度学习研究中具有里程碑意义的目标检测算法。

近年来，随着深度学习在图像处理领域的应用日益广泛，出现了许多基于深度学习的目标检测算法。根据识别步骤的不同，这些算法可以分为两类：首先是两阶段算法，包括 R-CNN、Fast-RCNN^[23]、Faster-RCNN^[24]和 Mask-RCNN^[25]。两阶段算法通常首先使用启发式算法或 CNN 生成候选区域，然后使用分类器对所有候选区域进行分类，再使用回归器优化平滑确定物体位置的向量。另一种是一阶段算法，如 YOLO^[26]算法和 SSD^[27]算法等。这些算法只使用一个网络，并直接提取检测类别和回归结果。相比之下，两阶段算法在目标定位和分类方面更为精确，而一阶段检测算法在检测速度和模型大小方面具有显著优势，但在检测精度上略逊于两阶段算法。表 1-1 列举出了常用的深度学习目标检测算法以及它们之间的优缺点对比。

从最近几年深度学习方法的研究趋势来看，目标检测算法的研究重点是提高检测精度，满足各种复杂场景的应用。现在已有很多成熟且开源的目标检测算法，但是大部分的算法模型有着不同的性能优势^[28]。在工业化的检测任务应用中，需要根据目标检测任务的具体需求选择合适的算法模型。

表 1-1 常用的深度学习目标检测算法对比

算法	优点	缺点
R-CNN	区域精确	慢、内存占用大
Fast R-CNN	更快、端到端	训练复杂
Faster R-CNN	更快、共享特征	较复杂、边界框限制
Mask R-CNN	目标检测+实例分割	速度较慢、资源占用大
YOLO	实时性强	定位不够精确
SSD	高速、多尺度检测	定位精度较低

关键点检测是深度学习目标检测方法的一个细化分支，多年来已有学者对其展开研究。由于近几年人机交互等技术的逐渐成熟，关键点检测算法逐渐被应用到不同的研究领域。

在工业检测领域，方翌啸等人^[29]对传统指针仪表读数方法进行研究，将深度学习关键点检测方法融入到仪表读数中，通过定位指针关键点的方式自动读取指针仪表数字。吴涛等人^[30]采用了 UniPose 算法和 Mask-RCNN 算法作为输电杆塔的关键点检测网络基础框架。张博雅等人^[31]利用卷积神经网络定位驾驶员眼睛和嘴部的关键点部分，进而估计驾驶员的疲劳状态。钟依健等人^[32]构建了一个奶牛关节点定位系统。王继皓等人^[33]提出了适用于铁路的关键点定位方法。

目前，已有许多学者将关键点检测用于汽车检测领域。欧巧凤等人^[34]选用多任务级联卷积神经网络来对车牌进行关键点定位。孙峰瑶等人^[35]提出基于多视角的特定车辆重识别网络来检测汽车车身的关键点位置。谢宇等人^[36]提出一种用于车辆关键点检测的新型多类型遮挡感知网络。但在汽车流水灯的缺陷检测方面，关键点检测方法的应用还少有研究。

1.2.3 汽车车灯检测技术研究现状

车灯作为汽车的重要部件之一，其相应检测手段经历了几十年的创新和发展，逐渐实现了自动化和高效化。汽车车灯检测技术在不断创新，其自动化和高效化水平逐步提升，为汽车制造业的可持续发展注入新的动力。随着科技的进步，机器视觉技术的引入为汽车车灯的检测提供了新的解决方案。传统的检测方法受限于人工智能和图像处理的局限性，而深度学习的应用为解决这些问题提供了更为先进的手段。

车灯检测方法可以分为传统方法和深度学习方法。传统方法一般使用图像处理方法进行模板匹配。Cucchiara 等人^[37]利用模板匹配的方法，将常见的汽车大灯形状制作成模板，再将模板与拍摄好的车灯图像中亮度最高的部分进行匹配，从而识别出汽车车灯的位置。姜涛等人^[38]提出基于 DAN 的关键点识别网络，用于精确识别汽车前脸关键点的位置。但传统的目标检测方法存在泛化性差、鲁棒性不强等问题，在车灯缺陷检测任务中难以完全满足要求。

在最近的几年里，由于计算机硬件计算能力的提升和开源数据集的增加，神经网络技术经历了前所未有的发展。随着卷积神经网络在目标检测领域的应用逐渐普遍，有学者将深度学习目标检测方法应用到车灯检测任务中。李策等人^[39]利用深度学习算法对汽车车灯进行识别，通过对视频截取出图片并标注，使用

YOLOv5 算法对训练模型，得到的模型具有准确度高，速度快的优势。Moon^[40]提出了一种基于卷积神经网络的汽车车灯位置旋转校准后的感兴趣区域缺陷检测方法，以确定汽车车灯零件是否存在缺陷。Chen 等人^[41]使用基于 Nakagami 图像的方法来定位车灯的整体区域，并用卷积神经网络生成特征图从而得到对应的车辆提议区域，最后将车辆提议区域和车灯区域结合为新的目标感兴趣区域。

利用深度学习方法检测车灯缺陷极大提升了工业化检测的效率，但在针对汽车流水灯的细化领域，深度学习方法的应用并不广泛。同时，由于汽车流水灯的风格繁杂，检测缺陷的难度高于普通汽车车灯。

1.3 论文研究内容

目标的精确识别作为缺陷检测领域的主要研究内容，直接衡量着该缺陷检测方法的有效性。因此，对缺陷部分的精准定位是研究内容的重中之重。本文将围绕汽车流水灯的灯光缺陷检测任务，采用深度学习目标检测算法，针对汽车流水灯的缺陷检测策略展开研究。本文的研究具体可包括以下几个部分：

(1) 对汽车流水灯的缺陷检测整体方案进行设计。

分析汽车流水灯灯光缺陷部分的不同特点，结合工业化的缺陷检测需求，对基于深度学习的缺陷检测方法进行研究，并选用合适的深度学习算法。在确定深度学习算法的基础上，提出定位矩形框和定位关键点两种缺陷检测思路。针对工业化检测需求，选用小型嵌入式平台对模型进行缺陷检测模型部署。最终确定汽车流水灯的缺陷检测策略。

(2) 对缺陷检测算法进行研究和改进，并自建数据集进行效果验证。

在当前已有的目标检测算法中，本文选用了精度和速度的综合表现较为优异的 YOLOv7 目标检测算法作为基础算法。在利用矩形框定位缺陷部分的检测方法中，本文对 YOLOv7 算法进行了相关改进。为提升卷积神经网络的特征提取能力，在 YOLOv7 原网络中加入了 GAM 全局注意力机制和 g^{ncov} 递归门控卷积。同时，为避免因大量的模型参数而导致速度下降，加入了 SimAM 无参数注意力和 Ghost 幽灵卷积。在利用关键点定位缺陷部分的检测方法中，本文提出了关键点检测网络 YOLO-kpt。该网络保留了 YOLOv7 的整体网络架构，采用了双 SPPCSPC 模块，并添加了关键点输出检测头。同时，为保证关键点信息的有效

提取，本文设计了全新的卷积操作模块 ResPC 作为 YOLO-kpt 的基本特征提取模块。该模块采用残差网络的结构设计，并融合了部分卷积 PConv。最后，由于公开的汽车流水灯缺陷数据集较少，本文利用真实车灯部件拍摄图片，建立汽车流水灯缺陷数据集并开展实验。

(3) 对模型的实物平台部署研究

在工业化的缺陷检测过程中，需要考虑检测设备的便捷性。本文将研究深度学习模型的嵌入式平台适用性，通过在嵌入式模块移植训练完成的网络模型，对汽车流水灯缺陷部分进行缺陷检测。在对比了多款嵌入式平台后，选用了英伟达 Jetson Xavier NX 模块作为嵌入式平台开展模型部署实验。

1.4 论文章节安排

本论文总共分为六章，每个章节的内容如下：

第 1 章：绪论。本章首先对基于深度学习的汽车流水灯缺陷检测策略的研究背景及意义进行整体概述。接着分别分析了缺陷检测技术、深度学习目标检测算法和汽车车灯检测技术的国内外研究现状。最后简单概括了本文的主要研究内容和章节安排。

第 2 章：流水灯缺陷识别算法理论基础。本章首先对问题和缺陷检测系统整体方案进行探究。随后分析了卷积神经网络的组成部分，并对基于候选区域和基于回归的深度学习目标检测算法进行对比分析。由于本文对算法的改进用到了注意力机制，因此对注意力机制的基本原理以及经典的注意力模型进行了总结。最后再论述了汽车流水灯缺陷检测的研究要点及对应解决方案。

第 3 章：基于矩形框定位的缺陷检测。由于本文使用的算法是基于 YOLOv7 改进而来，本章首先阐述了 YOLOv7 目标检测算法的结构与原理。接着对本文所使用的矩形框定位方法进行详细论述，包括所使用到的相关模块机制和改进后的 YOLOv7 矩形框缺陷定位算法。最后，开展了本章节的实验部分，并对算法的实验效果进行分析。

第 4 章：基于关键点定位的缺陷检测。本文使用的关键点定位算法借鉴了 YOLOv7 的网络架构，因此本章首先阐述了基于 YOLOv7 的关键点检测算法。然后，对汽车流水灯缺陷关键点定位方法进行详细论述，包括使用到的相关模块

机制和本章提出的关键点定位网络。最后，开展了本章节的实验部分，并对实验结果进行分析。

第5章：嵌入式平台部署与应用。本章首先概述了英伟达系列的 Jetson Xavier NX 嵌入式平台，包括硬件配置和系统环境。然后对本文汽车流水灯缺陷检测模型在嵌入式平台进行部署实验并分析效果。

第6章：总结与展望。针对本文的工作做出总结，简要概括本文的工作内容，并说明不足之处。最后对后续研究提出展望。

第 2 章 流水灯缺陷识别算法理论基础

本章首先对汽车流水灯检测过程中面临的问题进行详细分析,并探讨了缺陷检测系统的整体方案设计。本文方法涉及到深度学习算法,因此本章对卷积神经网络理论、深度学习目标检测算法以及注意力机制理论进行了简要分析。最后,对本文的研究对象汽车流水灯缺陷进行描述,并论述了汽车流水灯缺陷检测策略的整体技术路线。

2.1 问题分析与系统整体方案设计

在汽车车灯的缺陷检测过程中,存在许多检测难点。尤其是针对流水灯这种车灯类型,缺陷的特征更加复杂。在汽车流水灯的工业化缺陷检测过程中,一般采用机器视觉的检测手段。然而,目前公开的汽车流水灯缺陷数据集较少,难以利用开源的数据开展研究。在汽车流水灯的缺陷检测方法研究中,首先需要建立流水灯缺陷数据集。不同于普通的车灯款式,流水灯在运行过程中,灯珠连续闪烁点亮,流水灯的缺陷状态并没有持续显现。对于快速闪烁运行的流水灯,难以用一般的图像拍摄方式记录流水灯的缺陷状态。尤其对于整体尺寸较小和灯珠尺寸较小的汽车流水灯款式,用相机直接拍摄的方式难以突出缺陷特征。其次,现有的传统缺陷检测算法对于特定的缺陷形态有明显的效果,但面对缺陷特征较为复杂多样的汽车流水灯,往往难以用一个模型同时检测多种缺陷。最后,工业化的汽车流水灯缺陷检测方法需要考虑到缺陷检测任务的实施便捷性。对于在实验室环境中训练得到的缺陷检测模型,需要能够将其应用到工业化的生产环境中。

图 2-1 为汽车流水灯缺陷检测系统整体方案设计思路。首先,在汽车流水灯缺陷数据集的建立阶段,采用真实的车灯零部件。选用工业高速相机,并配合可调光的工业镜头对运行中的流水灯进行连续拍摄,此时可得到包含清晰的汽车流水灯缺陷特征的图像。接着根据检测模型的检测需求对流水灯缺陷图像进行缺陷位置标注,此时可建立满足研究需求的汽车流水灯缺陷数据集。其次,对于缺陷检测算法部分,采用当前缺陷检测领域最常用的深度学习算法。根据缺陷检测任务的需求侧重点,从目前已有的深度学习算法中选用合适的种类,包括常规目标

检测、关键点检测和语义分割算法等。在已选取的合适算法基础上，利用流水灯缺陷数据集进行模型训练。在模型训练过程中利用 GPU 服务器缩短模型迭代周期，并多次调试程序，使模型参数更合理。最后，将已经完成训练的检测模型移植到检测终端的核心模块中，并搭配可视化显示界面。汽车流水灯缺陷检测模型需要兼具缺陷检测的有效性和模型移植的便捷性，除了在实验室环境下精确检测缺陷目标，还需能够移植到工业化的生产环境中，符合实际生产的应用需求。




