编号 071951105

南京航空航天大學

本科毕业设计（论文）

题　目　航空发动机孔探图像智能识别方法

学生姓名	崔梓皓
学　　号	071951105
学　　院	通用航空与飞行学院
专　　业	民航维修工程
班　　级	2021202
指导教师	陈果 教授

二〇二五年五月

南京航空航天大学

本科毕业设计（论文）诚信承诺书

本人郑重声明：所呈交的毕业设计（论文）是本人在导师的指导下独立进行研究所取得的成果。尽我所知，除了文中特别加以标注和致谢的内容外，本设计（论文）不包含任何其他个人或集体已经发表或撰写的成果作品。对本设计（论文）所涉及的研究工作作出贡献的其他个人和集体，均已在文中以明确方式标明。

作者签名：

日　　期：　2025 年 5 月 18 日

南京航空航天大学

毕业设计（论文）使用授权书

本人完全了解南京航空航天大学有关收集、保留和使用本人所送交的毕业设计（论文）的规定，即：本科生在校攻读学位期间毕业设计（论文）工作的知识产权单位属南京航空航天大学。学校有权保留并向国家有关部门或机构送交毕业设计（论文）的复印件和电子版，允许论文被查阅和借阅，可以公布论文的全部或部分内容，可以采用影印、缩印或扫描等复制手段保存、汇编论文。保密的论文在解密后适用本声明。

论文涉密情况：

☑ 不保密

☐ 保密，保密期（起讫日期：　　）

作者签名：　　导师签名：

日　　期：　2025 年 5 月 18 日　　日　　期：　2025 年 5 月 18 日

摘　　要

航空发动机作为飞行器核心部件，能否正常工作直接决定了飞机飞行安全与飞行效率。通常检测航空发动机损伤的方法为孔探检测，传统人工孔探检测存在效率不足与漏检风险，现有孔探设备在损伤图像识别精度和实时性方面的智能化不足。

针对上述存在的问题，本文提出了基于深度学习的航空发动机孔探图像智能识别方法。基于深度学习方法的目标检测方法，能够自动对图像或视频中包含的损伤进行检测并标注分类，该方法主要包含以下步骤：

（1）搭建基于卷积神经网络模块的目标检测网络；

（2）对已有孔探损伤图像进行分类标注，并将图像划分为训练集与测试集；

（3）将上述数据传入到目标检测网络中，最终通过训练得到目标检测模型，使用该目标检测模型即可完成对典型损伤的检测与识别。

最终，通过使用本文方法对孔探图像数据进行试验验证，其检测精度达到 90.50%，相比传统方法有较大提升。使用本文方法能显著缩短飞机检测周期，降低维护人员技能门槛，为航空企业提供了经济可靠的技术支持。

关键词：航空发动机；损伤图像；目标检测；深度学习

Abstract

As the core component of the aircraft, whether the aircraft can work normally directly determines the aircraft's flight safety and flight efficiency. Usually, the method of detecting damage to aero engine is hole detection. Traditional artificial hole detection has insufficient efficiency and risk of missed detection. The existing hole detection equipment lacks intelligence in terms of damage image recognition accuracy and real-time performance.

In response to the above existing problems, this paper proposes an intelligent recognition method for aero engine hole exploration images based on deep learning. The object detection method based on deep learning methods can automatically detect and classify damage contained in images or videos. This method mainly includes the following steps:

(1) Build a target detection network based on the convolutional neural network module;

(2) Classify and annotate existing hole detection damage images, and divide the images into training sets and test sets;

(3) Pass the above data into the target detection network, and finally obtain the target detection model through training. Use the target detection model to complete the detection and identification of typical damage.

Finally, by using this method to test and verify the hole probe image data, its detection accuracy reached 90.50%, which is a significant improvement compared with the traditional method. Using this method can significantly shorten the aircraft detection cycle and reduce the skill threshold of maintenance personnel, providing economic and reliable technical support for aviation enterprises.

KEY WORDS：Aero-engine; damage images; object detection; deep learning

目录

第一章 绪论 - 1 -
1.1. 研究目的及意义 - 1 -
1.2. 国内外研究现状 - 1 -
1.2.1. 基于传统方法的孔探图像检测 - 3 -
1.2.2. 基于深度学习方法的孔探图像检测 - 4 -
1.3. 目前工作的主要问题 - 6 -
1.4. 本文的主要工作 - 6 -
第二章 基于目标检测的孔探图像检测方法 - 7 -
2.1. 目标检测算法概述 - 7 -
2.2. 基于 Two-Stage 的目标检测算法 - 7 -
2.3. 基于 One-Stage 的目标检测算法 - 8 -
2.4. 基于深度学习的孔探图像自动检测方法对比 - 9 -
2.5. 本章小结 - 9 -
第三章 基于 YOLOv5s 的孔探图像智能检测算法 - 11 -
3.1. YOLOv5s 的算法框架及关键技术 - 11 -
3.1.1. 算法框架 - 11 -
3.1.2. 算法关键技术 - 12 -
3.2. 孔探损伤智能检测流程 - 13 -
3.3. 孔探图像获取与预处理方法 - 14 -
3.4. 本章小结 - 16 -
第四章 算法试验验证 - 19 -
4.1. 试验环境与参数介绍 - 19 -
4.2. 试验指标 - 20 -
4.3. 试验结果分析 - 21 -
4.4. 本章小结 - 31 -
第五章 总结与展望 - 33 -
5.1. 本文总结 - 33 -
5.2. 未来展望 - 33 -
参考文献 - 33 -
致谢 - 34 -

第一章 绪论

1.1 研究目的及意义

现代主流的交通运输工具中，飞机的核心动力部分为航空推进单。该类推进装置的运行状况，对飞行安全的影响极大。从实际情况来看，其叶片、燃烧部件等结构在持续高温、高压、以及高速运动状态下，非常容易出现裂隙与烧蚀等损害现象。以往惯常采取的检测手法属于内窥检查体系，即使用微型镜头采集装置内部画面，再交由工作人员进行目测筛查。实际操作时，两项突出困扰始终存在。一方面，整体检测进程十分缓慢，大多数情况下需要消耗数小时进行作业，同时依赖检修员的专业感觉。另一方面，工人对细粒度缺陷长期保持察觉能力并不现实，由此可见，漏判现象非常常见。

近年来，伴随智能化科技发展提速，工厂自动检测领域已有新式方案引入。但是现在市场销售的数字图像分析设备，多数仍处于基础阶段。例如，发动机腔体内多层金属、复杂反光表面，构建起及其完备繁复的视野条件，这就会造成误差率居高。同时，不同破损纹理较为类似，本地端处理系统通常难以完全区分细小破坏。检测响应速度因硬件性能掣肘，也无法充分满足现场检修所需效率水平。实际情况表明，上述瓶颈，使智慧识别模式很难推广至更广的范围，并形成企业降本增效的支撑作用。

针对此背景，本课题聚焦于创建一种涵盖全流程的损伤影像自适应平台，尝试攻克三项关键挑战。第一，强化深层卷积神经网络架构，努力提升杂乱视觉场景下敏感区域锁定准确性。第二，引入模型裁剪机制，以保障系统能以普通计算装备实现高频次推理。第三，将模块化硬件接口与可交互控件同步集成，打造图像录制到结果输出一站式闭环应用环境。潜移默化的，这种技术落地预期带来更短维修周期，各级人员技能门槛有效下降，为航空发动机维护流程提供更可靠的信息安全保障与支撑体验。

1.2 国内外研究现状

1.2.1 国内研究现状

2021 年敖良忠等[1]设计出了以 DenseNet 和 ResNet 融合为基础的新型单通道网络结构，可以对发动机的部件进行分类，在自建数据集测试集上测试的准确率和平均召回率分别为 96.0%和 95.9%。

2022 年陈鑫硕等[2]为了解决 YOLOv5 模型推理速度相对较慢的问题，对 YOLOv5 模型采用了 BN 层通道剪枝的操作，使得其 mAP 从 97.6%提升到 98.6%但是速度的变化微乎其微，此外还与数字图像处理算法结合的方式来识别裂纹并提取裂纹骨架。

2022 年黄睿等[3]在 13 个航空发动机区域的 2654 幅孔探图像上针对烧蚀、裂缝、材料丢失、涂层脱落、刻痕和凹坑等 6 种典型的发动机损伤进行检测实验，提出的损伤检测方法在准确率和召回率两方面分别达到了 90.4%和 90.7%。

2023 年何宇豪等[4]提出了一个孔探视频检测的 SW-YOLO 模型，与 YOLOv5，Faster R-CNN，SSD 模型的对比实验，结果表明 SW-YOLO 模型的平均精度均值分别提高了 7%、6.2%、6.3%。