图 2-1 系统整体方案设计

2.2 卷积神经网络理论基础

1、卷积神经网络

卷积神经网络在深度学习方法中有着重要地位，是传统人工神经网络的主要替代。利用卷积操作，卷积层会提取出本层输入特征图的信息。随着卷积操作的迭代，最终得到的特征信息也更接近于理想值。图 2-2 为卷积神经网络整体结构。




图 2-2 卷积神经网络结构

卷积神经网络通常包括卷积层、池化层、全连接层、激活函数和损失函数等部分。其中，卷积层、池化层和全连接层用于进行卷积操作，进而提取图像的信息特征。激活函数的作用是引入非线性映射，损失函数则用来更新网络的权重参数。

2、卷积层

卷积层是卷积神经网络中的核心组件之一，功能是利用卷积操作从输入的图片数据里提取出特征信息。通过利用卷积操作对输入的图片数据进行逐步计算，并提取出新数据作为特征图输出。卷积操作属于一种数学运算方式，它在输入数据上滑动一个称为卷积核(或滤波器)的小窗口，计算输入数据与卷积核之间的点乘和累加运算。这个小窗口的大小通常是正方形或矩形，并且可以通过学习得到最优的卷积核参数。图 2-3 为卷积操作示例。其中，输入尺寸为 5×5 大小的特征图，利用 3×3 大小的卷积核进行乘加运算，滑动步长为 1。卷积核与特征图的 9 个数字一一对应相乘，将相乘得到的数相加。之后卷积核向右滑动一个位置再重复操作。




图 2-3 卷积操作示例

由卷积操作得到的特征图可以看作是对输入数据的不同特征的响应图，每个特征图都对应着一种不同的局部特征。通过多个卷积层的连续卷积操作，神经网络能够提取到更有效的特征信息。卷积操作有两个重要特性，分别是参数共享和局部连接。参数共享减少了需要学习的参数数量。局部连接使得卷积操作对输入数据的平移操作具有不变性。

3、池化层

池化层是卷积神经网络结构中的一个组成部分，功能是减小特征图的尺寸并提取特征的汇总信息。它通过滑动一个固定大小的窗口在输入数据上进行卷积操作，常见的池化操作包括最大池化和平均池化。进行最大池化操作时，将被选特

征图按照滑动窗口划分成几个区域，选出滑动窗口中的最大值。最大池化在保留主要特征的同时，减少了空间维度，并且对于输入数据的平移和部分变形具有一定的不变性。进行平均池化操作时，将被选特征图按照滑动窗口划分成几个区域，计算出滑动窗口中的平均值。平均池化可以有效地减少噪声和细微的变化，平滑特征图，并保留一定程度的全局特征。图 2-4 是最大池化和平均池化的效果示例，图中输入特征图为 4×4 的尺寸，池化窗口为 2×2 的尺寸，滑动步长为 2。




图 2-4 最大池化示例

值得注意的是，池化层没有可训练的参数，仅仅是通过一些简单的操作来改变特征图的尺寸和特征表示。池化层提取主要特征和减少冗余信息的方式，可以帮助网络更有效地处理图像和其他二维数据。

4、全连接层

全连接层是卷积神经网络中的最后一环。全连接层把高维的特征表示转换为一维向量，将这些特征与相应的权重进行线性组合，产生最终的输出结果。最后将最终输出结果得到的特征信息进行类别判定。全连接层通常位于卷积层和最终输出层之间，可以有多个全连接层堆叠在一起。

图 2-5 为全连接层的简易形式。此时令 x_1 、 x_2 、 x_3 为输入， a_1 、 a_2 、 a_3 为隐含层， b_1 、 b_2 、 b_3 为偏置项， w_{ij} 为相应的权重，则隐含层的计算可表示为式(2-1)。

$$\begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} = \begin{pmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \\ w_{31} & w_{32} & w_{33} \end{pmatrix} * \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} + \begin{pmatrix} b_1 \\ b_2 \\ b_3 \end{pmatrix} \quad (2-1)$$

全连接层在图像分类、目标检测和语义分割等任务中起着关键作用，能够将卷积和池化层提取到的高级特征与标签之间建立起关联，并进行分类、回归或其他特定任务的预测。全连接层在卷积神经网络中将卷积和池化层的特征表示映射到特定任务的输出空间中，实现对图像或其他数据的分类、回归等任务。并且通

过学习权重参数，使得网络能够自适应地进行预测和决策。




图 2-5 全连接层示例

5、激活函数

激活函数是神经网络中的一种非线性函数，常用于引入非线性变换，增加网络的表达能力和非线性拟合能力。激活函数的主要作用是对输入信号进行非线性映射，使得卷积神经网络可以对输入信号进行非线性处理。以下是几种常见的激活函数：

Sigmoid 函数：Sigmoid 函数具有平滑的 S 形曲线形状，能将任意实数映射到一个概率值或激活状态，可表示为公式(2-2)。并将输入值映射到 0 到 1 之间的连续范围。但是，在输入值较大或较小时，容易导致梯度消失问题。

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

双曲正切函数(Tanh 函数)：Tanh 函数能将输入值映射到-1 到 1 之间的连续范围，可表示为公式(2-3)。它与 Sigmoid 函数类似，但是在输出范围上更对称，具有更大的动态范围和更陡峭的斜率。

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

ReLU 函数(Rectified Linear Unit)：ReLU 函数在输入值大于 0 时输出输入值本身，而在输入值小于或等于 0 时输出 0，可表示为公式(2-4)。它具有简单的计算形式和线性增长的特性，使得神经网络具有更好的收敛性和表达能力。但是在输入值小于 0 时，ReLU 函数的梯度值为 0，这种情况可能会使神经元无法更新权重。

$$f(x) = \max(0, x) \quad (2-4)$$

Leaky ReLU 函数：Leaky ReLU 函数是 ReLU 函数的改进版本，在输入值小于 0 时引入一个小的负斜率，以避免梯度为 0 的问题。这样可以解决 ReLU 函数

的梯度消失问题，提高网络的稳定性和学习能力。Leaky ReLU 函数可表示为公式(2-5)。

$$f(x) = \max(\alpha x, x) \quad (2-5)$$

激活函数可以对输入值进行非线性映射，使得神经网络可以处理复杂的非线性模式和关系，从而提高网络的表达能力。激活函数还可以引入非线性，使神经网络可以表示更加复杂和抽象的特征和模式。这让神经网络能够适应各种复杂的数据分布和任务要求，提高模型的拟合能力和泛化能力。图 2-6 为 4 种激活函数的曲线图。选择合适的激活函数取决于具体的任务和网络结构。在某些情况下，可以根据问题的特点尝试其它激活函数，以优化网络的性能和收敛速度。




图 2-6 激活函数曲线图

2.3 深度学习目标检测算法

2.3.1 基于候选区域的目标检测算法

基于候选区域的目标检测，又称两阶段(Two-stage)目标检测。第 1 个阶段是生成候选区域，首先使用一个区域提议网络(Region Proposal Network, RPN)来生成可能包含目标的候选区域。以输入图像为基础，通过滑动窗口或锚点框的方式在不同位置和尺度上生成候选区域。对于每个候选区域，RPN 会预测它是否包含目标以及对应的边界框偏移量。第 2 个阶段为位置精修与分类：在生成候选区域之后，候选区域会被输入到第 2 个阶段。此时通过卷积神经网络(CNN)提取出候选区域的特征信息，最后再用全连接层和 Softmax 函数对特征信息所属类别进行区分。同时，对于每个候选区域，位置回归器会根据候选区域的特征和真实标注框之间的差异，预测出更准确的边界框位置。

两阶段算法的训练过程可以简述为：通过区域提议网络(RPN)生成候选区域，

并计算候选区域与真实标注框之间的位置偏差。根据候选区域的特征和真实标注框的类别信息,计算分类器的损失。使用位置回归器预测候选区域的边界框位置,并计算位置回归器的损失。将分类器和位置回归器的损失进行加权求和,得到总的损失,并使用反向传播算法进行模型参数的更新。在目标检测推理阶段,通过将待检测图像输入到两阶段目标检测算法中,得到候选区域和它们对应的类别和位置信息。常见的两阶段目标检测算法包括 Faster R-CNN、Mask R-CNN 等。

2.3.2 基于回归的目标检测算法

两阶段的目标检测方法在检测精度上有优势,但图像推理的效率较低,基于回归的目标检测算法逐渐显现其优势。基于回归的目标检测,又称一阶段(One-stage)目标检测,是一种直接使用卷积神经网络提取特征从而给出目标类别的检测算法。主要以 YOLO 系列、SSD 算法为代表。

YOLO 系列属于一阶段的目标检测算法,采用了一种网格划分的思想,将输入图像划分成多个固定大小的网格单元,并在每个单元上预测目标的边界框和类别。这样的设计使得 YOLO 算法在处理速度上非常快,适用于实时目标检测。YOLO 还采用了全局上下文信息,通过将图像的整体信息融入到预测中,有助于更好地理解图像中的目标。此外,YOLO 算法还引入了多尺度预测,通过在不同层级的特征图上预测目标,可以更好地处理不同尺度的目标。图 2-7 展示了 YOLO 算法在目标检测任务中的简明检测流程。




图 2-7 YOLO 系列算法检测流程简图

该算法首先调整输入图像的大小,再输入到卷积神经网络,在确定阈值范围后获得预测的目标。公式(2-6)表示边界框置信度的计算,置信度表示 YOLO 算法模型预测得到的边界框与图中目标的真实标注边界框之间的重合程度。然后,

应用非极大值抑制算法(NMS)来消除低于阈值的边界框，以得到预测结果。YOLO 算法采用单次处理图像中的所有特征来对可能的边界框进行预测。第 1 代 YOLO 算法的网络设计如图 2-8 所示。

$$Pr(Class_i | Object) \times Pr(Object) \times IOU_{pred}^{truth} = Pr(Class_i) \times IOU_{pred}^{truth} \quad (2-6)$$




图 2-8 YOLOv1 网络结构

在 YOLO 模型的网络训练过程中，通常使用真实目标和预测目标之间的均方和误差来作为损失函数，用于卷积网络模型的参数优化。YOLO 模型的损失函数如公式(2-7)所示，其中 L_{cls} 、 L_{obj} 和 L_{box} 分别表示预测目标时的分类损失、置信度损失和坐标位置损失。

$$LOSS = L_{obj} + L_{cls} + L_{box} \quad (2-7)$$

考虑到三种损失对网络 LOSS 的贡献不同，YOLO 算法使用 $\lambda_{coord}=5$ 来调整位置损失，并使用 $\lambda_{noobj}=0.5$ 来调整置信度损失。经过修正后的 LOSS 计算公式如式(2-8)所示。

一阶段目标检测算法在输入图像的不同位置和尺度上同时进行目标检测，无需先生成候选区域再进行分类和位置精修。一阶段算法采用端到端的训练方式，直接从原始图像到目标检测结果，简化了训练过程，能够更好地优化模型。并且由于没有候选区域生成的额外开销，一阶段算法通常具有更快的处理速度，特别适用于实时应用或对速度要求较高的场景。在满足即时任务(如交通监控、自动驾驶等)要求实时性的同时，获得了不错的检测性能。在工业化的缺陷检测任务中，通常需要考虑到算法的精度和速度的综合表现，基于回归分析的一阶段算法

更适用于工业化缺陷检测任务。

$$\begin{aligned}
 LOSS = & \lambda_{coord} \sum_{i=0}^{s^2} \sum_{j=0}^B \gamma_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\
 & \lambda_{coord} \sum_{i=0}^{s^2} \sum_{j=0}^B \gamma_{ij}^{obj} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] + \\
 & \sum_{i=0}^{s^2} \sum_{j=0}^B \gamma_{ij}^{obj} (C_i - \hat{C}_i)^2 + \lambda_{noobj} \sum_{i=0}^{s^2} \sum_{j=0}^B \gamma_{ij}^{obj} (C_i - \hat{C}_i)^2 + \\
 & \sum_{i=0}^{s^2} \gamma_{ij}^{obj} \sum_{c \in classes} [P_i(c) - \hat{P}_i(c)]^2
 \end{aligned} \tag{2-8}$$

2.4 注意力机制原理

注意力机制理论正在逐渐成为深度学习领域中的一项重要技术,用于加强关键信息弱化无用信息,从而提高算法效率。注意力模型发展可以分为四个阶段:空间注意力、通道注意力、通道与空间混合注意力以及自注意力。2014 年有学者提出递归神经网络 RAM^[42],该网络包含了空间注意力机制。RAM 核心思想是有选择地将注意力集中在输入图像的不同区域,使模型能够从图像的不同部分捕捉相关信息,将来自不同区域的相关细节信息进行组合。通过多次提取局部特征,网络会通过迭代关注不同区域的组合信息来完善其对图像的表征。

通道注意力机制是另一种特定的架构机制,其功能是选择性地关注和增强图像中特定类别特征的表示。通道对应于捕捉输入数据特定方面的不同卷积核或特征映射。该机制使用通道间权重来衡量卷积特征映射中不同通道的重要性,通道间权重的大小代表通道间的相关性水平。通过对通道间的相关性进行学习,并对通道的特征进行自适应加权,能有效加强有用特征的贡献,同时抑制了不太相关或无用的特征。2018 年 CVPR 会议论文中首次提出通道注意力机制网络结构 SE-Net^[43],如图 2-9 所示。SE-Net 的目标是通过学习特征权重和强调相关特征的重要性来提高卷积神经网络的性能。其结构包括两个主要部分:压缩和激励,可表示为公式(2-9)。压缩部分使用全局平均池化操作将原始特征图 $H \times W \times C$ 压缩为全局特征向量 $1 \times 1 \times C$ 。激励部分放大特征图中最重要区域的权重,同时忽略无关部分。通过使用带有激活函数的全连接层来实现这一目的,其结果为向量 s 。压

缩部分获得的全局信息 z 被用作特征权重。然后将这些权重应用于原始特征图，以放大有用特征的重要性。




图 2-9 SE-Net 注意力机制原理图

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j)$$

$$s = \sigma(W_2 \delta(W_1 z)) \quad (2-9)$$

$$x_c = s_c u_c$$

通道与空间混合注意力旨在同时捕捉通道和空间信息，使模型能够同时关注通道(特征图)和空间维度(特征图的宽度和高度)的重要特征。2018 年 ECCV 会议论文中提出通用且轻量级的卷积注意力模块 CBAM^[44]，如图 2-10 所示。其核心思想是让特征图依次通过 CAM(Channel Attention Module) 通道注意力模块和 SAM(Spatial Attention Module)空间注意力模块，利用卷积操作将跨通道的信息和不同空间的信息进行融合。其公式可表示为式(2-10)。




图 2-10 CBAM 注意力机制原理图

$$M_c(F) = \sigma(MLP(AvgPool(F))) + \sigma(MLP(MaxPool(F)))$$

$$= \sigma(W_1(W_0(F_{avg}^c))) + \sigma(W_1(W_0(F_{max}^c)))$$

(2-10)

$$M_s(F) = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)]))$$

$$= \sigma(f^{7 \times 7}([F_{avg}^c \cdot F_{max}^c]))$$

自注意力机制(Self-Attention)^[45]是自然语言处理中的一个关键机制，在Transformer架构中也有显著的体现，从根本上围绕着动态权衡序列中不同元素的重要性展开。计算机视觉中的自注意机制是从自然语言处理中的成功应用中改良而来，主要思想包括为特征图中的每个位置生成查询、关键和值表示，使网络能够在处理过程中动态调整局部和全局特征的重要性。

2.5 汽车流水灯缺陷检测策略整体技术路线

汽车流水灯在应用中常有转向灯或装饰灯等多种用途，因此流水灯的制造并无行业内的统一标准。这直接导致了市面上的汽车流水灯有着品种繁杂的款式，不同款式的流水灯有不同的亮灯特点。并且，同一种款式的流水灯也可能有着不同的缺陷形式。汽车流水灯缺陷类型示例如图 2-11 所示。




图 2-11 复杂的流水灯缺陷形式

种类繁杂的汽车流水灯款式，直接导致了传统模板匹配方法难以利用单个模板同时识别不同的流水灯缺陷。针对每一种流水灯款式，需要创建专门的匹配模板。甚至，对于同一款流水灯，也需要创建多个模板来适应不同的缺陷形式。这种情况直接降低了流水灯工业化生产的检测效率。对于流水灯的工业化检测方法，需要有一定的精确度和速度，以及具备对于不同缺陷类型的鲁棒性。汽车流水灯缺陷具有复杂多变的特点，伴随着流水灯款式的不断增加，缺陷的类型也在逐渐复杂。如何利用单个模型对不同类型的流水灯缺陷进行准确识别，成为了有待解决的实际问题。因此，需要研究能通过训练单个模型实现对多种不同流水灯缺陷进行精准识别的方法。除了算法的设计外，还需要考虑模型在工业化的环境中是否适用。

专门适用于汽车流水灯缺陷的目标检测算法是整套缺陷检测策略的重中之重，所有的缺陷检测任务最终都将归为目标检测任务。当前适合汽车流水灯缺陷

的目标检测方法较少,且对于多种不同款式流水灯的缺陷特征适应能力并不理想,特别是对于流水灯灯光缺陷不明显或尺寸过小时,检测的难度较大。因此,本文提出的汽车流水灯缺陷检测策略包含了两种具有不同优势的方法。策略的整体方案如下图 2-12 所示,整体上可分为基于矩形框的缺陷检测和基于关键点的缺陷检测两大路线分支。在完成了模型的训练以及在台式电脑上验证效果后,再将模型部署到小型嵌入式平台,以满足便捷性的工业化缺陷检测需求。




图 2-12 本文整体技术路线

其中,基于矩形框定位的缺陷检测方法主要是检测缺陷的整体部分,矩形框的细微偏差不会影响到缺陷检测的效果。直接利用矩形框形式来定位缺陷部分的方式更适合通过单个模型实现对多种不同流水灯缺陷进行检测。通过矩形框的形式进行缺陷定位的独特优势在于,即使同时检测数十种不同的目标缺陷,通过矩形框定位的方式仍能识别出汽车流水灯的缺陷部分。基于关键点定位的缺陷检测方法主要是检测缺陷部分的某个特定点的位置。关键点定位的重点在于获得缺陷部分的关键点坐标,这种定位形式对于缺陷部分的位置检测更加精确。并且通过对关键点标注位置的设定,能够识别出流水灯缺陷部分的具体形状。小型嵌入式平台模型部署主要针对工业化的应用需求,完成汽车流水灯检测模型从实验室设计到实际工程应用的对接。在选用嵌入式平台时,需要考虑深度学习模型的兼容

性以及嵌入式平台的便捷性。本文选用了深度学习目标检测算法中速度和精度均较为优异的 YOLOv7 算法^[46]来作为基础算法进行深入研究。

2.6 本章小结

本章主要分析了本文用于汽车流水灯缺陷检测的相关基础理论。首先，对流水灯缺陷检测任务所面临的问题进行分析，并探究了缺陷检测系统的整体方案。随后，详细论述了基于深度学习的流水灯缺陷识别基础原理，包括卷积神经网络的整体概念以及各个组成部分的具体功能，并对当前主流的深度学习目标检测算法以及常用的注意力机制模块进行总结。最后，对本文的汽车流水灯缺陷检测策略的技术路线进行详细论述。

第3章 基于矩形框定位的缺陷检测方法

汽车流水灯有着繁杂多样的款式，其缺陷形式也不胜枚举。利用传统方法难以用单个模型完成对多种缺陷目标的精确检测，故本章采用了深度学习算法完成汽车流水灯缺陷检测任务。本章选用了 YOLOv7 目标检测算法，通过矩形框定位的方式识别出流水灯缺陷的整体部分，并在原网络结构的基础上进行改进。通过实验分析，验证了改进后的算法在流水灯缺陷检测任务中的优异性能。

3.1 YOLOv7 矩形框定位算法

YOLO 系列算法在 2016 年首次被提出，全称是 You Only Look Once。YOLO 算法把目标检测问题当作回归问题处理，采用单个神经网络就能直接预测目标边界框和分类概率，实现端到端的目标检测。YOLOv7 在 2022 年 7 月份被提出，该版本的论文称在 5FPS 到 160FPS 的每秒帧数范围内，YOLOv7 的精度和速度都超过了当前已知的其他目标检测算法，网络结构如图 3-1 所示。




图 3-1 YOLOv7 网络结构图

与大多数目标检测算法一样，YOLOv7 的网络结构也可以分为 Backbone、Neck 和 Head 三部分。YOLOv7 以不同的模块为单位构造了整个网络，其中 CBS

模块由卷积操作、正则化和激活函数组成,MP 模块由 CBS 模块和最大池化组成。ELAN-1 和 ELAN-2 模块是 YOLOv7 主要计算模块,负责提取特征,结构图如图 3-2 所示。




图 3-2 ELAN 模块结构图

在输入部分,彩色三通道图片的尺寸会被统一裁剪成 640×640 的大小。

在 Backbone 部分,不同于其他算法直接应用已有的主干网络结构设计,YOLOv7 用 4 个 ELAN-1 模块完成 Backbone 部分的主要特征提取任务,最后的 3 个 ELAN-1 模块经过通道数修改后输出到 Neck 部分。

在 Neck 部分,YOLOv7 采用了特征金字塔结构,利用 1 个 SPPCSPC 模块和 4 个 ELAN-2 模块实现特征提取功能,右侧 3 个 ELAN-2 模块直接输出到 Head 部分。

最后,网络输出 3 个检测头,输出特征图尺寸分别为 20×20 、 40×40 和 80×80 ,图中从上到下分别对应大目标、中等目标和小目标的优先识别。

3.2 改进矩形框定位算法的相关模块机理分析

1、 $g^n\text{conv}$ 递归门控卷积

递归门控卷积通过门控卷积和递归结构设计实现高效、可扩展和平移等变的高阶空间交互,并将自注意力中的二阶交互扩展到任意阶,而不会引入大量额外的计算,精度会随着空间阶数的增大而升高。结构如图 3-3 所示。

原作者提出的 $g^n\text{conv}$ 包括两个核心概念^[47]: (1)门控卷积,令 $x \in R^{HW \times C}$ 是输入特征,门控卷积的输出 $y = g^n\text{conv}(x)$ 可表示成公式(3-1),其中 ϕ_{in} 和 ϕ_{out} 是用于实现通道融合的线性投影层, f 是深度可分离卷积; (2)将多个门控卷积利用递归结构进行循环设计,即将特征进行逐阶相乘操作,通过这种递归设计的特征可以保留更多的高阶信息。




图 3-3 递归门控卷积原理图

$$[p_0^{HW \times C}, q_0^{HW \times C}] = \mathcal{O}_{in}(x) \in R^{HW \times 2C}$$

$$p_1 = f(q_0) \odot p_0 \in R^{HW \times C} \quad (3-1)$$

$$y = \mathcal{O}_{out}(p_1) \in R^{HW \times C}$$

2、GAM 全局注意力机制

大多数注意力机制忽略了保留通道和空间两个方面的信息对增强跨维度交互作用的重要性，论文^[48]提出了一种全局注意力机制，通过减少信息弥散和放大全局交互表示来提高深度神经网络的性能。原作者沿用了 CBAM 中对通道注意力和空间注意力的顺序设计，并重新设计了子模块。GAM 整体结构设计可表示为图 3-4，并可简要表示为公式(3-2)，其中 M_c 和 M_s 分别表示通道和空间注意力模块， $\otimes$ 表示对应元素相乘。




图 3-4 全局注意力机制原理图

$$F_2 = M_c(F_1) \otimes F_1 \quad (3-2)$$

$$F_3 = M_s(F_2) \otimes F_2$$

3、Ghost 幽灵卷积

深度卷积神经网络通常需要大量卷积操作，这导致巨大的计算成本。论文^[49]提出了一种新颖的 Ghost 模块，它可以使用较少的参数生成更多的特征。原理结构图如图 3-5 所示。在 Ghost 模块中，一个原始的卷积层将被拆分成两部分。第 1 部分为普通的卷积操作，提取的特征图的维数将被严格控制。在第 1 部分的原始特征图基础上，通过一系列简单的线性运算生成更多的特征图，以此来实现消除冗余特征。与传统的卷积神经网络相比，在不改变输出特征图大小的情况下，Ghost 模块整体所需的参数和计算复杂度都有所下降。




图 3-5 Ghost 卷积原理图

4、SimAM 无参数注意力机制

针对当前存在的大部分注意力模块都是从输入端产生 1 维或 2 维的参数权重，论文^[50]提出了一种注意力机制，可以直接生成 3 维的参数权重，且无需产生额外的参数。其中，图 3-6(a)为通道注意力，每个参数对应着不同的通道。图 3-6(b)为空间注意力，每个参数分别对应着所有通道的相同位置。图 3-6(c)为 SimAM 注意力原理，相对于单纯的 1 维或 2 维参数结构，3 维的参数权重则同时考虑到了不同特征图之间和同一特征图的细化特征。




图 3-6 SimAM 注意力机制

3.3 改进的 YOLOv7 流水灯缺陷矩形框定位算法

针对汽车流水灯的缺陷特征较为复杂的问题,本文在原算法中加入了递归门控卷积 $g^n\text{conv}$, 以及将多个原 ELAN 模块替换为融入注意力机制的并列结构 ELAN 模块,如图 3-7 所示。旨在进一步提升 YOLOv7 在流水灯缺陷检测中的精确度,使得改进的算法能对不同款式的流水灯有较强的适应性。