2023 年傅荣春雪等[5]使用 PRIDnet 图像去噪算法对原始孔探图像进行预处理，按照训练精度和训练速度两个指标对 YOLOv5 进行通道剪枝和微调，实验结果表明，相比于原始方法，发动机孔探图像内损伤的检测精度提高 4%～10%，在检测效率上提高 6%～20%。

2023 年闫子砚等[6]针对孔探检测中的小目标，构建了低层次的特征融合层，设计了相应的先验框，设计了轻量化的卷积结构 DSConv3 和 DSConv5，改进后的 YOLOv4 对小目标损伤的检测精度提升了 3.43%，同时检测速度提高了 31.03%。

2023 年何超等[7]提出了基于 YOLOv4 框架下的目标识别网络模型，该网络在保证准确率的前提下每秒检测的帧率相比原目标识别网络提升了 23.7%以上。

2023 年李小丽等[8]提出了一套适用于叶片损伤的图像预处理方式，并运用基于特征点的自动测量方法实现了发动机叶片损伤的识别测量。

2024 年蔡舒妤等[9]提出了 FDG-YOLO 轻量化航空发动机损伤检测模型，与原模型相比，FDG-YOLO 模型参数量降低了 52.5%，在嵌入式设备上的平均精度均值 mAP 达到 89.6%，帧率 FPS 达到 61。

2024 年李耀华等[10]提出一种融合注意力机制的轻量化 WGS-YOLO 缺陷检测算法，该算法识别精确度为 92.0%，相较于基准网络提高了 2.1%，而网络参数量减少了 55.3%，计算量降低了 57%。

1.2.2 国外研究现状

2018 年 Markus Svensén 等[11]使用 VGG16 卷积神经网络，对高压涡轮叶片、燃烧室等 5 类损伤进行分类，得到的分类准确率达到 95%。

2019 年 Zejiang Shen 等[12]提出了一种基于 FCN 的 3 阶段框架神经网络，使用该网络训练的模型能从飞机发动机孔探图像中快速准确地检测出裂纹和烧伤两类损伤，并在测试数据上对模型进行了验证，达到 98.03%的分类准确率。

2021 年 Jonas Aust 等[13]提出使用图像处理技术来缓解神经网络需要大量数据集的问题，使用图像处理技术对叶片边缘的刻痕、凹痕和撕裂进行自动检测并提供维修决策，检测和定

位准确率达到 83%。

2021 年 Chun Yui Wong 等[14]使用了 Mask R-CNN 对航空发动机孔探损伤进行了语义分割和实例分割，能够有效划分高压压气机 2 级和 4 级的损伤。

2021 年 Daiwei Zhang 等[15]使用 YOLOv3 网络对航空发动机叶片的裂纹、擦伤、凹痕、划痕和撕裂等 5 种损伤类型的 227 幅图像进行了识别，达到 85.71%的识别精度。

2022 年 Xubo Li 等[16]基于 YOLOv5 网络，在 YOLOv5 网络中引入了深度可分离卷积，并使用 k-means 聚类优化锚框大小，最终对裂纹、腐蚀、图层剥落等 5 类损伤进行识别，测试结果中 mAP@50 达到 83.8%，与原始 YOLOv5s 的相比，mAP@50 提高 1.9%。

2023 年 Anurag Upadhyay 等[17]使用 U-Net 结果检测高压压气机叶片上的缺陷，并结合 GAN 解决了小尺寸缺陷的数量问题，通过上述方法达到了超过 90%的精确率和召回率。

2023 年 Donghuan Wang 等[18]提出了一种基于 DBFF-YOLOv4 的缺陷检测算法，建立了一个完整的涡轮机叶片 X 射线图像检测与识别系统，并对该系统进行了测试与输出，结果表明，该缺陷检测系统的召回率为 91.87%，准确率为 96.7%。

2023 年İsmail UZUN 等[19]使用 Faster R-CNN 模型与 Inceptionv2 特征提取器，对划痕、裂纹和烧伤的分类准确率分别达到 92.05%、92.64%和 81.14%，平均准确率达到 88.61%。

2024 年 Hongbing Shang 等[20]使用多级图卷积网络，结合超像素感知区域建议网络，提出了一种新的超像素感知图神经网络，对 3000 幅仿真孔探数据进行识别，相对 Faster R-CNN 等网络更有效。

1.3 现有的孔探图像检测方法

1.3.1 基于传统方法的孔探图像检测

基于传统方法的孔探图像检测方法主要依赖人工经验和经典算法，可分为以下三类。

（1）专家系统（Expert System）

专家系统的基本原理是利用预定义的规则库或历史案例库来进行推理和决策。

其典型方法是规则匹配（例如，设定“若裂纹长度超过 2mm 则触发报警”）和案例推理通过比对历史相似案例（如积碳分布模式）进行诊断。但是专家系统的规则更新依赖专家经验，难以应对复杂或新型损伤。

（2）传统机器学习算法

传统机器学习算法的基本原理是通过人工提取图像特征（如纹理、形状、灰度）后进行分类或分割。

典型方法是利用人工神经网络（ANN），如 BP 神经网络用于损伤分类，RBF 网络用于

分割。用支持向量机（SVM），结合人工特征（如 HOG、LBP）进行分类。通过遗传算法（GA）来优化神经网络参数，提升模型精度。但同时它的特征设计依赖人工经验，并且对微小损伤和复杂背景鲁棒性差。

（3）经典图像处理技术

经典图像处理技术的基本原理是直接对图像进行数学变换或像素级操作。

典型方法是首先进行阈值分割，通过灰度阈值分离损伤区域（如 Otsu 算法）。

然后在进行边缘检测，使用 Canny、Sobel 算子定位损伤边界。最后在进行形态学操作，通过腐蚀、膨胀消除噪声或连接断裂区域。这个方法的缺点是对光照不均、模糊图像敏感，误检率高。

早在 20 世纪 80 年代到 2000 年传统检测技术以专家系统主导，当时内窥镜技术刚刚从医学领域引入航空检测领域，但其早期检测十分依赖技术人员的目视判断，效率低下。

所以在 20 世纪 80 年代，专家系统开始应用于航空维修，基于规则匹配实现损伤诊断，但不足的是其规则库规模有限，灵活性差。

等到了 2000-2010 年间，引入了机器学习与图像处理结合的方法。人工神经网络开始被引入探损检测技术中，用于损伤分割与分类，但依旧面临训练速度慢、局部最优等问题。新技术的引用将传统图像处理方法（阈值分割、边缘检测）与神经网络结合，提高了分割精度，提升了图像处理技术。

再往后到 2010 年后，混合方法与优化技术开始成为了主流，混合专家系统（规则+例+神经网络）可以同时提供损伤测量与维修建议。优化技术主要应用在遗传算法、D-S 证据理论等用于参数调优与结果融合，提升模型性能。

传统方法依旧存在以下等局限性：

（1）非常依赖人工经验。规则库与特征设计需领域专家参与，难以适应复杂多变的损伤类型。

（2）处理能力受限。对微小损伤（如微裂纹）和复杂背景（油污、积碳）的识别精度不足。

（3）数据需求矛盾。专家系统需要大量案例，使得它的标注成本很高；机器学习依赖数据量，然而早期的相关样本很稀缺。

1.3.2 基于深度学习方法的孔探图像检测

基于深度学习方法的孔探图像检测的关键技术方法如下所示：

首先是损伤分类与特征提取，使用卷积神经网络（CNN），通过多层卷积和池化操作的

方法提取孔探图像的纹理、形状等特征。使用复数卷积神经网络（CV-CNN），它是针对极化 SAR 图像的相位信息设计。徐丰团队提出的复数域 CNN 可将分类精度提升至 98%。类似方法可迁移至孔探图像分析，优化低对比度图像的分类效果。

然后是目标检测包含以下两种，其一是两阶段检测算法，如 Faster R-CNN，首先生成候选区域再分类和回归边界框。旷可嘉结合 VGG 主干网络优化 Faster R-CNN，提升凹坑、烧蚀等损伤的检测精度。其二是单阶段检测算法，以 YOLO 系列为代表，直接回归目标位置和类别，兼顾了速度与精度。YOLOv3-Lite 在飞机裂纹检测中实现实时处理。而改进版的 Cascade-YOLO 通过多检测头级联分类，平均精度（mAP）提升了 24.8%。

接着是实例分割与掩码生成包含了 Mask R-CNN 与改进模型，即在目标检测基础上生成像素级掩码，精确定位损伤轮廓。例如，改进的 Mask R-CNN 融合底层特征（如 P3、P4 层）与高层特征，优化边界粗糙问题，提升热障涂层丢失、裂纹等分割精度。和 YOLOv8_seg，它应用于钻孔图像的岩脉充填和裂隙分割，结合多项式拟合计算结构面产状（如倾向、倾角），实现自动化地质分析。