图 3-7 改进的 ELAN 模块结构图

在 Backbone 部分,利用本文提出的 ELAN-G 模块替换了 3 个直接输出到 Neck 部分的 ELAN-1 模块。并且,为保留常规卷积对图片的特征提取效果,本章保留了首个 ELAN-1 模块。在 ELAN-G 模块中,本章使用了 GAM 全局注意力机制和 Ghost 卷积。其中, GAM 注意力的特征提取能力较强,同时参数也较多。大多数汽车流水灯的灯珠朝同一方向依次点亮,对于更多不同亮灯方向的流水灯,全局注意力机制能兼顾不同位置的流水灯缺陷目标特征信息,并且能保留更多的有效参数。然而 ELAN-G 模块含有较多卷积操作,在全面提取缺陷特征信息的同时,也会产生大量重复的特征信息。将 Ghost 卷积放在 ELAN-G 模块末尾,先通过普通卷积进行初步特征提取并减少维数,再继续通过一系列简单的线性运算生成更多的特征图,能有效消除冗余的缺陷特征,避免因过多相似的特征信息而增加不必要的参数。在 ELAN-G 的结构上,本章采用并列结构设计。相对于原 ELAN-1 模块结构,并列结构的设计可以使得 Cat 融合的 4 条通路互不相干,能得到输入特征图通过普通卷积操作后的特征,同时能得到通过 GAM 注意力提取的特征,还能保留原始的输入特征。

在 Neck 部分，利用本文提出的 ELAN-S 模块替换了 3 个直接输出到 Head 部分的 ELAN-2 模块。为保留连续常规卷积操作的特征提取效果，本章保留了特征金字塔结构左侧的一个 ELAN-2 模块。如图 3-7 所示，在 ELAN-S 模块中，本章使用了 SimAM 注意力机制。SimAM 的引入不会额外增加任何参数，这使得 ELAN-S 模块相比于原 ELAN-2 模块的参数大幅减少。同时 SimAM 能够关注到通道和空间的参数特征，减小了缺陷特征信息丢失的可能性。在 ELAN-S 的结构上，本章同样采用了并列结构设计，以 CBS 和 SimAM 组成了两条特征提取主通路，并且保留了 ELAN-S 模块的输入特征。这种设计能在保留传统卷积操作优势性能的同时减少网络参数量。

改进的 YOLOv7 算法主体结构图如图 3-8 所示。另外，本章在 SPPCSPC 模块后加入了递归门控卷积模块 $g^n\text{conv}$ ，并直接输出到 CBS 和 cat 模块。递归门控卷积模块的添加有助于进一步增强流水灯缺陷部分的特征提取能力，递归循环设计的阶数越高，进行门控卷积的操作次数就越多。对于不同特点的缺陷，利用递归设计可以在进行门控卷积提取特征之后，继续融合前一步门控卷积提取的缺陷特征，不仅能利用连续的卷积操作提取部分主要缺陷特征，还能避免由于连续卷积操作后的细节特征丢失问题。




图 3-8 改进的 YOLOv7 网络模型结构图

3.4 流水灯缺陷的矩形框定位实验与分析

3.3.1 矩形框定位实验环境及评价指标

本章的实验在 Windows10 系统环境下开展，实验的具体配置是：程序编译软件使用 Pycharm2020，代码解释器为 Python 3.6，深度学习框架采用 Pytorch 1.10.2，CUDA 为 11.2 版本，CPU 型号为 Intel i7-10700，GPU 型号是 NVIDIA GeForce RTX 3060。

由于公开的汽车流水灯缺陷数据集较少，本次实验使用的数据集为自建数据集。所收集的汽车流水灯缺陷图像均拍摄自真实流水灯零部件，包含足够的样本以覆盖不同的流水灯款式和缺陷类型。其中，共拍摄了 920 张带有灯光缺陷的流水灯运行状态图片。由于图片数量不多，模型训练的 batch-size 设置为 2，模型训练至 mAP 基本稳定为止。训练集、验证集和测试集的分配比例为 6:2:2。用于拍摄的相机为海康威视 MV-CA004-10UC 工业相机，部分车灯设备与图像采集装置如图 3-9 所示。



图 3-9 车灯设备与图像采集装置示例

在数据集的标注方面，本章标注了损坏的流水灯部分作为缺陷目标，且由于本文的算法最终将应用到汽车流水灯在运行状态下的实时检测和流水灯的时序检查方面，本章还标注了流水灯依次点亮的头灯部分。因此，本文实验将检测流水灯的缺陷部分和头灯部分两种目标，并选用 Labelimg 作为图片的标注软件。在本文所用的自建数据集中，流水灯的缺陷部分以 LED 灯珠的损坏区域为主，表现形式为单个 LED 灯珠不亮或流水灯灯带的断裂，以及流水灯亮灯模块的部分损坏。

本文实验使用精度(Precision)以及类别平均精度(mean Average Precision, mAP)以及每秒模型可以检测处理的图片数量(Frame per second, FPS)作为评价指标,另外给出了不同模型的训练后权重文件大小作为辅助指标。计算公式分别如式(3-3)所示:

$$\begin{aligned} P &= \frac{TP}{TP + FP} \\ AP &= \int_0^1 P(r)dr \\ mAP &= \frac{1}{n} \sum_{i=1}^n AP_i \end{aligned} \quad (3-3)$$

其中, TP (true positives)表示的是预测结果是正样本并且确实是正样本; FP (false positives)表示的是预测结果为正样本但实际为负样本; FN (false negative)表示的是预测结果为负样本但实际为正样本。正样本表示计算的类型为该类并且计算的边框与真实框的交并比大于某个阈值,若小于阈值或未检测到的则为负样本。

3.3.2 矩形框定位实验结果与分析

为验证改进的 YOLOv7 矩形框定位方法的性能,设计了如下实验。其中,为比较所提算法与其他算法在自建流水灯数据集上的效果,本章开展了对比实验。为分析不同模块对于算法在性能上的贡献,进行了消融实验。为探究本章方法在其它目标检测任务上适用性,利用工件数据集做了对比实验。另外,不同输入图片对模型训练产生的效果有差异,将不同的图片输入尺寸作为变量展开实验。具体实验分析如下。

1、不同算法的对比实验分析

基于所构建的流水灯灯光缺陷数据集,本章将改进的 YOLOv7 网络与其它目标检测网络进行对比实验,包括 YOLOv3、YOLOv4、YOLOv5 和原版 YOLOv7。实验数据如表 3-1 所示,其中 Ours 表示改进的 YOLOv7 网络。由表中数据分析可得,改进的 YOLOv7 精度最高,达到了 89.7%,相对于原版 YOLOv7 提升了 4%,相对于 YOLOv3、YOLOv4 和 YOLOv5 分别提升了 16.2%、9.5%和 8.9%。原版 YOLOv7 的速度最快,达到了 72.46 fps,同时原版 YOLOv7 的参数权重文件最小,只有 71.5MB。但改进的 YOLOv7 在速度方面仍然比 YOLO 系列其它

算法有着明显优势，且权重文件也较小，更适合部署到嵌入式系统。

表 3-1 不同算法的对比实验效果

Model	Weight/(M)	mAP@0.5	mAP@.5:.95	FPS
YOLOv3	118	73.5%	50.9%	41.32
YOLOv4	244	80.2%	42.1%	42.96
YOLOv5	88.7	80.8%	56.8%	47.62
YOLOv7	71.5	85.7%	57.7%	72.46
Ours	72.8	89.7%	62.9%	61.35

由此可知，综合考虑模型的检测精度与速度，相比于改进前的模型以及三种常用 YOLO 系列目标检测模型，改进后的 YOLOv7 能够在保证检测速度的前提下拥有较高的精度；相较于原版 YOLOv7，改进后的模型参数权重变大，在检测速度上不具有竞争力，但拥有更高的检测精度。因此，综合以上分析可知，改进后的 YOLOv7 实现了检测速度和检测精度的平衡，在保证流水灯缺陷检测过程中实时性的同时提高了检测准确度，更适用于汽车流水灯的工业化缺陷检测任务。

如图 3-10 所示，图中展示了 6 种不同款式汽车流水灯的缺陷检测效果。对于多种不同特点的流水灯灯光缺陷，所提方法均能准确识别出来，并区分类别。同时还能进行头灯部分的追踪识别。由此证明，所提出的方法能够通过训练一个深度学习模型，同时对多种不同特点的灯光缺陷进行精准识别，实现高效率的汽车流水灯缺陷检测。




图 3-10 缺陷检测效果图

2、不同模块的消融实验分析

为研究不同的模块对于模型的性能贡献,本文基于自建的流水灯缺陷数据集进行消融实验,主要探究单独添加 ELAN-G、ELAN-S 和 $g^n\text{conv}$ 模块对模型性能的作用,其中 ELAN-G 模块融合了 Ghost 卷积和 GAM 注意力机制,ELAN-S 模块融合了 SimAM 注意力机制。实验数据如表 3-2 所示。由表中数据分析可知,加入了 $g^n\text{conv}$ 门控递归卷积模块后,模型参数量明显增加,保留了更多有效信息,权重文件大小增加了 5.8M,此时图片推理速度变慢,但精度有 0.2%的微小提升。加入了 ELAN-S 模块后,由于 SimAM 注意力机制的无参数特性,模型的权重文件大小减小了 2.8M,此时图片推理速度显著提升,但精度有所下降。加入了 ELAN-G 模块后,由于全局注意力机制的作用,模型的特征提取能力有所增强,识别精度的提升较为明显。同时因网络层数的加深,图片推理速度有所降低。但由于 Ghost 卷积能有效减少参数,此时的模型参数权重文件仍小于原模型的权重。在融合了所有模块后,改进的 YOLOv7 模型的权重文件变大,图片推理速度有所下降,但在精度上有明显提升。

表 3-2 不同模块的消融实验效果

Model	Weight/(M)	mAP@0.5	mAP@.5:.95	FPS
YOLOv7	71.5	85.7%	57.7%	72.46
YOLOv7- $g^n\text{conv}$	77.3	85.9%	59.2%	68.49
YOLOv7-SimAM	68.7	85%	58.2%	76.34
YOLOv7-GhostConv+GAM	69.8	87.3%	61.2%	64.94
Ours	72.8	89.7%	62.9%	61.35

3、算法通用性的实验分析

为进一步验证本章所提的改进 YOLOv7 网络的在不同任务上的性能,本节将本章改进的模型与其他网络在金属工件数据集上进行对比实验。所用到的金属工件数据集包含 1084 张图像,有六种待检测工件,在不使用预训练权重的情况下进行训练。六种工件有着不同的形状和大小,能够验证所提方法对于不同特点检测目标的泛化性。工件数据集对比实验数据如表 3-3 所示。由实验数据可知,本文所提算法在工件数据集上比原 YOLOv7 算法有 1.3%的提升,同时优于另外三种比较算法,由此可证明本章所提的算法在流水灯缺陷检测以外的领域同样有

效，但对精度的贡献不明显，原因为所提算法对于汽车流水灯的缺陷特征有着更强的针对性。

表 3-3 利用工件数据集验证算法通用性的实验效果

Model	Weight/(M)	mAP@0.5	FPS
YOLOv3	117	55%	37.59
YOLOv4	244	69.91%	42.39
YOLOv5	237	63.1%	23.04
YOLOv7	71.3	75.9%	60.98
Ours	72.6	77.2%	56.82

4、不同尺寸输入图片的模型效果实验分析

不同尺寸的图片在输入进模型进行处理前会被统一裁剪成相同的尺寸，不同的输入尺寸对应着不同大小的输出特征图尺寸。为比较不同的图片输入尺寸对模型检测精度和速度的影响，设计了不同图片输入尺寸的模型效果对比实验。YOLOv7 的原定输入尺寸是 640×640 ，额外加入了 512×512 和 800×800 两种输入大小作为对比。其中三个不同的输入尺寸所对应的输出特征图尺寸如表 3-4 所示，其模型训练效果如表 3-5 所示。

表 3-4 输入图片尺寸与输出特征图尺寸的对应关系

输入尺寸	512×512	640×640	800×800
	16×16	20×20	25×25
输出尺寸	32×32	40×40	50×50
	64×64	80×80	100×100

表 3-5 不同输入图片尺寸的模型实验效果

输入尺寸	mAP@0.5	mAP@.5:.95	FPS
512×512	85.8%	58.2%	63.29
640×640	89.7%	62.9%	61.35
800×800	87.8%	60.5%	43.86

由表 3-5 可知，当输入尺寸为 512×512 时，图片的处理速度最快。因输入图

片的尺寸越小,图片在计算机中进行卷积计算的次数越少,图片处理的速度越快。但在精度方面,640×640 的图片输入尺寸有着最高的精度。通常情况下,输入图片的尺寸越大,意味着输出的三个特征图尺寸越大,能够保留更多的细节信息,大多时候对识别准确度的提高有正向作用。在本实验中输入尺寸越大精度变低,推理原因为输入 640×640 尺寸得到的输出特征图尺寸更加符合自建数据集的缺陷大小。