最后是图像增强与数据扩展技术，用来生成对抗网络（GAN）即用于低照度、高噪声图像的清晰度提升，如 SRGAN 增强孔探图像对比度。以及风格迁移技术，通过交互式数据扩展方法，将缺陷目标与背景图像风格融合，并利用泊松融合修正边界，使检测模型在 Mask R-CNN 任务中的平均精度提升 99.5%。

接着基于深度学习方法的孔探图像检测大致分为以下几个阶段：

（1）早期探索阶段（2010 年代中后期）

2012 年，于 ImageNet 竞赛中取得突破性进展的是 AlexNet 设计的模型，即后来逐渐成为计算机视觉任务核心技术的乃是卷积神经网络（CNN）。在深度学习领域具有里程碑意义的事件被记录于此，传统图像处理方法由此显露出局限性。实例表明，视觉识别任务的性能指标得到了显著提升。但与此此时，传统孔探检测仍然十分依赖人工经验与规则匹配，所以相关研究者开始尝试将 CNN 应用于工业图像分析。而在 2015 年后，研究者开始将 CNN 引入到孔探图像的特征提取中。通过多层卷积和池化操作自动识别叶片腐蚀、裂纹等损伤，使得分类准确率达到了 80%以上。虽然在早期的应用受到了来自于于数据量和计算资源的限制，模型以浅层网络为主（如 VGG、ResNet），但是已经展现出了超越传统阈值分割和 SVM 分类的潜力。在后来到英伟达 GPU（如 GTX 580）的普及后，显著加速了模型训练。

（2）技术突破与多样化应用阶段在 2018-2020 年代初期

随着目标检测与实例分割算法的日益成熟（如 Faster R-CNN、YOLO 系列、Mask R-CNN）

大大推动了孔探图像检测从分类到精细化定位的转变。在到后来目标检测算法引入包含了两阶段模型即 Faster R-CNN 结合 VGG 网络用于航空发动机叶片凹坑、烧蚀等损伤检测，通过候选区域生成提升定位精度；和单阶段模型即 YOLO 系列（如 YOLOv3-Lite）实现实时检测，应用于飞机结构裂纹识别，兼顾了速度与精度。再之后就是实例分割与掩码生成，将 Mask R-CNN 及其改进模型用于生成像素级损伤轮廓。典型的例子就是改进后的 Mask R-CNN 融合多尺度特征，优化热障涂层裂纹分割效果。最后就是图像增强与数据扩展，将 GAN 和 Transformer 投入适用于低质量的孔探图像的清晰度提升中当去。例如，SRGAN 增强图像对比度，风格迁移技术通过泊松融合生成合成数据，使检测模型精度提升至 99.5%。

（3）智能化与多模态融合阶段从 2020 年代中期至今

在轻量化模型、多模态数据融合及端到端系统的需求推动技术进一步优化后，同时结合了专家系统实现决策自动化。MobileNet、YOLO-Lite 等轻量级网络被部署至嵌入式设备，满足航空、矿井等场景的实时检测需求。使用多模态与跨领域技术迁移，将复数 CNN（CV-CNN）从极化 SAR 图像分析迁移至孔探领域，利用相位信息提升低对比度图像的分类精度。再利用端到端智能化系统，将损伤检测、尺寸测量与专家系统规则结合，例如 Mask R-CNN 分割后自动计算损伤面积并生成维修建议，以及元学习驱动的自适应部署（如 Meta-rLLS-VSIM 显微技术）启发孔探领域，实现从数据采集到模型部署的快速闭环 。

1.4 目前工作的主要问题

目前主要存在以下几个问题：

（1）数据局限性：孔探图像标注成本高，公开数据集稀缺，现有模型易过拟合。

（2）小目标检测难题：缺陷区域占比小且形态多变，传统检测算法漏检率高。

（3）复杂背景干扰：油渍、反光等噪声导致误检，现有分割方法鲁棒性不足。

（4）实时性需求：工业场景要求在线检测，但高精度模型计算复杂度高，难以部署。

（5）跨设备泛化性差：不同型号内窥镜成像差异大，模型迁移能力有限。

1.5 本文的主要工作

本文的主要工作是学习搭建成功一个可以投入使用的智能识别系统，并学习如何创建标注训练集，然后将标注好的训练集投入搭建成功的智能识别系统，进行系统化的学习，得到最终一个可以稳定识别各种不同损伤的智能识别系统。

第二章 基于目标检测的孔探图像检测方法

2.1 目标检测算法概述

计算机视觉领域的核心任务之一，目标检测。其存在是为了可以从图像中准确定位并识别目标物体的具体类别。其技术发展迭代可以划分为传统方法与基于深度学习的方法两大阶段，而后者因为其精度和效性更高逐渐成为主流。

首先，传统方法在早期依赖手工特征提取，通过阈值分割或边缘检测来进行对目标的定位。在钻孔图像分析中曾采用霍夫变换提取结构面线条，缺点是很容易受噪声干扰而且泛化能力较差。传统方法还包含了专家系统，基于人工规则匹配（如 IF-THEN 逻辑）构建知识库，用于对孔探损伤进行分类和提高维修决策。缺点是灵活性差，难以应对复杂场景。

最后是基于深度学习的方法，基于深度学习的方法包含了几下几类。第一是两阶段检测器，它可以首先生成候选区域再分类回归，以 Faster R-CNN、Mask R-CNN 为代表，精度高但速度较慢。第二是单阶段检测器，它可以直接预测目标位置与类别，如 YOLO 系列、SSD，适合实时检测但小目标精度十分有限。第三是 Transformer 架构，它通过 DETR 等模型通过自注意力机制实现全局建模，无需锚框，但是训练成本高。

2.2 基于 Two-Stage 的目标检测算法

Two-stage（两阶段）目标检测算法默认将目标检测分为以下两大部分：候选区域的选取和对目标的分类识别。两阶段目标检测算法可以一次性选取多个候选框进而可以充分提取所选目标的特征信息，进而大幅提高其检测的准确度，此外他还能在保障准确率的同时，实现对目标的精准定位，比较遗憾的是由于算法模型比较复杂而且分为两个步骤进行，所以检测速度相对较慢。[21]

Two-stage 的目标检测算法有以下代表算法：

首先是 R-CNN[22]算法,它是由 Girshick 等人在 2014 年提出，人们首次将深度学习运用在目标检测就是通过此算法实现的，进而为后续该系列检测算法奠定了结实的基础。在这之后，目标检测算法的实时性与精确度一直与时俱进，不断的优化和提高。R-CNN 目标检测算法可以分为以下四个步骤：第一步，利用选择性搜索算法 SS（Selective Search） [23]从图像中提取约 2000 个候选框。第二步，利用深度卷积神经网络提取各候选框的函数向量。第三步，用 AlexNet 将各个函数向量发送给各个向量机（SVM），判断是否属于此类。第四步，使用边界框的回归和非极大值抑制算法来获得候选的最佳框。

在此之后，因为 R-CNN 算法只能对固定大小的图像进行卷积运算，所以很容易出现特征

信息损失和运算速度慢的问题。而为了解决这个问题，He 等人在 2015 年提出了 SPP-Net 算法。SPP-Net 算法同样大致分为以下四个步骤：第一步，采用 SS（Selective Search）方法让一张图片生成 2000 个候选区域；第二步，利用空间金字塔池化[24]（SpatialPyramid Pooling,SPP）操作，把每个候选区域对应的特征转换成固定长度的特征；第三步，输入全连接层；第四步，进行后续 SVM 的分类和回归。SPP-Net 算法通过引入 SPP 来避免重复进行卷积运算，不仅可以保证同样或者更好的检测精度，同时还极大地提升了检测速度，相比 R-CNN 算法快 24～102 倍[25]。

还有 Fast R-CNN[26]是 R-CNN 算法的优化版本，它跟前面算法不一样的是在卷积计算的部分使用 VGG16 网络来替代 AlexNet 网络，并且融合了 SPP-net 的思想，将网络的 SPP 层单独设计为一层，即 ROI(Region of Interesting)Pooling 层，从而解决了权值更新的问题。此算法引入 SVD（Singular ValueDecomposition）对全连接层进行分解，提高了处理一张图片的速度。Fast R-CNN 将卷积神经网络提取的特征存储在显存中，减少了对磁盘空间的占用，从而提高了训练性能，加快了训练速度。同时在网络中加入多任务损失函数边框回归，该算法的整个训练过程非常简洁，仅仅包含候选区域提取和 CNN 训练两个阶段。

2.3 基于 One-Stage 的目标检测算法

单阶段目标检测算法是通过卷积网络提取图像的高级特征，再对特征图进行融合处理，然后定位到所需要的目标。目前的单阶段检测算法主要包括 YOLO 系列、SSD[27]和 RefineDet[28]算法，在检测领域具有很高的应用价值[29]。

Redmon J 等[30]在 2015 年提出了 YOLO 算法，YOLO 算法就是将整张图像分为 S*S 个网格，如果这个网格存在着预测物体的中心位置，就由预测的任务就由这个网格承担，并且每个网格会产生多个边界框，但是在训练期间每个边界框只能选择一个对象预测，所以当一个网格内存在多个物体时难以检测，限制了目标的检测精度，但是却提高了检测速度。

所以在 2017 年，Redmon J 又提出了 YOLOv2[31]，该算法采用了 Darknet-19 网络，使用了一系列设计决策来提高速度和精度。利用批量标准化（BN 层）稳定模型训练、设计高分辨分类器，让网络更好地适应高分辨输入、引入多尺度训练以提升检测精度；采用 K-Means 对目标框进行聚类，让模型可以更好地进行训练学习。YOLOv2 提供了更好的模型选择灵活性，将检测对象延伸到了 9000 个，所以又被称之为 YOLO9000。

到了 2018 年，Redmon J 再一次提出了 YOLOv3[32]，其采用 Darknet-53 为特征提取网络，如图 2.3.1 所示，在网络中加入 ResNet[33]残差网络连接，从而来减弱网络所带来的梯度负面影响；并结合 FPN[34]的思想将深浅尺度的特征图融合，进而可以提取更丰富的特征；采用

K-Means 聚类先验框，利用三个不同尺度的特征图来预测边界框，因为多尺度预测的优势，所以可以更多地检测小物体，但是在中大型物体上的性能相对较差。

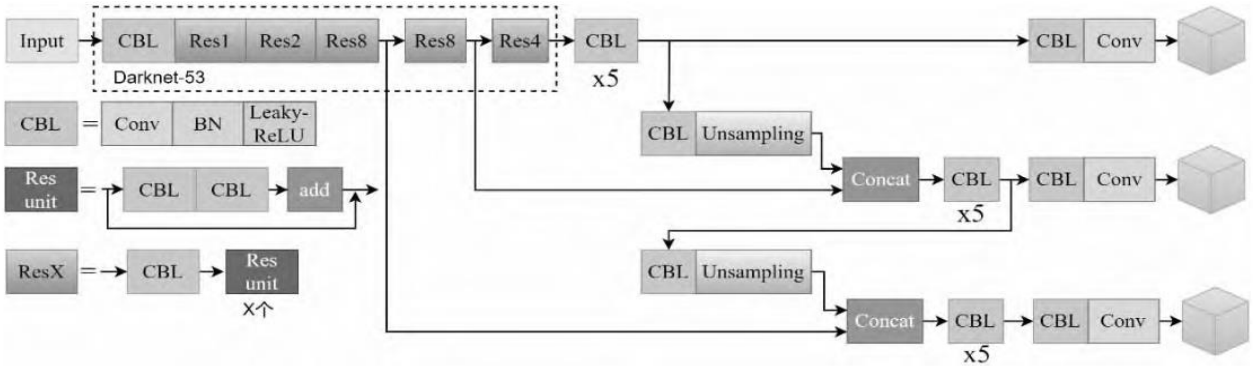

图 2.3.1 YOLOv3 结构图

2.4 基于深度学习的孔探图像自动检测方法对比

孔探检测需权衡精度、速度与环境适应性，不同算法的适用场景如表 2.4.1 所示：

表 2.4.1 各方法优缺点表

方法类型	典型算法	优点	缺点	适用场景
传统方法	Haar 级联分类器	不要标注大量数据，计算资源需求低	依赖手工特征设计，易受噪声干扰	简单损失的快速筛选
Two-Stage	Fast R-CNN	像素级分割，边界定位准确	需要标注大量数据，计算成本高	适用于高精度需求
One-Stage	YOLOv5s	延迟低，实时性强	小目标检测精度受限	发动机内部损伤实时检测

综上所述 YOLO 系列的目标检测算法通过轻量化设计与实时性优化，成为航空发动机孔探检测的首选。

2.5 本章小结

在本章中可以看出传统方法在一些简单、低资源场景中仍然具有其自身的实用价值，但显而易见的是深度学习已成为航空发动机孔探检测的主流技术，尤其在复杂工业场景中体现显著优势。目标检测技术从传统方法的运用慢慢演变优化到深度学习的运用，显著提升了孔探检测的智能化水平。在未来仍然需进一步突破小目标检测、极端环境适应性与标注数据依赖等瓶颈，推动工业检测向智能化、实时化方向发展。

第三章 基于 YOLOv5s 的孔探图像智能检测算法

3.1 YOLOv5s 的算法框架及关键技术

被广泛应用的 YOLOv5s 模型，其结构可划分为 backbone 部分、neck 部分及 head 部分三个主要组成单元。

(1)Backbone 组件作为网络的主干存在，主要承担特征提取的功能实现。该组件能够从输入图像中提取关键信息特征，为后续网络层提供必要的数据支持。值得注意的是，预训练模型参数可以直接加载于 backbone 网络之中，亦可在其后添加自定义网络层结构，这种做法使得模型能够更好地适应具体应用场景需求。

(2)位于 backbone 之后的 neck 模块发挥着重要作用。该模块对 backbone 提取的特征进行进一步处理加工，实例表明这种处理方式显著提升了模型的鲁棒性能表现。

(3)Head 模块作为网络的最终输出环节存在。由此可见，该模块通过整合前期各阶段提取的特征信息，最终完成模型的预测任务执行。

本文的主要方法就是将标注好的训练集投入到 YOLOv5s 中，利用其 backbone 主干网络来进行训练，使得 YOLOv5s 系统可以投入到航空发动机孔探智能检测的使用中去。

3.1.1 算法框架

Yolov5s 的算法框架如图 3.1.1 所示：首先利用主干网络，即提取特征的网络，来提取图片中的信息，利用框架内的不同模块进行卷积处理，在这之后供后面的网络使用。接着在将主干网络中处理好的图片输入进 neck 结构中，进一步提取图片特征，提高模型的鲁棒性。最后在 head 部分，利用之前提取到的特征，做出合理的预测。