3.5 本章小结

为应对汽车流水灯缺陷复杂多样的特点,本章在 YOLOv7 网络的基础上提出了一种改进的 YOLOv7 网络模型,用矩形框的形式定位汽车流水灯缺陷的整体范围。为了增强特征提取能力和保留更多有效信息,在模型中加入了 $g^n\text{conv}$ 门控递归卷积和 GAM 全局注意力机制。为了减少信息冗余和避免信息丢失,在模型中加入了 Ghost 卷积和 SimAM 无参数注意力机制。并修改了原 ELAN 模块的结构,提出融合了注意力机制的并列结构 ELAN 模块。实验结果表明,改进的 YOLOv7 在汽车流水灯缺陷检测任务上的精度达到了 89.7%,能够满足实际工业化检测的准确度要求。同时还比较了在不同图片输入尺寸下模型训练的检测结果。

第4章 基于关键点定位的缺陷检测方法

矩形框的定位形式适用于同时检测多种流水灯缺陷的整体部分,但难以检测出缺陷部分的具体位置与形状。本章提出了一种通过定位关键点的方式精确检测汽车流水灯缺陷的方法。本章节在传统的YOLOv7关键点定位算法的基础上,提出了更适用于汽车流水灯缺陷检测的关键点定位算法,并通过实验分析验证了该算法的优异性能。

4.1 YOLOv7 关键点定位算法

当涉及到用深度学习方法识别关键点时,通常是指在计算机视觉任务中,比如人脸识别、姿态估计或手势识别中,使用深度学习算法来自动检测和定位物体或人体的关键点位置。深度学习方法能够有效识别出关键点位置,主要有以下几个原因:大规模数据集的训练、神经网络的多层结构、卷积神经网络(CNN)的使用和目标函数的设计。

YOLOv7 关键点定位算法与传统YOLOv7 目标检测算法有着相同的网络结构。其区别在于,YOLOv7 关键点网络在传统YOLOv7 目标检测网络的基础上增加了预测关键点的输出信息。且训练的标注数据集除了有待测目标的整体位置,还需关键点的位置坐标。关键点检测旨在检测图像中的特定关键点或局部结构,相比之下,普通目标检测更侧重于检测和定位整个物体或物体的边界框。因此,关键点检测能够提供更精细的定位信息,对于需要准确关注物体内部结构的任务具有独特的优势。

深度学习算法之所以能够识别出关键点信息,是因为卷积神经网络模型能够从大规模数据中学习到关键点的模式和特征,并通过多层神经网络的特征提取和卷积神经网络的局部感知能力,逐渐提取出关键点的位置信息。相对于直接对目标进行整体范围检测,通过识别缺陷部分的关键点还具备两个功能属性:(1)对不同特点的流水灯缺陷部分进行精确形状定位;(2)测量角度误差。目前已有吕硕等人^[51]通过检测螺栓关键点的坐标来计算螺栓的角度误差,进而判断螺栓是否松动。

4.2 改进关键点定位算法的相关模块机理分析

1、SPPCSPC 结构

空间金字塔池化(Spatial Pyramid Pooling, SPP)是一种用于图像特征提取的方法，空间金字塔池化的原理是在不同尺度上对图像进行分割，并对每个分割区域进行池化操作，以捕捉图像中不同尺度下的局部信息。SPP 使得特征提取具有尺度不变性和局部感知能力，从而提高图像识别、目标检测等任务的性能。SPP 的结构如图 4-1(a)所示。由图可知，SPP 有四条通路。其中三条通路为最大池化操作，第 4 条通路为特征映射。三个池化操作各自有着不同大小的卷积核，分别进行运算。第 4 条通路没有特征提取的功能，目的是保留特征图的输入信息，避免因过多的池化操作而丢失原本有效的信息。图中的 Conv 表示一次卷积操作，作用是调整输入特征图的通道数。在所有卷积操作之后，四条通路的特征信息通过 Concat 操作进行叠加，在图中表示为 cat。




图 4-1 SPP 与 SPCCSPC 结构

以 SPP 模块为基础，并借鉴 CSP 结构，SPCCSPC 模块在 YOLOv7 中首次被应用。SPCCSPC 模块结构如图 4-1(b)所示，模块首先将 Backbone 中提取的特征分为 SPP 和常规卷积操作两部分。SPP 结构有 4 条分支，分别对应池化核大小为 5、9、13、1 的最大池化操作，这 4 种不同大小的最大池化操作，使得 SPCCSPC 结构能够处理 4 种不同的感受野对象，能够更好地区分小目标和大目标。最后将

这两部分合并在一起，进行 Concat 操作，从而使得模型减少了大量计算，模型的速度更快、精度更高。

SPPCSPC 与 SPP 的区别在于其结合了空间金字塔池化和上下文感知的空间金字塔卷积，并在 SPP 基础上多使用一个卷积。SPPCSPC 引入了上下文感知的空间金字塔卷积操作，能够更好地捕捉全局和上下文相关性。相对于传统的 SPP 结构主要关注局部区域，SPPCSPC 通过考虑不同尺度的上下文信息，使特征提取更具全局性和上下文感知能力。由于 SPPCSPC 结合了多尺度的信息，并且考虑了全局和上下文关系，它对于尺度变化较大、背景复杂的图像场景具有更强的鲁棒性且能够提供更准确和可靠的特征表示。

2、PConv 部分卷积

为了设计运行速度更快的神经网络，许多学者都致力于减少浮点运算 (FLOPs) 的数量。然而，研究人员观察到，仅仅是通过减少 FLOPs 并不一定导致延迟相似度的减少，主要的原因在于每秒浮点运算效率太低。为了实现更快的网络运算，有相关学者重新研究了常用的卷积操作，并证明 FLOPs 过低主要是由于卷积操作的频繁地访问内存，特别是深度卷积操作。因此，Chen 等人^[52]提出了一种新颖的部分卷积(PConv)作为一种具有竞争力的深度卷积替代方案，既减少了计算冗余，也减少了内存访问的次数。图 4-2 展示了 PConv 的结构设计。图中，两边的长方体表示输入或输出特征图，中间的长方体表示不同尺寸的卷积核。PConv 利用特征图中的冗余信息，并仅对部分输入通道应用常规卷积(Conv)，而保持其余部分不变。从本质上讲，与常规的 Conv 相比，PConv 的 FLOPs 更低。从设备计算能力的角度进行比较，PConv 相对于常规卷积更好地利用了设备的计算能力。PConv 能通过仅对少量输入通道进行卷积运算，并保持其余通道不变，从而实现了快速高效的卷积操作。并且，PConv 的浮点操作数(FLOPs)比常规卷积更低。常规卷积的 FLOPs 计算可表示为式(4-1)，PConv 卷积的 FLOPs 可以表示为式(4-2)。

常规卷积 FLOPs:

$$h \times w \times k^2 \times c^2 \quad (4-1)$$

PConv 卷积 FLOPs:

$$h \times w \times k^2 \times c_p^2 \quad (4-2)$$

其中, h 、 w 和 k 分别表示特征图的高、宽和维度。 c 和 c_p 表示对于连续或规则的内存访问, 将第 1 个或最后一个连续的 c_p 通道视为计算整个特征图的代表。这种设计仅对输入通道的一部分应用常规的卷积进行空间特征提取, 并保持其余通道不变。其中, $c_p:c = 1:4$ 。因此, PConv 的 FLOPs 只有常规卷积的 $\frac{1}{16}$ 。经验证后, 作者还发现 PConv 在提取空间特征方面也非常有效。




图 4-2 PConv 卷积结构

3、ResPC 卷积计算模块

本章提出了全新的卷积计算模块, 并把它命名为 ResPC, 用来作为关键点检测网络的主要特征提取模块。在这个模块的整体构造中, 借鉴了残差网络的结构设计, 如图 4-3 所示。残差网络(ResNet)^[53]是一种深度学习中的重要架构, 用于解决深层神经网络中的梯度消失和爆炸问题。随着神经网络的发展, 传统的网络结构往往面临训练困难和性能瓶颈的挑战。这些问题主要是由于网络层数的增加导致梯度在反向传播过程中逐渐衰减或增长过大, 从而导致难以有效更新网络参数。为了解决这一问题, ResNet 引入了残差学习的思想, 允许网络层跳过一定数量的非线性变换, 直接将输入特征与输出特征相加。这种设计不仅能够解决梯度消失和爆炸问题, 还能够促进网络的收敛和提高模型的表达能力。

在 ResNet 中, 残差块是构建网络的基本单元, 充分利用了跳跃连接(identity)来实现残差学习。跳跃连接允许输入特征直接流经网络中的特定层, 而不是经过一系列的非线性变换。这种直接的连接路径使得网络可以更轻松地学习到残差信息, 避免了梯度的衰减和爆炸。具体而言, 一个典型的残差块由两个卷积层组成,

分别为主路径和跳跃连接。主路径包含了一系列的卷积层和批归一化层，用于提取输入特征的高级表示。在主路径的末端，会通过一个批归一化层对提取的特征进行归一化处理，以加速网络的训练和收敛。而跳跃连接则直接将输入特征添加到主路径的输出中，形成了残差结构。




图 4-3 残差网络结构

本章提出的 ResPC 模块的结构如图 4-4 所示。ResPC 整体上主要由三个 PCmodule 堆叠组成，并包括了一路恒等映射。PCmodule 模块包括了一组常规卷积模块和一组 PConv 卷积模块。输入和输出的关系可以表示为式(4-3)。




图 4-4 ResPC 模块结构

$$x_{i+1} = x_i + P^3[F(x_i)] \quad (4-3)$$

其中, x_i 和 x_{i+1} 分别表示 ResPC 模块的输入和输出特征图。 $F(x)$ 表示 PCmodule 模块的所有操作，包括常规卷积、PConv 卷积以及恒等映射。 $P^3[x]$ 则表示三个 PCmodule 的嵌套。PCmodule 同样采用了残差结构的设计，并包含一个 CBS 和一个 PConv。在原 YOLOv7 网络中，ELAN 模块被作为基本的卷积计算模块。

与 ELAN 模块一样，ResPC 能够在网络中即插即用。相对于 ELAN 模块，ResPC 有着更深的网络层数。并且由于包含了一个 PConv，避免了在加深网络层数时导致参数量暴涨。ResPC 可以作为 ELAN 的替代方案，被用于深度卷积神经网络的搭建。

4.3 改进的 YOLOv7 流水灯缺陷关键点定位算法

PANet(Path Aggregation Network)^[54]是一种用于深度学习中的目标检测任务的网络结构，它在 FPN(Feature Pyramid Networks)^[55]的基础上扩展了特征融合的能力。PANet 的设计目标是解决 FPN 在多尺度特征融合上的不足，特别是处理小目标时容易丢失细节信息的问题。由图 4-5 所示，PANet 引入了自顶而下的路径并进行多次迭代的特征融合，这样可以通过多个阶段的融合过程，逐渐提高特征的表达能力和细节保留能力。相比之下，FPN 只进行了一次自顶而下的特征融合。由于多次迭代的融合过程，PANet 相对于 FPN 在处理小目标时具有更好的性能。传统的 FPN 在处理小目标时容易丢失细节信息，而 PANet 通过多次迭代的特征融合可以更好地保留和利用细节信息，提高小目标的检测和分割准确性。




图 4-5 特征金字塔结构

本章提出的汽车流水灯关键点检测网络 YOLO-kpt 如图 4-6 所示。YOLO-kpt 沿用了 YOLOv7 的 PANet 整体网络框架，有助于在不断地卷积计算中能有更高的特征提取效率。传统的 YOLOv7 使用了 1 个 SPPCSPC 模块，但同时使用 2 个 SPPCSPC 模块对增强特征提取能力有帮助。因此 YOLO-kpt 在 Neck 部分靠近 BackBone 的一侧使用了两个 SPPCSPC。YOLOv7 在 Head 部分使用了三个 RepConv 模块，YOLO-kpt 继续沿用了这一设计。本章提出的 ResPC 模块将作为