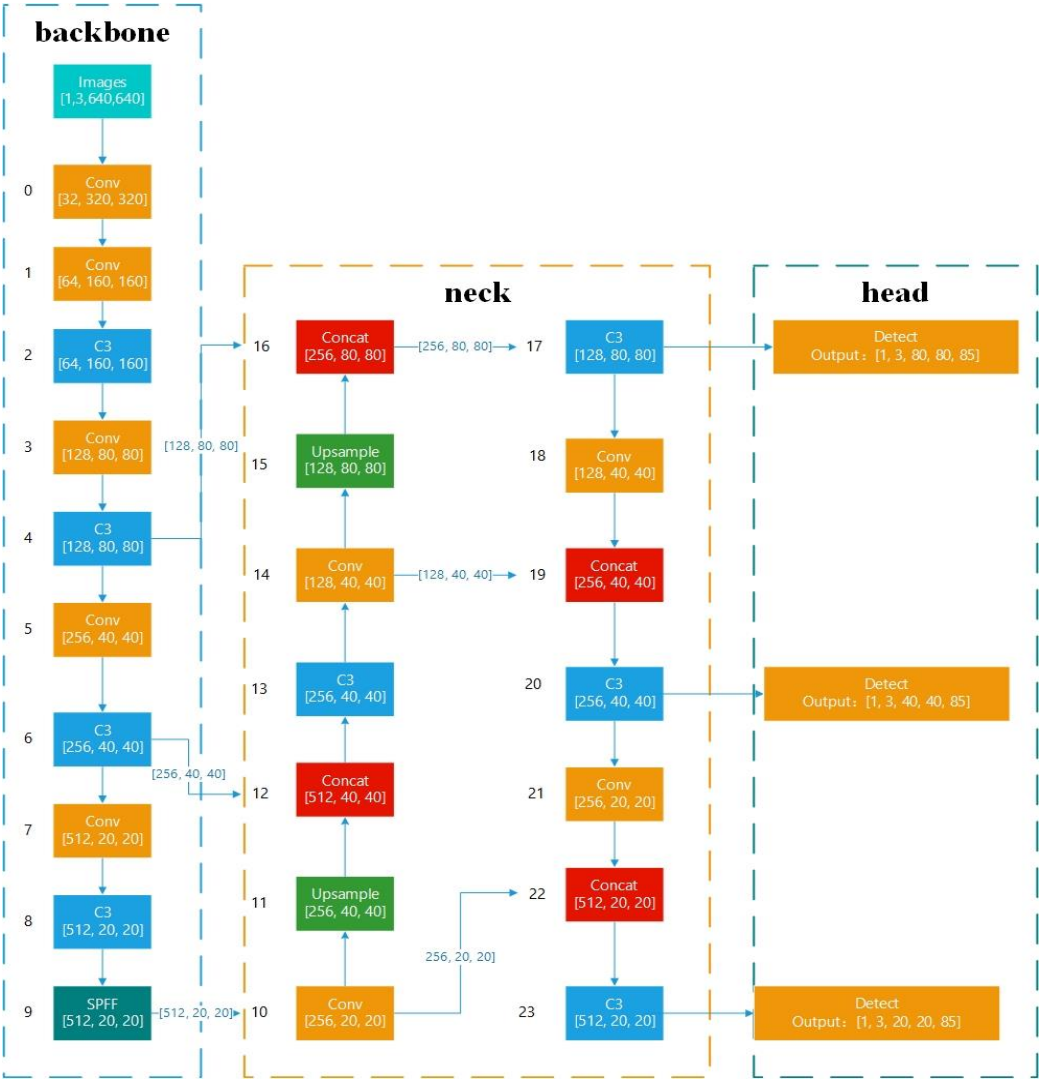

图 3.1.1 YOLOv5s 框架图

3.1.2 算法关键技术

（1）在网络结构优化与轻量化设计方面，利用 TCN（Temporal Convolutional Networks）的卷积操作，进行高效的并行运算，来达到更好的运用设备硬件的目的。

然后通过 CBS 卷积（在 YOLOv5s 中的作用是增强特征提取能力，进而提高目标检测的准确率），与池化降维路径（用来减少模型计算量，提高计算速度并增强模型的鲁棒性）从而解决模型准确率偏低的问题。同时采用 SPP 池化层，让 CNN 能够输入任意尺寸大小的图片，使得 CNN 网络不在需要固定尺寸的图像的输入，减少网络参数量，显著提升了训练速度。还运用空洞空间金字塔池化（ASPP），利用不同扩张率的卷积核（如 1×1、3×3、6×6、全局池化）捕获多尺度上下文信息，扩大感受野（特征图上的一点，相对于原图的大小，也是卷积神经网络特征所能看到输入图像的区域），增强了系统对微小缺陷的定位能力，尤其适用于孔探图像中局部损伤的复杂背景。

（2）在特征聚焦的增强过程中，坐标注意力（Coordinate Attention，CA）被采用。不仅

跨通道的信息能够被捕获，方向感与位置感知的信息同样可以被获取。目标的定位与识别由此得到更为精准的辅助。轻量化且灵活的特性使其能够轻易地嵌入各类模块之中。

在通道与空间两个维度上对网络进行优化的，是由混合注意力 CBAM 卷积块注意力模块(Convolutional Block Attention Module)的引入所实现的。更为有效的特征是从这两个维度获取的，当网络经过优化后，模型在通道维度的特征提取效果获得了进一步提升。

（3）在动态多尺度训练与自适应增强的方面，使用多分辨率输入切换，在训练阶段随机选择输入尺寸（640×640 至 1280×1280），来模拟不同距离下的孔探图像，增强模型对尺度变化的鲁棒性。结合 Mosaic 数据增强（随机拼接 4 张图像，按照一定比例组合成一张图片），来提升小目标样本的多样性。为了针对孔探图像中常见的遮挡问题，采用随机擦除（Random Erasing）随机屏蔽局部区域，模拟探入角度受限的场景；结合旋转（±15°）等几何增强，提升模型泛化能力。

（4）特征融合与上采样优化，采用内容感知特征重组（CARAFE）在每个位置上，都可以利用底层信息来预测重组核，并在预定义的附件区域重新组合特征，比主流上采样算子（如插值或反卷积）实现更好的性能。此外还使用了双向特征金字塔（BiFPN）来增进不同网络层级的特征图之间的信息传递，使网络更好的关注到小目标所在的区域。

（5）提升模型效率和性能，采用 MobileNetV3，它在 2019 年提出，旨在进一步优化模型的效率和性能，特别实在移动设备上。

3.2 孔探损伤智能检测流程

孔探损伤智能检测的大体流程如下所示。首先就是数据的采集和预处理，采用工业级电子内窥镜，支持高分辨率和 RAW/JPEG 的格式输出，配备可以 360°旋转的探头以及 LED 自适应补光模块，来确保复杂发动机内部环境下的图像清晰度。期间要注意采集图像的规范，严格依据《航空发动机孔探检测规程》，对叶片前缘、燃烧室、涡轮等关键区域进行多角度拍摄（俯仰角±30°，旋转角 0°-180°），单次检测生成 2000×2000 像素以上图像 50-200 张。在我们完成对图像的采集之后对图像进行去噪和增强，在这之后在对所得到的图像进行标注，要运用到标签软件 labelimg 来将所得到的图片上的裂纹，腐蚀等缺陷进行标注并组成训练集。

然后就是训练模型的搭建和训练，下载所需软件（Anaconda，Cuda 等），创建所需要的虚拟环境然后将其激活。接着在所激活的 pytorch 环境中，输入相关指令，下载后续所需要的相关软件。搭建完平台之后，在根据自己的需求设定好各项参数。

最后将标定好的训练集，投入设定好参数的系统中去，开始进行多次训练，在训练完成

之后，得到预测的结果。

3.3 孔探图像获取与预处理方法

采用工业级电子内窥镜（如图 3.3.1 所示）来获取发动机内部高分辨率的图像（JPEG/RAW 格式），确保光照均匀且焦距稳定。

图 3.3.1 深圳微视光电国产孔探仪

将内窥镜镜头随机旋转（±15°）和水平翻转来模拟不同探入角度获取更多更准确的图片。通过调整对比度（±30%）与高斯噪声（σ=0.01），来达到模拟实际场景中的光学干扰的效果。

然后在进行过一化处理，将图像缩放至模型输入尺寸（默认 640×640），并采用零均值化（mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225]）来加速模型收敛。所采集到的图片共 171 张图片如图（3.3.2 和 3.3.3）所示：

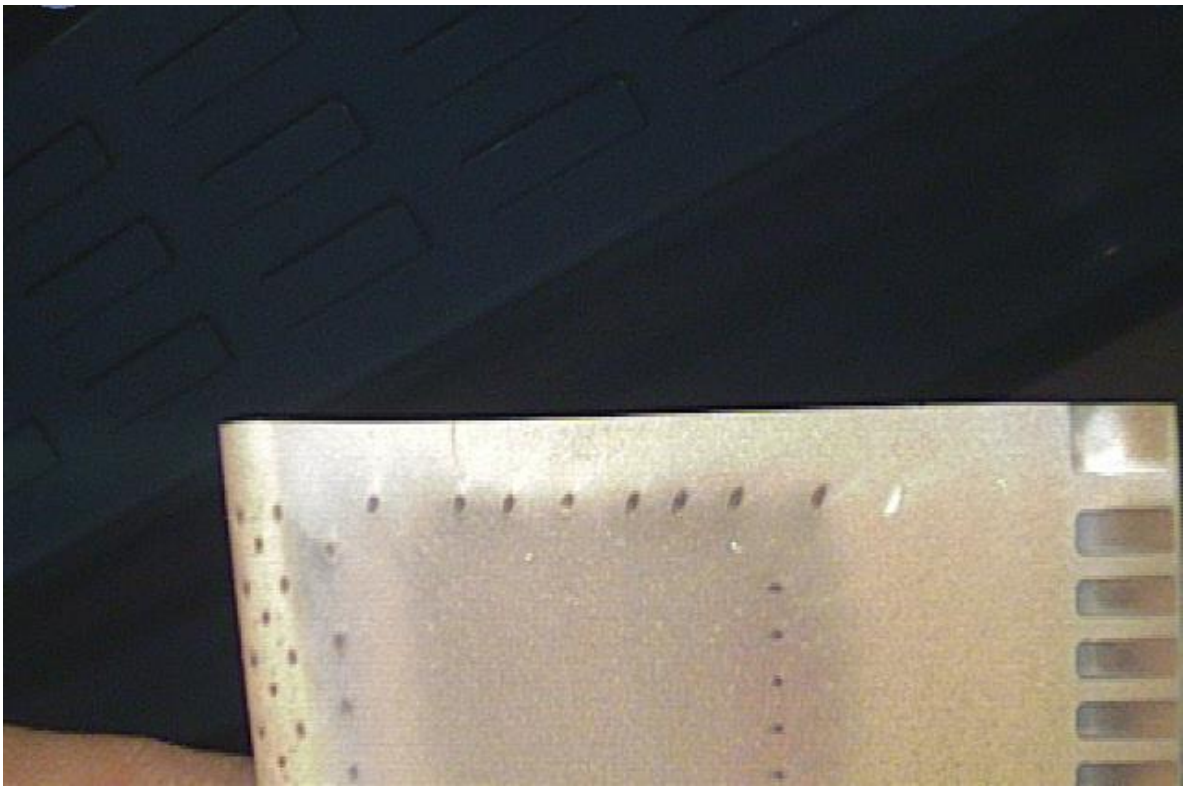

图 3.3.2 采集到的损伤原图

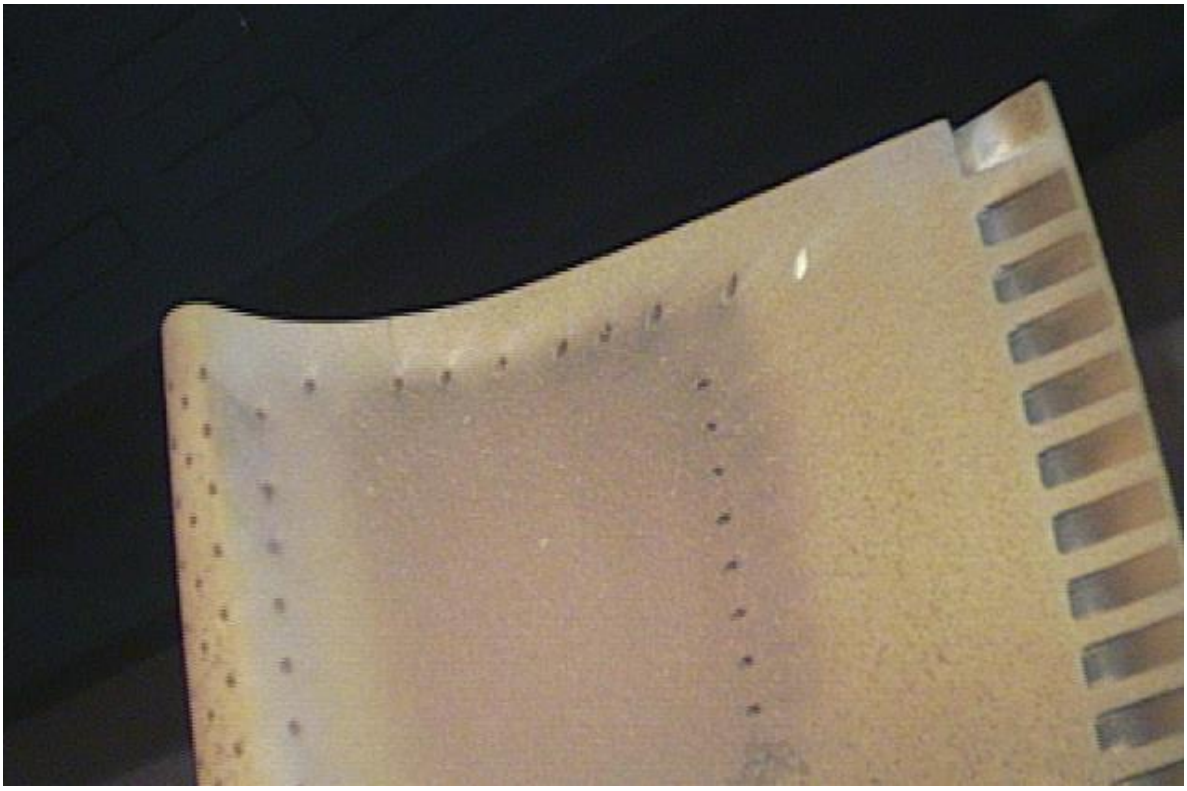

图 3.3.3 采集到的损伤原图

最后再将处理好的图片使用标签软件 labelimg 行进标注如图（3.3.4 和 3.3.5）所示：

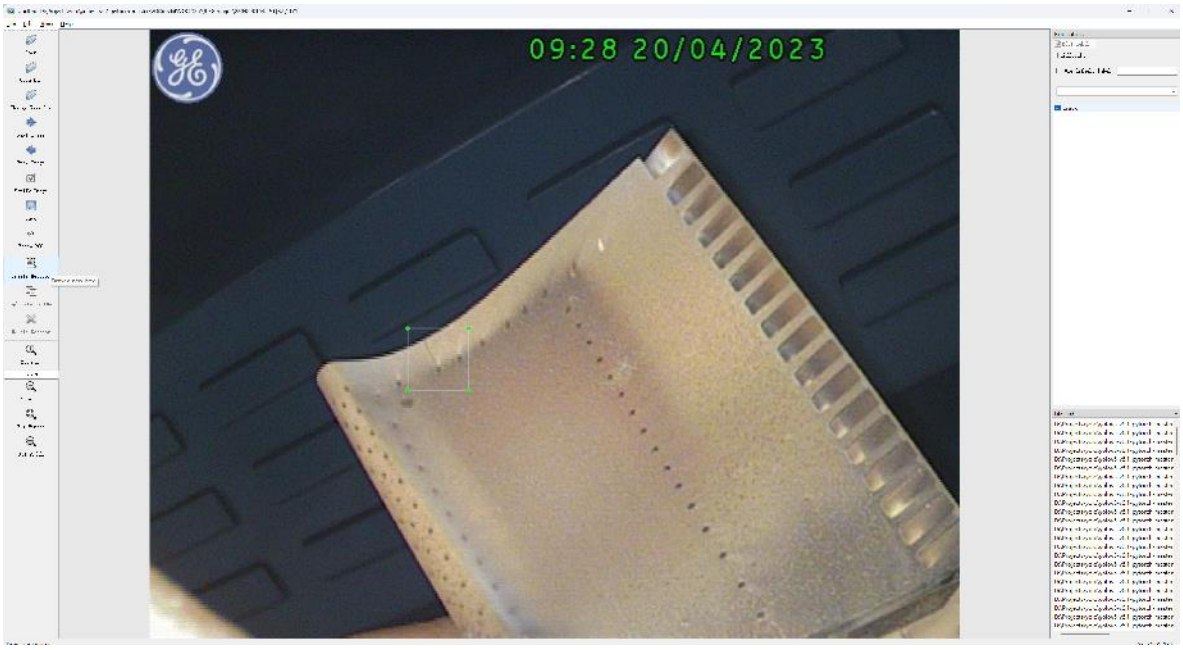

图 3.3.4 正在进行标注图

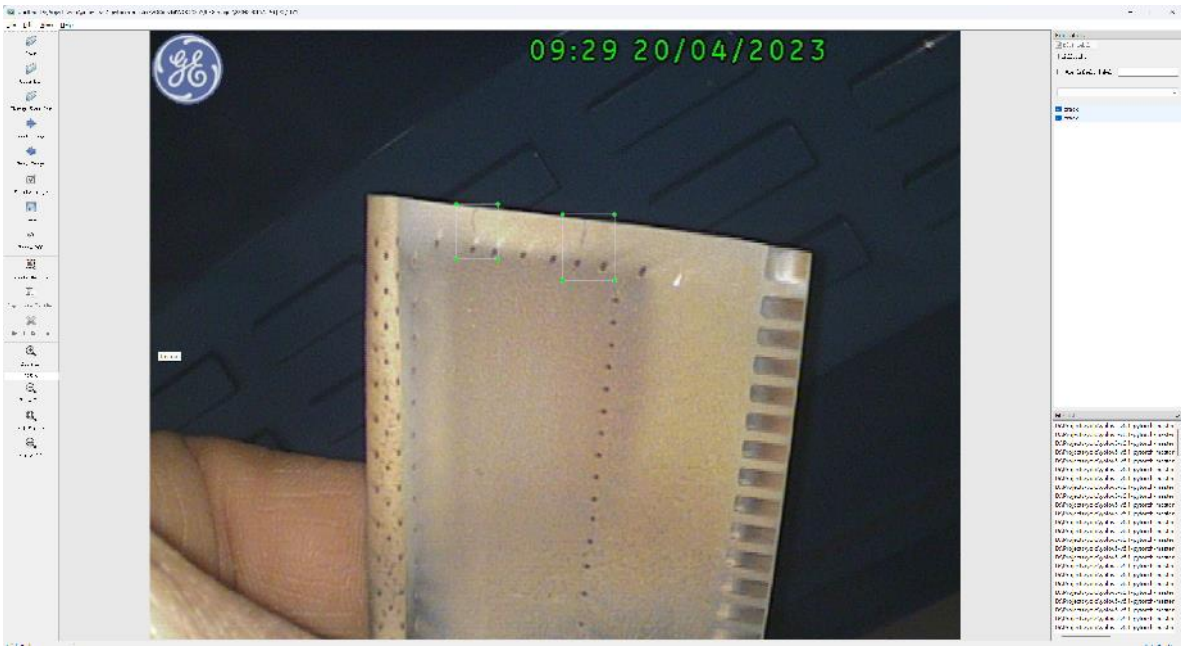

图 3.3.5 正在进行标注图

将标注好的图片和其对应的代码存进设定好的文件夹中，在激活提前创建好的环境，打开创建好的系统，然后把标注好的图片投喂进去开始进行训练，重复训练，让系统得到充分的学习，进而得到所需的预测结果。