主要的卷积计算模块。ResPC 兼具了 ResNet 结构避免梯度消失的优点，以及 PConv 快速运算的优点。




图 4-6 YOLO-kpt 关键点网络结构

YOLO-kpt 网络使用本章提出的 ResPC 模块作为主要的卷积计算模块。其中，在 Backbone 部分使用了 4 个 ResPC 模块，在 Neck 部分使用了三个 ResPC。ResPC 的使用保证了 YOLO-kpt 网络在模型训练时拥有高效的缺陷特征提取能力。YOLO-kpt 的损失函数由五个部分组成，可以表示为公式(4-4)。式中的 L_{obj} 、 L_{cls} 和 L_{box} 分别表示预测目标整体的置信度损失、分类损失和位置损失。 L_{kpt} 和 L_{kcls} 分别表示预测关键点的偏移损失和分类损失。

$$LOSS = L_{obj} + L_{cls} + L_{box} + L_{kpt} + L_{kcls} \quad (4-4)$$

其中，关键点的偏移损失 L_{obj} 参考了 oks 关键点评价指标相似的计算方式。oks 的表达式可以表示为式(4-5)：

$$oks = e^{\left(-\frac{d_i^2}{2s^2k^2}\right)} \quad (4-5)$$

其中， d_i 为第 i 个关键点的欧式距离， s 为物体尺寸的缩放比例， k 为常数。

4.4 流水灯缺陷的关键点定位实验与分析

4.3.1 关键点定位实验设置及评价指标

本章实验的硬件设备和深度学习环境与第 3 章的配置相同。在数据集的建立方面，本章选取了多款由 LED 模块组成的汽车流水灯组件，并拍摄了 400 张带缺陷的流水灯运行状态图片。流水灯缺陷的具体部分为两个 LED 模块之间的区域，因此在缺陷部分的前后两个 LED 模块上进行关键点标注，关键点的标注位置如图 4-7 所示。标注关键点数量为 4 个或 6 个点，关键点所围成的区域即为流水灯的缺陷部分。模型训练时的训练集、验证集和测试集的分配比例为 7:2:1。由于拍摄所得的图片数量不多，模型训练的 batch-size 设置为 2，初始学习率为 0.01，优化器权重衰减率为 0.0005。模型训练至损失值基本稳定为止。




图 4-7 流水灯缺陷部分的关键点定位标注示例

关键点检测的效果评估主要取决于预测关键点和真实关键点的位置偏差，因此通过计算预测关键点和真实关键点的距离误差来衡量关键点检测的准确性。本文关键点检测的误差 σ 可以表示为式(4-6)：

$$\sigma = \frac{\sum_{i=0}^m \frac{\sum_{j=0}^n \sqrt{(x_j - x)^2 + (y_j - y)^2}}{n}}{m} \quad (4-6)$$

式中 x_j 和 y_j 分别表示预测关键点的像素坐标， x 和 y 分别表示真实关键点的像素坐标。通过求出预测点和真实点的欧氏距离 $\sqrt{(x_j - x)^2 + (y_j - y)^2}$ ，得 y 到预测关键点和真实关键点的像素误差距离。公式中的 n 表示一张图片中所有的关键点数量， m 表示测试图片的数量，本文的评价指标 σ 表示测试图片中所有关键点的距离误差平均值。

4.3.2 关键点定位实验结果与分析

为验证本章 YOLO-kpt 算法的性能，本章设计了如下实验。其中，为比较所提 YOLO-kpt 算法与其它算法在流水灯缺陷检测上的效果，开展了对比实验。为分析不同的模块对于算法在检测性能上的贡献，进行了消融实验。对于不同的注意力机制与 PConv 在 ResPC 模块中的效果对比，开展了不同注意力机制的效果对比实验。另外对于 YOLO-kpt 网络在其他目标检测任务上是否适用，利用公开数据集进行了对比实验。具体实验及分析如下。

1、不同算法的对比实验分析

基于自建流水灯缺陷数据集，开展了对比实验。对比实验主要验证不同算法对于关键点检测的准确度。对比实验用到的算法包括了 YOLO 系列的目标检测算法，并同时采用了 YOLOv7 的三个不同版本。在进行关键点检测时，预测关键点的坐标是否与实际关键点相一致是评价误差的关键。因此误差 σ 被作为对比实验的评价指标。对比实验的结果如表 4-1 所示。

表 4-1 不同算法的误差对比实验效果

method	σ
YOLOv3	2.7876
YOLOv4	2.6584
YOLOv5	2.5985
YOLOv7	2.5152
YOLOv7-tiny	4.34
YOLOv7-w6	2.0742
YOLO-kpt	1.8383

由表 4-1 可知。YOLOv7-tiny 的误差最大，预测关键点坐标和实际关键点坐标的像素欧氏距离平均值达到了 4.34。此时从关键点检测的角度分析，误差较为明显，难以满足工业化检测的需求。本章提出的 YOLO-kpt 在关键点检测的误差仅为 1.8383，可以满足实际的检测要求。从算法的角度分析，YOLO-kpt 是在 YOLOv7 的基础上提出的。YOLOv7 的误差 σ 为 2.5985，YOLO-kpt 的表现明显由于基准方法 YOLOv7。

2、不同模块的消融实验分析

本文的方法是建立在 YOLOv7 的基础上的，为了验证不同模块对算法的贡献，开展了消融实验。YOLOv7-ResPC 是将原 YOLOv7 的 ELAN 模块全部换成 ResPC 模块。主要目的是验证 ResPC 对算法性能的贡献。YOLOv7-Resblock 是将原 YOLOv7 的 ELAN 修改成和 ResPC 相同的结构，但不加入 PConv。主要是为了验证残差结构的性能。YOLOv7-sppcspc2 表示将原 YOLOv7 的一个 ELAN 模块替换成 SPPCSPC，用于验证同时使用两个 SPPCSPC 的效果。实验结果如表 4-2 所示。相对于原版 YOLOv7，在修改了不同的模块后，YOLOv7 的性能都有细微的提高。

表 4-2 不同模块的消融实验效果

method	σ
YOLOv7	2.5152
YOLOv7-Resblock	2.2585
YOLOv7-ResPC	3.1201
YOLOv7-sppcspc2	2.3729
YOLO-kpt	1.8383

3、不同注意力机制的效果对比实验分析

本文所提出的 YOLO-kpt 中使用了 PConv。为了验证 PConv 的有效性，将 PConv 分别替换成了 CBAM，CA，GhostConv 和 SimAM 进行实验。

实验结果如表 4-3 所示。在将 PConv 分别替换成 CA 和 CBAM 两种注意力后，关键点的检测误差明显增大。将 PConv 分别替换成 GhostConv 和 SimAM 后误差 σ 仍然大于 2。因此，YOLO-kpt 使用 PConv 的效果最好。

4、算法通用性的实验分析

为了验证本章所提算法在不同检测任务上的通用性，用公开的 NWPU VHR-10 数据集来检测 YOLO-kpt 在目标检测上的性能。在这个通用性实验中，一共有 6 种 YOLO 系列的算法参与比较。评价指标主要为 Precision、Recall、mAP 和 FPS。实验结果如表 4-4 所示。分析表中的数据可知，YOLO-kpt 的 mAP 达到 0.837，相对于其他算法有着明显的提升。同时，检测速度可以维持在 54 帧每秒，

可以满足在目标检测任务上的实时性需求。因此，本文提出的 YOLO-kpt 不仅在关键点检测上有着优异的表现，在其他目标检测任务上同样性能优越。

表 4-3 不同注意力机制的对比实验效果

method	σ
YOLO-kpt-CBAM	3.5840
YOLO-kpt-CA	3.3383
YOLO-kpt-GhostConv	2.8762
YOLO-kpt-SimAM	2.1377
YOLO-kpt-PConv	1. 8383

表 4-4 算法通用性实验

method	P	R	mAP@.5	mAP@.5:.95	FPS
YOLOv3	0.626	0.631	0.65	0.373	56
YOLOv4	0.722	0.627	0.676	0.354	58
TOLOR-p6	0.669	0.658	0.703	0.414	51
YOLOv7	0.83	0.707	0.808	0.459	67
YOLOv7-tiny	0.772	0.731	0.773	0.444	97
YOLOv7-w6	0.785	0.734	0.767	0.449	48
YOLO-kpt	0.913	0.772	0.837	0.502	54

5、汽车流水灯缺陷的关键点定位效果

YOLO-kpt 网络对流水灯缺陷部分的关键点定位效果如图 4-8 所示。由图可知，YOLO-kpt 网络对关键点位置的定位非常准确。对于多种不同的流水灯款式，依旧能准确识别出流水灯缺陷部分的关键点位置。图中展示了 4 款汽车流水灯，本章算法精准识别出了流水灯缺陷区域周围的关键点位置。将已经识别出的关键点相连接，所围成的区域内即为汽车流水灯的缺陷部分，如图 4-9 所示。相对于直接用矩形框的形式识别出缺陷区域的整体范围，定位关键点的方式对流水灯缺陷部分的检测更加精准。




图 4-8 关键点定位效果




图 4-9 汽车流水灯缺陷部分定位效果

4.5 本章小结

为精准检测出汽车流水灯缺陷部分的具体位置与形状,本章提出通过定位关键点的方式识别流水灯的缺陷部分。在借鉴 YOLOv7 目标检测算法的基础上,本章提出了适用于流水灯缺陷的 YOLO-kpt 关键点检测网络。通过开展多个实验进行分析,利用预测关键点和实际关键点平均欧氏距离来判断准确度。结果显示,本章关键点定位方法的关键点误差平均欧氏距离仅有 1.8383,均优于其他对比算法,验证了本章所提关键点缺陷定位方法的有效性。

第 5 章 嵌入式平台部署与应用

嵌入式平台相对于训练深度学习模型所用的台式 GPU 服务器有着体积小的独特优势,更适合于工业化的缺陷检测任务。本章选用了英伟达 Jetson Xavier NX 小型嵌入式平台,对本文提出的两种汽车流水灯缺陷检测模型进行模型部署。

5.1 Jetson Xavier NX 嵌入式平台硬件介绍

英伟达 Jetson Xavier NX 嵌入式平台是 Jetson 系列设备的最新型号,体系结构类似于功能强大的 Jetson AGX Xavier。Jetson Xavier NX 拥有精确的多模式人工智能推理能力,是顶级边缘计算设备中的佼佼者。并且将 Xavier 系列的强大功能与 NANO 系列的紧凑设计无缝融合,可高效用于模型开发、测试和轻量化部署。Jetson Xavier NX 模块具有“小尺寸,强性能”的特点,其尺寸较小,仅有 $70\text{mm} \times 45\text{mm}$ 。除此以外,还有较低的功耗,可在 10W 功率下提供 14TOPS 的算力,在 15 W 功率下可提供 21 TOPS 的算力。为了便于开发,许多厂商推出了较多基于该核心模块的开发套件,其核心模块和本章所用到的平台开发套件如图 5-1 所示。




图 5-1 Jetson Xavier NX 核心模块与套件

Jetson Xavier NX 采用了英伟达的自主架构 GPU(Graphics Processing Unit)架构,包括 512 个 NVIDIA CUDA®核心、6 个 Carmel Armv8.2 CPU 内核、5 个图像信号处理器和 2 个视频编解码器。此外,还具有 8GB LPDDR4x 内存、16GB eMMC 存储器和多个接口。Jetson Xavier NX 处理器集成了 64 位英伟达

(NVIDIA®)Carmel ARM 芯片(6 核)、384 核英伟达(NVIDIA®)Volta GPU 和 48 个张量核。另外, Jetson Xavier NX 具有两个 NVIDIA 深度学习加速器。Jetson Xavier NX 包含 8GB 缓存, 128GB 内存, 提供两种功率模式: 10W 和 15W, 算力最高为 21TOPS。Jetson 系列嵌入式平台可为汽车流水灯调试提供出色的低功耗性能和可靠的计算支持。硬件模块和套件的具体参数如表 5-1 所示。

表 5-1 硬件模块和套件的具体参数

名称	型号与参数
尺寸	70x45 mm
CPU	6-core NVIDIA Carmel ARM®v8.2 64-bit CPU 6MB L2 + 4MB L3
GPU	364-core NVIDIA Volta™ GPU with 48 Tensor Cores
显存	8GB/16GB
存储	16 GB eMMC 5.1
功耗	10W/15W/20W
算力	21 TOPS

5.2 嵌入式系统环境搭建

英伟达的 Jetson 系列 GPU 嵌入式平台提供了相对完善的软硬件开发环境, 为二次开发提供了诸多便利, 逐渐成为嵌入式人工智能领域的主流解决方案。本次实验所用到的硬件设备由 Jetson Xavier NX 嵌入式平台和 HDMI 接口显示屏组成。实验设备如图 5-2 所示。

在 Jetson Xavier NX 嵌入式平台上进行开发, 需要进行相关的环境配置。首先需要安装 JetPack SDK, 该 SDK 包括了 Jetson Xavier NX 开发板的驱动程序、CUDA、cuDNN 等开发所需的组件。Jetson Xavier NX 模块内部采用的是 Linux 操作系统, 并且支持多种深度学习框架和工具, 如 TensorFlow、PyTorch、Caffe、MXNet、OpenCV 等。同时, 还集成了 NVIDIA TensorRT 深度学习推理引擎, 可提供高效的深度学习推理加速。JetPack SDK 是 NVIDIA 提供的开发套件, 为模块提供了一体化的软件包, 包含了英伟达 Jetson 系列平台所需的软件工具和驱

动程序的套件，主要用于烧录系统镜像、开发和部署应用程序。JetPack SDK 可以根据不同的应用场景选择不同的软件工具，使硬件与软件充分发挥作用，实现各种功能，同时 JetPack 安装了 CUDA、cuDNN、OpenCV、Python 等软件环境。目前常用的卷积神经网络框架有 TensorFlow、Pytorch 等。本章所搭建的软件环境如表 5-2 所示。