3.4 本章小结

本章为了解决前文中对航空发动机孔探图像检测中存在的小目标漏检、背景干扰强、实时性要求高等问题，提出了智能检测算法 YOLOv5s。

首先是在算法创新性上的优化，采用轻量化网络架构通过 TCN 卷积与双向特征金字塔（BiFPN），在保证检测精度的前提下，模型参数量降低，推理速度提升，满足工业嵌入式设备的实时性需求。同时增强了注意力机制，引入坐标注意力（CA）与混合注意力（CBAM），显著提升了微小损伤（如裂纹、烧蚀点）的定位精度。

接着是采用动态训练策略，结合多分辨率输入切换（640~1280 像素）与 Mosaic 数据增强，使模型对尺度变化的鲁棒性提升，有效应对内窥镜探入角度多变而产生的图像尺度差异。

第四章 算法试验验证

4.1 试验环境与参数介绍

如上图 4.1.1 所示，下载 Anaconda 后在用 win+R 打开 cmd，然后输入代码创造 pytorch 虚拟环境，然后输入 activate pytorch 将其激活，之后在里面下载其他所需要的库：（如下表 4.1.1 所示）

表 4.1.1 框架所需库表

所需要的库	对应版本
scipy	1.2.1
numpy	1.17.0
matplotlib	3.1.2
opencv_python	4.1.2.30
torch	1.2.0
torchvision	0.4.0
tqdm	4.60.0
Pillow	8.2.0
h5py	2.10.0

激活完虚拟环境后，打开 Visual Studio 然后进入 train.py 之后就可以开始调试合适的参数。

（1）第 47 行的参数如下所示：cuda=false；

首先要设置的参数就是 Cuda，这个参数的意思是有没有使用 Cuda。在有 GPU 的情况下设置为 True，而电脑为 A 卡不是 N 卡，所以没有 GPU，这里如图所示设置为 False。

（2）第 78 行的参数如下所示：classes_path=’model_data/cls_classes.txt’；

接着就是设置路径，此处的含义是指向 model_date 下的 txt，与自己所需要训练的数据集有关，在训练前一定要修改好 classes_path 的路径，使其对应自己的训练集。

（3）第 84 行的参数如下所示：anchors_mask=[[6,7,8],[3,4,5],[0,1,2]]；

此处的 anchors_path 代表先验框对应的 txt 的文件，anchors_mask 用于帮助代码找到对应的先验框，上述两者一般不做任何修改。

（4）第 104 行的参数如下所示：model_path=’model_data/yolov5s_n_v6.1.pth’；

模型路径变量 model_path 被用于指定预训练权重文件的位置。预训练权重的使用在大多数情况下是必要的。主干网络部分的权值若未经预训练初始化将呈现过度随机化的状态。特征提取能力会因此显著下降。网络训练的最终效果将受到负面影响。由此可见，该参数通常不建议进行修改。

（5）第 108 行的参数如下所示：input_shape=[640,640]；

Input_shape 代表了我们输入到网络当中进行训练的图片的大小，默认情况下一般都是[416,416]，如果需要更改的话，则需要改成 32 的倍数即可，如图所示训练时改成了[640,640]符合需求和规定。

（6）第 179 行的参数如下所示：Freeze_batch_size=16；

处于冻结阶段时，主干网络被冻结是其特征提取层不发生改变的原因所在。模型训练参数较少这一现象导致了显存占用的降低，实例表明此时通常仅需网络微调即可。显存需求较小这一特点使得 batch_size 的适当增加成为可能，实例为单次传递至训练程序的样本数量。具体调整方案需依据个人设备显存容量而定，由此可见设备性能差异将直接影响训练参数设置。

（7）第 190 行的参数如下所示：Unfreeze_batch_size=8；

解冻阶段内，主干模型处于非冻结态。主干特征提取网络的变化，在冻结解除后随之产生。训练参数数量增多，实例表明显存占用呈现上升趋势。网络参数的调整，由此可见由上述变化引发。Unfreeze_batch_size 的设置需谨慎处理，实例显示显存需求增大时稳定性维持困难，较小参数值通常被采用。

（8）第 195 行的参数如下所示：Freeze_Train=True；

关于 Freeze_Train 参数的使用目的，被设定为是否采用冻结训练策略。通常而言，初始阶段将主干网络部分进行冻结处理，实例表明该操作具有普遍性。训练过程的后期阶段中，网络参数的解冻操作才会被执行。由此可见，该参数对模型训练流程的阶段性控制起着关键作用。

（9）第 245 行的参数如下所示：num_workers=4；

在数据读取过程中，决定是否采用多线程机制的关键参数为 num_workers。实例表明，该参数的启用确实能够显著提升数据加载速率。值得注意的是，内存资源消耗量亦随之增加的现象已被观察到。由此可见，对于内存配置较低的设备而言，将该参数值设定为 0 或 2 的情况较为常见。

4.2 试验验证指标

train loss：表示模型在训练集上的误差，反映了模型对训练数据的拟合程度，train loss 会随着训练的进行逐渐下降。

val loss：表示模型在验证集上的误差，用于评估模型在未见过的数据上的表现，帮助检测模型是否过拟合。

Precision（精准率）计算公式如(1.1)所示：

$$P = \frac{TP}{TP + FP} \tag{1.1}$$

反映的是模型预测为正类的结果中有多少是真正的正类。

Recall（召回率）计算公式如（1.2）所示：

$$R = \frac{TP}{TP + FN} \tag{1.2}$$

描述了实际为正类的情况下有多少被成功检测出来。

Accuracy（准确率）的计算公式如（1.3）所示:

$$A = \frac{TP + TN}{TP + TN + FP + FN} \tag{1.3}$$

准确率表示模型预测正确的样本数量占总样本数量的比例。

Specificity（特异性）的计算公式如（1.4）所示：

$$S = \frac{TP}{TN + FP} \tag{1.4}$$

测量的是实际为负类的情况中，有多少被正确识别为负类。

上述公式中的缩写含义如下所示：

被预测为正例且实际为正例者，可称为真正例项（TP）。

预测结果呈现正例而真实情况为负例之情形，则属于假正例项（FP）。

当预测与事实均为负例时，则被归为真负例项（TN）。

若预测为负例而实际为正例之情况，应划入假负例项（FN）范畴。

置信度（Confidence）这一概念在模型识别过程中被运用，用以表征分类判定时的概率性特征。不同于传统二分法的是或否判断方式，现代分类模型倾向于采用概率化评估机制，将待识别对象归属于某一特定类别的可能性予以量化表达。当此概率值超过预设阈值时，分类结果方被最终确认。

F1-置信度曲线（F1-Confidence Curve）的形成机理在于：随着置信度阈值的逐步提升，F1 分数（F1-Score）呈现相应的动态变化趋势。实例表明，该曲线能够直观反映模型性能随判定标准严格程度变化的规律。

作为统计学中的重要评价指标，F1 分数（F1 Score）主要用于二分类或多任务二分类模型的精度评估。该指标的特殊性体现在同时兼顾了准确率（Precision）与召回率（Recall）两个维度的性能考量。由此可见，F1 分数实质上是上述两个指标经过加权处理后得到的调和平均值。其取值范围被限定在 0 至 1 区间内，数值大小与模型性能优劣呈正相关关系。