图 5-2 嵌入式平台验证实验设备

表 5-2 软件环境

环境	版本号
Linux 系统	Ubuntu20.04
Python	3.8.10
Pytorch	2.0.0
OpenCV	4.5.4
CUDA	11.4
cuDNN	8.6

其中 Pytorch 为深度学习框架，主要用于卷积神经网络的搭建和训练。CUDA 是英伟达官方提供的计算框架，用于 GPU 加速。cuDNN 是用于卷积神经网络的 GPU 加速库和 NVIDIA 图形处理单元(GPU)的高性能推理库。OpenCV 是用于图像处理的重要工具包。

TensorRT 是英伟达推出的基于 GPU 的推理框架，专门应用于嵌入式计算平台加速推理深度学习模型，完全契合 Jetson Xavier NX 模块。TensorRT 的核心是

一个 C++ 程序库，可帮助模型在英伟达的图形处理器(GPU)上实现加速推理。在英伟达的官方介绍中，基于 TensorRT 加速的应用程序的平均执行速度比纯 CPU 平台快 36 倍。

5.3 汽车流水灯缺陷检测模型部署

5.3.1 基于矩形框定位的模型部署

本文在第 3 章完成了基于矩形框定位的汽车流水灯缺陷识别算法设计，并验证了缺陷定位算法在台式 GPU 服务器上的优异性能。本小节将第 3 章已经训练好的算法模型权重移植到 Jetson Xavier NX 嵌入式平台，在 Xavier NX 系统内进行汽车流水灯的缺陷识别效果测试。由于本节仅为在 Jetson Xavier NX 平台上对算法进行验证，因此无需在 Jetson 系统内对网络模型进行重新训练，只需将在服务器上训练好的程序与所得模型权重移植到 Jetson Xavier NX 系统内对汽车流水灯缺陷部分进行识别。本小节基于矩形框定位的缺陷检测模型在 jetson 平台上的部署实验流程如图 5-3 所示，整体上包括了在 jetson 平台上的缺陷检测效果和工业化应用示例两大部分。其中，前半部分展示了流水灯缺陷检测的效果，比较了模型在 GPU 服务器和 jetson 平台上的精度，并对 TensorRT 的加速效果进行探究。工业化示例部分主要为模型对流水灯 LED 灯珠亮灯次序缺陷的检测应用。




图 5-3 矩形框定位部署实验流程

1、缺陷检测效果

通过矩形框定位的方式识别汽车流水灯的缺陷部分，在容许部分定位偏差存

在的情况下，几乎可以适应所有的流水灯款式。因此，在服务器上所用到的汽车流水灯缺陷数据集同样适用于嵌入式平台。本章从缺陷数据集选取了多种不同的汽车流水灯缺陷，将其放到 Jetson Xavier NX 系统内进行测试。缺陷识别效果如图 5-4 所示。




图 5-4 缺陷检测效果展示

由测试效果可知，基于改进 YOLOv7 的矩形框定位缺陷识别方法模型在小型嵌入式平台上能够准确识别出汽车流水灯灯光缺陷部分，与在服务器上的整体效果相比无明显差异。但由于台式服务器和 Jetson Xavier NX 系统的各项硬件配置不一样，且训练阶段均在台式服务器上完成，故理论上模型在小型嵌入式系统的表现略逊于大型台式服务器。表 5-3 比较了模型在 PC 端的台式 GPU 服务器上和在 Jetson 平台上的缺陷检测精度。由表可知，模型移植到 Jetson 平台上后，精度出现了细微的下降，但相对于流水灯缺陷检测任务而言，模型在 Jetson 嵌入式平台上的表现依旧能够满足实际应用需求。

在速度方面，本章在保证整体精度需求的前提下，开展了 TensorRT 加速推理的性能比较实验。实验结果如表 5-4 所示，在无 TensorRT 加速的条件下，Jetson Xavier NX 平台对单张图片的平均推理时间为 334ms。而有 TensorRT 加速的条件下，对单张图片的平均推理时间仅为 20.1ms，刚好可以达到实时推理的标准。另外，Jetson Xavier NX 嵌入式平台体积更小，在价格上也远低于 GPU 服

务器。因此，Jetson Xavier NX 嵌入式平台更适合用于汽车流水灯的工业化缺陷监控。

表 5-3 GPU 服务器与嵌入式平台的精度对比

设备	模型	mAP@0.5
GPU 服务器	改进的 YOLOv7	89.7%
Jetson Xavier NX	改进的 YOLOv7	89.4%

表 5-4 TensorRT 加速推理速度对比

模型	输入尺寸	推理时间(ms)
无 TensorRT 加速	640×640	334
TensorRT 加速	640×640	20.1

2、工业化应用示例

基于矩形框的缺陷定位方法的用途较为广泛。在汽车流水灯检测方面，不仅能检测出灯光的缺陷部分，同时还能够对流水灯的头灯部分进行追踪，进而为后续检测流水灯亮灯时序错误提供技术支持。该工业化应用示例如图 5-5 所示。




图 5-5 缺陷定位与头灯位置追踪效果

取一组带有灯光缺陷的汽车流水灯连续点亮的图片，在 Jetson Xavier NX 系统内进行检测，同时识别流水灯灯光部分和头灯部分。汽车流水灯灯光缺陷部分和 LED 头灯部分的识别效果如图 5-5 所示，其中蓝色矩形框内为缺陷部分，灰色矩形框内为汽车流水灯依次点亮时的第 1 个 LED 灯珠。可知 Jetson 嵌入式平

台对于同时识别流水灯的缺陷部分和头灯部分有着较高的准确度。在汽车流水灯的工业化缺陷监控过程中，通常利用高速摄像机连续拍摄闪烁中的流水灯，再通过分析图片中的灯珠闪烁位置作为流水灯质量是否达标的判定依据。同时识别缺陷部分和头等部分的作用在于，依次点亮的头灯部分与第 1 个灯珠的相对位置，或与缺陷部分的相对位置，能够判断流水灯灯珠的点亮顺序是否发生时序错误。因此，本文第 3 章提出的通过矩形框定位检测汽车流水灯缺陷的方法，在小型嵌入式平台依然有较好的表现。

5.3.2 基于关键点定位的模型部署

本文在第 4 章完成了基于关键点定位的汽车流水灯缺陷识别算法设计，并验证了缺陷定位算法在台式服务器上的优异表现。本小节将第 4 章已经训练好的关键点定位算法模型权重移植到 Jetson Xavier NX 嵌入式平台上，在 Jetson 系统内对汽车流水灯灯光缺陷的关键点识别效果进行测试。由于网络模型训练的过程已经在台式服务器上完成，只需要把已经训练好的模型权重移植到 Jetson 系统中，再对汽车流水灯缺陷部分进行关键点的定位。实验流程如图 5-6 所示。




图 5-6 矩形框定位部署实验流程

1、缺陷检测效果

通过关键点定位的方式识别汽车流水灯的缺陷，主要是精确识别出灯光缺陷的边缘顶点部分。相对于用矩形框直接定位的方式，定位关键点有着更高的精确度要求。将关键点算法模型移植到 Jetson Xavier NX 嵌入式平台首先需要保证其精确的关键点识别位置。本节从第 4 章用到的缺陷数据集选取了多种不同的汽车流水灯缺陷，并将其放到 Jetson 系统中进行测试。缺陷识别效果如图 5-7 所示。由缺陷位置识别的效果可知，基于关键点的流水灯缺陷识别模型在小型的嵌入式

平台上依旧有着较好的关键点定位精度。




图 5-7 关键点定位缺陷效果

为验证 YOLO-kpt 关键点模型在 Jetson 平台的迁移效果，表 5-5 比较了关键点模型在 PC 端的 GPU 服务器上和在 Jetson 平台上的缺陷检测精度。由表可知，关键点模型移植到 Jetson 平台上后，预测关键点的误差出现了细微的增大，但误差增大的幅度不到 0.1 个像素距离。因此，迁移到 Jetson 平台的关键点模型依旧能够满足关键点定位任务的精确度需求。在关键点定位任务中，对精度的要求远远高于对速度的要求。在使用 TensorRT 加速推理的过程中，会使得模型精度有一定程度的下降。因此，为保证汽车流水灯缺陷的关键点定位准确性，本节的 Jetson Xavier NX 平台验证工作没有对关键点模型进行 TensorRT 加速。

表 5-5 GPU 服务器与嵌入式平台的关键点定位误差对比

设备	模型	误差 σ
GPU 服务器	YOLO-kpt	1.8383
Jetson Xavier NX	YOLO-kpt	1.8927

2、工业化应用示例

在汽车流水灯的质量检测任务中，流水灯在装配过程中出现的角度方向偏差也是汽车流水灯缺陷的一种形式。基于矩形框定位的方式识别汽车流水灯缺陷，只能识别灯光缺陷的整体部分。然而，通过关键点定位的方式识别汽车流水灯缺陷，可以得到较为准确的关键点坐标。这种方式不仅能够定位出流水灯灯光的缺陷部分，还能通过坐标点的位置计算出流水灯的亮灯方向，进而判断流水灯的装配角度偏差是否符合标准。

图 5-8 展示了基于关键点定位的方法在汽车流水灯的装配角度偏差测量的应

用示例。右侧图中的数字为预测关键点坐标的 x 、 y 值。将单个缺陷模块的关键点分为三组，通过计算每一组中两点连线的方向角度，求出平均角度。得出的平均角度为流水灯亮灯方向上的角度的预测值。将预测值与流水灯装配角度的误差范围阈值相比较，超出一定的误差范围则判定为存在亮灯角度方向缺陷。




图 5-8 利用关键点坐标检测装配角度

以图 5-8 为例，将检测出的 6 个关键点按照 1-2、3-4 和 5-6 这三个分组进行连线。经计算得出 1-2 组的角度方向为 179.58 度，3-4 组的角度方向为 181.13 度，5-6 组的角度方向为 179.85 度。将三组求得的角度求平均数，得到这条流水灯亮灯方向的角度预测值为 180.18 度。取 0-2 度为角度误差合理范围，汽车流水灯的装配方向规定为 180 度，则该条流水灯的角度误差符合要求。

5.4 本章小结

本章主要验证了基于矩形框定位和基于关键点定位的汽车流水灯缺陷识别算法在小型嵌入式平台上的通用性。首先，分析了本章验证实验所用的英伟达 Jetson Xavier NX 小型嵌入式平台的硬件配置以及系统内部的软件安装包环境。将已经在服务器训练好的模型权重部署到嵌入式系统内，在嵌入式系统内部对汽车流水灯缺陷图片进行推理，结果显示本文的方法在小型的嵌入式平台依旧有着较理想的缺陷检测效果。并且，简要探究了本文方法在工业化汽车流水灯缺陷检测的应用示例。

第 6 章 总结与展望

6.1 工作总结

本文致力于解决汽车流水灯缺陷检测问题，特别关注不同款式流水灯的缺陷多样性，以及在质量检测中由此带来的挑战。随着汽车流水灯的广泛应用，本文引入深度学习算法，以提高缺陷检测的效率和准确性。全文的工作内容可总结为以下 3 个部分：

(1) 基于矩形框定位的汽车流水灯缺陷检测方法。为应对流水灯缺陷形式繁杂多样的问题，本文提出了基于矩形框定位的汽车流水灯缺陷检测方法。该方法基于 YOLOv7 目标检测算法，采用整体矩形框形式定位汽车流水灯的缺陷部分。并且，通过对 YOLOv7 网络的改进，包括加入 $g^n\text{conv}$ 递归门控卷积、GAM 全局注意力机制、Ghost 卷积、SimAM 无参数注意力机制以及提出融合注意力机制的并列结构 ELAN 模块等，以提高检测精度，实现通过训练单个模型就能同时精确识别不同特点的流水灯缺陷。改进后的 YOLOv7 在自建的汽车流水灯缺陷数据集上取得了 89.7% 的精度。

(2) 基于关键点定位的汽车流水灯缺陷检测方法。为识别出缺陷部分的具体位置与形状，本文提出了一种基于关键点定位的汽车流水灯缺陷检测方法。通过对局部关键点的精确定位，该方法能够准确识别出汽车流水灯的缺陷部分。基于 YOLOv7 网络的整体框架，本文设计了适用于汽车流水灯缺陷的关键点检测网络 YOLO-kpt，该网络包含 PANet 特征金字塔结构、双 SPPCSPC 模块、PConv 卷积和 ResPC 模块。训练得到的 YOLO-kpt 模型在自建数据集上表现出色，预测关键点位置的平均欧式像素距离误差仅为 1.8383。

(3) 嵌入式平台部署。为探究汽车流水灯缺陷检测模型的工业化应用有效性，本文将两种方法得到的汽车流水灯缺陷检测模型部署到小型嵌入式平台 Jetson Xavier NX 上，验证了本文方法的缺陷识别效果。

综合而言，本文通过引入深度学习算法，分别基于矩形框和关键点两个角度对汽车流水灯缺陷进行了精准的检测。并且在小型嵌入式平台上完成了模型部署，为汽车流水灯质量检测任务提供了有力的解决方案。

6.2 未来展望

尽管本文从矩形框定位和关键点定位两个角度提出了基于深度学习的汽车流水灯缺陷检测策略，并验证了模型在小型嵌入式平台的有效性。但在直接检测汽车流水灯缺陷部分的基础上，未来的研究可以继续进行综合性的优化，以进一步提升汽车流水灯缺陷检测系统的整体性能。

本文提出的基于深度学习的汽车流水灯缺陷检测方法在高效性和准确性方面取得了显著成果，但随着嵌入式系统和移动端设备的快速发展，对于模型轻量化的需求也逐渐增加。未来的研究可以致力于进一步优化和精简现有的模型，以适应资源受限的环境，例如在车辆上的实时应用。未来考虑采用量化技术、剪枝算法、模型蒸馏等方法，以降低模型的计算和存储需求，提高模型在嵌入式平台上的运行效率。虽然本研究着重于对汽车流水灯缺陷的准确检测和定位，但对于缺陷部分的实例分割仍然是一个值得深入研究的方向。通过实例分割，可以更精细地了解缺陷部分的空间分布和形状，为后续的修复和改进提供更有针对性的信息。未来的工作可以探索引入先进的实例分割技术，如 Mask R-CNN 或 U-Net 等，以更全面地解决流水灯缺陷的识别和描述问题。此外，可以考虑将实例分割与本文提出的矩形框定位和关键点定位相结合，以获取更为详细和完整的缺陷信息。

通过对上述未来工作方向的深入研究，有望进一步提高汽车流水灯缺陷检测系统的性能和实用性，为汽车制造业提供更为先进和可靠的质量控制解决方案。

参考文献

- [1] Yang X, Zheng Q, Hu Y, et al. Research on High-Quality Development of Auto Parts Manufacturing Industry Based on Machine Learning Model[J]. Scientific Programming, 2022, 141-142.
- [2] 赖城贤. 汽车灯光检测中存在的问题与对策[J]. 汽车与新动力, 2022, 5(06): 85-87.
- [3] 修亚男, 穆平安, 戴曙光, 等. 车灯模组的照度检测研究[J]. 计量学报, 2020, 41(10): 1212-1217.
- [4] 田光宇. 灯光检测中测量设备和测量过程对检测结果的影响[J]. 农业装备技术, 2019, 45(03): 63-64.
- [5] 许益成, 谭文安, 陈丽婷. 基于 Hough 变换检测前大灯的夜间车辆检测[J]. 控制工程, 2018, 25(08): 1360-1363.
- [6] 朱婉仪, 穆平安, 戴曙光. 基于图像匹配的透明车灯部件检测[J]. 计量学报, 2018, 39(03): 353-358.
- [7] 曾文治, 王疆瑛, 蔡晋辉. 基于机器视觉的车灯灯座尺寸检测系统设计[J]. 汽车实用技术, 2023, 48(02): 108-113.
- [8] Wahab Hashmi A, Singh Mali H, Meena A, et al. Surface Characteristics Measurement Using Computer Vision: A Review[J]. Computer Modeling in Engineering & Sciences, 2023, 135(2): 917-1005.
- [9] Xiao F, Wang H, Li Y, et al. Object Detection and Recognition Techniques Based on Digital Image Processing and Traditional Machine Learning for Fruit and Vegetable Harvesting Robots: An Overview and Review[J]. Agronomy, 2023, 13(3): 639.
- [10] Dong S, Wang P, Abbas K, et al. A survey on deep learning and its applications[J]. Computer Science Review, 2021, 40:100379.
- [11] Zhang D, Hao X, Wang D, et al. An efficient lightweight convolutional neural network for industrial surface defect detection[J]. Artif Intell Rev, 2023, 56:10651-10677.

- [12]张瀚丹, 吴一全. 基于视觉的汽车装配件缺陷检测研究进展[J]. 仪器仪表学报, 2023, 44(08): 1-20.
- [13]刘宇涵, 闫河, 陈早早, 等. 强噪声下自适应 Canny 算子边缘检测[J]. 光学精密工程, 2022, 30(03): 350-362.
- [14]潘宏亮, 孙金霞, 韩希珍. 图像清晰度评价与变步长融合调焦方法[J]. 红外与激光工程, 2023, 52(01): 248-253.
- [15]杨宏飞. 基于机器视觉的钢轨表面缺陷智能检测关键技术研究[D]. 吉林: 吉林大学, 2023.
- [16]曹锦纲. 基于机器视觉的复杂环境下表面缺陷检测技术研究[D]. 北京: 华北电力大学(北京), 2022.
- [17]Lowe, DG. Distinctive Image Features from Scale-Invariant Keypoints[J]. International Journal of Computer Vision, 2004, 60: 91-110.
- [18]Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks[J]. Commun ACM, 2017, 60(6): 84-90.
- [19]Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [20]Dehua Zhang, Xinyuan Hao, Linlin Liang, et al. A novel deep convolutional neural network algorithm for surface defect detection[J]. Journal of Computational Design and Engineering, 2022, 9(5): 1616-1632.
- [21]Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks[J]. Commun ACM, 2017, 60(6): 84-90.
- [22]Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, America, 2014: 580-587.
- [23]Girshick R. Fast R-CNN[C]//International Conference on Computer Vision (ICCV), Santiago, Chile, 2015: 1440-1448.
- [24]Ren SQ, He KM, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. Advances in neural information processing systems (NIPS), 2015, 39(6): 1137-1149.
- [25]Xu X, Zhao M, Shi P, et al. Crack detection and comparison study based on faster

- R-CNN and mask R-CNN[J]. *Sensors*, 2022, 22(3): 1215.
- [26] Shen L, Tao H, Ni Y, et al. Improved YOLOv3 model with feature map cropping for multi-scale road object detection[J]. *Measurement Science and Technology*, 2023, 34(4): 045406.
- [27] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multibox detector[C] //European Conference on Computer Vision (ECCV), Amsterdam, The Netherlands, 2016: 21-37.
- [28] Xiao Y, Tian Z, Yu J, et al. A review of object detection based on deep learning[J]. *Multimedia Tools and Applications*, 2020, 1-63.
- [29] 方翌啸. 基于关键点检测的指针仪表读数识别算法研究与应用[D]. 浙江: 浙江大学, 2020.
- [30] 吴涛. 基于深度学习的输电杆塔关键点检测方法研究[D]. 吉林: 东北电力大学, 2022.
- [31] 张博雅. 基于深度学习的驾驶安全评估方法研究[D]. 陕西: 西安科技大学, 2019.
- [32] 钟依健. 基于深度学习的奶牛关节点定位[D]. 广东: 华南农业大学, 2019.
- [33] 王继皓. 基于卷积神经网络关键点定位的遥感图像铁路检测[D]. 甘肃: 兰州交通大学, 2019.
- [34] 欧巧凤, 肖佳兵, 谢群群, 等. 基于深度学习的车检图像多目标检测与识别[J]. *应用科学学报*, 2021, 39(06): 939-951.
- [35] 孙峰瑶. 基于深度学习的道路异常物体识别算法研究[D]. 陕西: 西安电子科技大学, 2019.
- [36] 谢宇. 基于遮挡感知沙漏网络的车辆关键点检测及其应用[D]. 安徽: 安徽大学, 2022.
- [37] Cucchiara R, Piccardi M, Mello P. Image analysis and rule-based reasoning for a traffic monitoringsystem[J]. *IEEE transactions on intelligent transportation systems*, 2000, 1(2): 119-130.
- [38] 姜涛. 基于深度学习的汽车前脸几何特征精确提取[D]. 辽宁: 大连理工大学, 2019.

- [39]李策. 基于计算机视觉的汽车车灯检测技术研究[D]. 北京: 北京化工大学, 2021.
- [40]Moon C B, Lee J Y, Kim D S, et al. Inspection System for Vehicle Headlight Defects Based on Convolutional Neural Network[J]. Applied Sciences, 2021, 11(10): 4402.
- [41]Chen L, Hu X, Xu T, et al. Turn signal detection during nighttime by CNN detector and perceptual hashing tracking[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(12): 3303-3314.
- [42]Di C, Gong J. An AI-based approach to create spatial inventory of safety-related architectural features for school buildings[J]. Developments in the Built Environment, 2024, 100376.
- [43]Hu J, Shen L, Albanie S, et al. Squeeze-and-Excitation Networks[C]//Conference on Computer Vision and Pattern Recognition, Salt Lake City, America, 2018: 7132-7141.
- [44]Wang W, Tan X, Zhang P, et al. A CBAM based multiscale transformer fusion approach for remote sensing image change detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 6817-6825.
- [45]Zhao X, Huang J X. Bert-QAnet: BERT-encoded hierarchical question-answer cross-attention network for duplicate question detection[J]. Neurocomputing, 2022, 509: 68-74.
- [46]Wang CY, Bochkovskiy A, Liao HYM. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Conference on Computer Vision and Pattern Recognition (CVPR), Vancouver, Canada, 2023: 7464-7475.
- [47]Rao Y, Zhao W, Tang Y, et al. HorNet: Efficient high-order spatial interactions with recursive gated convolutions[J]. Advances in Neural Information Processing Systems, 2022, 35: 10353-10366.
- [48]Liu K, Sun Q, Sun D, et al. Underwater target detection based on improved YOLOv7[J]. Journal of Marine Science and Engineering, 2023, 11(3): 677.
- [49]Han K, Wang Y, Tian Q, et al. Ghostnet: More features from cheap operations[C]//Conference on Computer Vision and Pattern Recognition, Seattle,

America, 2020: 1580-1589.

- [50] Yang L, Zhang RY, Li L, et al. Simam: A simple, parameter-free attention module for convolutional neural networks[J]. In International conference on machine learning, 2021, 11863-11874.
- [51] 吕硕, 杨国涛, 陈涵深, 等. 基于关键点检测的钢桥螺栓松动识别方法[J]. 低温建筑技术, 2023, 45(02): 56-59.
- [52] Chen J, Kao S, He H. Run, Don't Walk: Chasing Higher FLOPS for Faster Neural Networks[C]//Conference on Computer Vision and Pattern Recognition, Vancouver, Canada, 2023: 11863-11874.
- [53] 陈龙伟, 周小成, 李传昕, 等. 基于 UNet-ResNet14*半监督学习的无人机影像森林树种分类[J]. 农业工程学报, 2024, 40(01): 217-226.
- [54] Liu S, Qi L, Qin H, et al. Path aggregation network for instance segmentation[C]//Conference on Computer Vision and Pattern Recognition, Salt Lake City, America, 2018: 8759-8768.
- [55] Lin T Y, Dollár P, Girshick R. Feature pyramid networks for object detection[C]//Conference on Computer Vision and Pattern Recognition, Honolulu, America, 2017: 936-944.

攻读硕士学位期间发表的学术论文

一、读研期间发表的学术论文

- [1] Chen J, Bai S, Wan G, et al. Research on YOLOv7-based defect detection method for automotive running lights[J]. Systems Science & Control Engineering, 2023, 11: 2185916.
- [2] Chen J, Bai S, Wan G, et al. Research on defect detection method of automotive running lights based on keypoint identification[C]//The 36th Chinese Control and Decision Conference, Xi'an, China, 2024.

致谢

三年研究生学习生活即将画上句号，如今毕业在即，将要走向工作岗位。在我即将完成学业、毕业的时刻，我想要向在我学术生涯中给予支持和帮助的人致以最诚挚的感谢。

首先，我要感谢我的导师柏受军副教授。在整个研究过程中，导师给予了我无私的指导和支持。柏老师尽职尽责的教导让我受益匪浅，柏老师的鼓励和指导让我能够克服各种困难，并始终保持对研究的热情和信心。同时，感谢万国扬老师在学术上的带教。在万老师的悉心指导下，我不仅在学术上取得了进步，也在个人成长方面有了很大提升。

其次，我要感谢江明教授和李云飞老师。江老师和李老师在我的学术研究中提供了许多宝贵意见。我要感谢实验室的所有同学们，为我提供了一个良好的学术氛围，让我能够在积极、合作的团队中进行研究。在同学们的帮助下，我学到了很多实践技能，也体会到了团队合作的重要性。

最后，我还要感谢我的家人和朋友。他们在我整个学习生涯中一直支持我、鼓励我，给予我无私的关爱和理解。没有他们的支持，学术生涯履步为艰。在这篇毕业论文的完成过程中，有太多人值得我表达感激之情，文字难以尽述。但愿我未来的道路上，能够回馈社会，让更多人受益。