4.3 试验结果分析

将制作好的数据集投喂进搭建好的模型之后，反复训练所得到的数据如下所示：

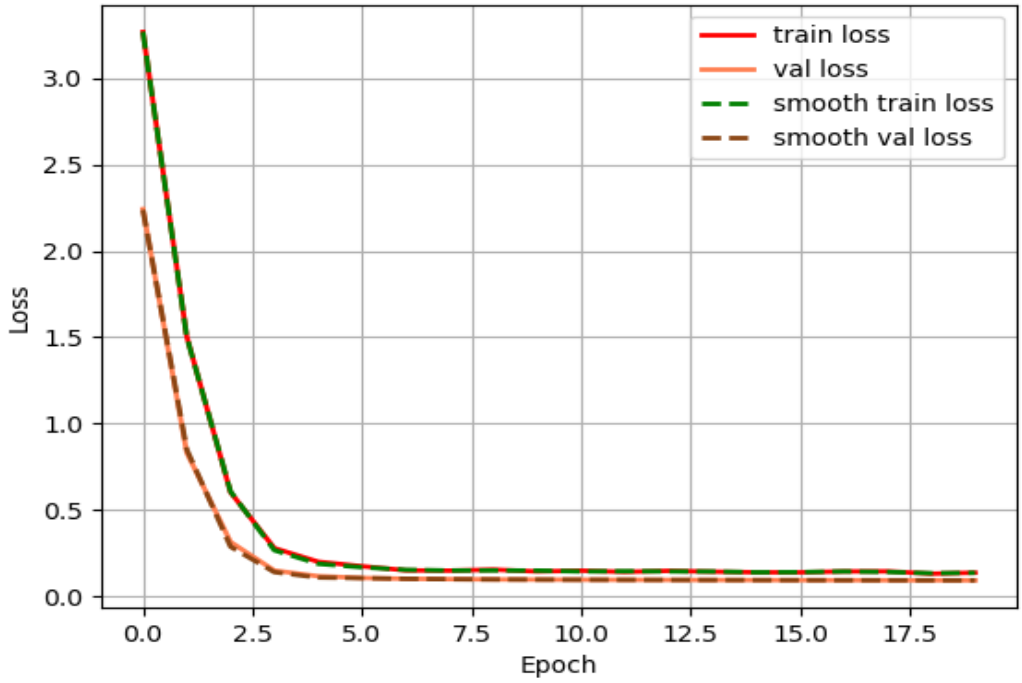

图 4.3.1 epoch_loss（循环与损失的关系）

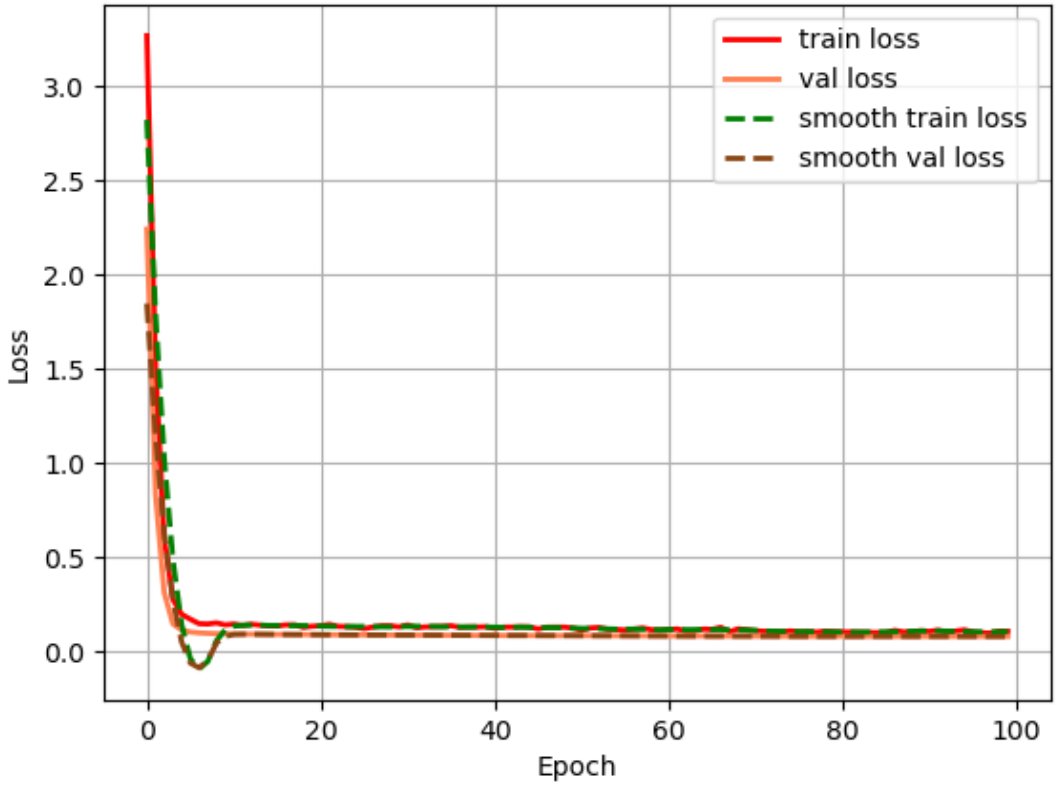

图 4.3.2 epoch_loss（循环与损失的关系）

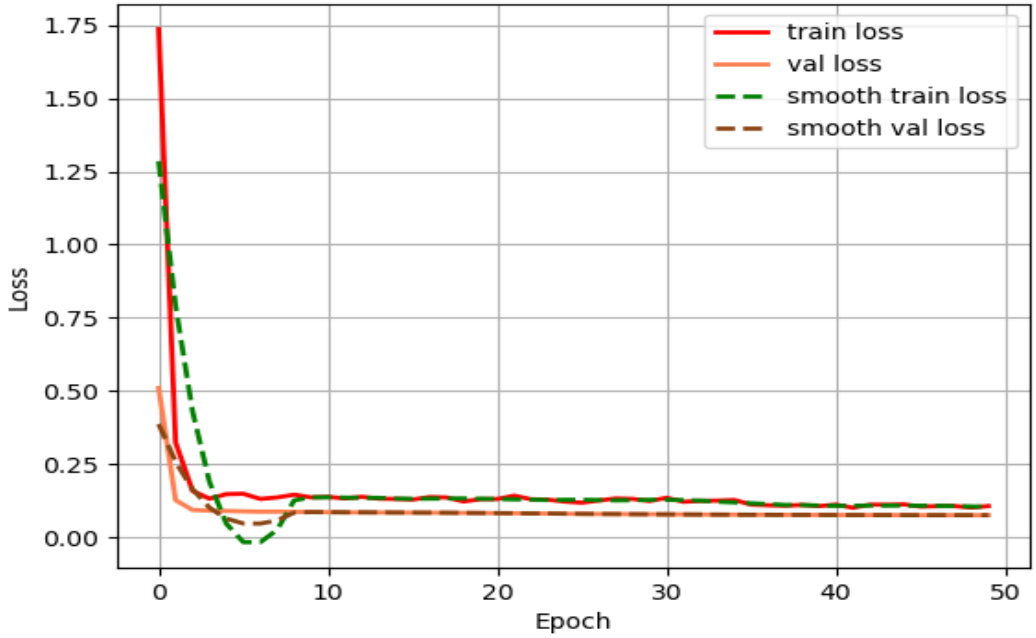

图 4.3.3 epoch_loss（循环与损失的关系）

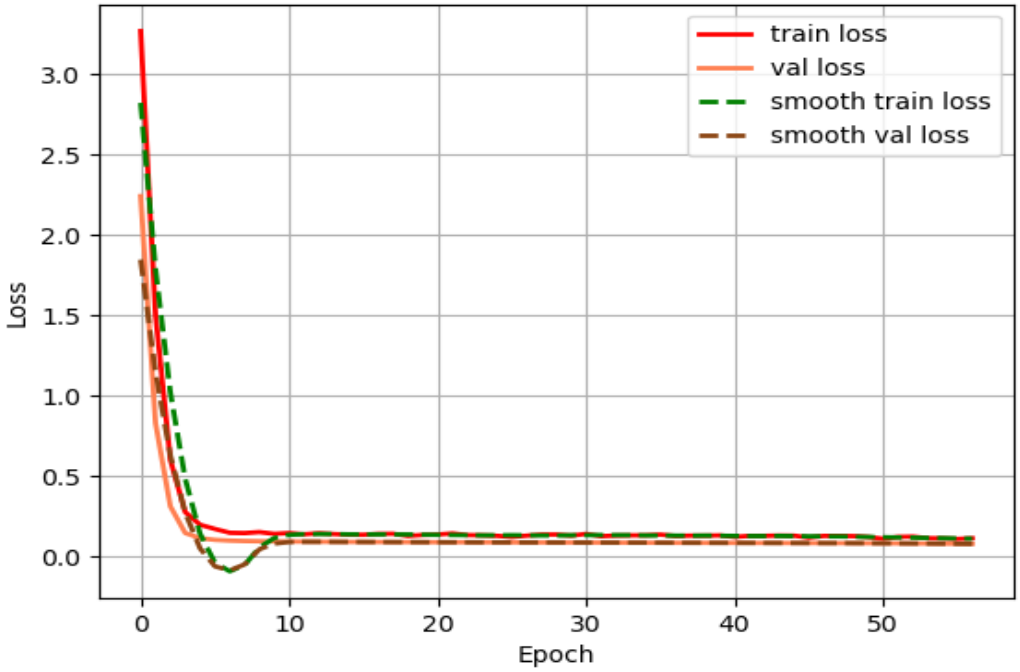

图 4.3.4 epoch_loss（循环与损失的关系）

可以看出在上述四张图片中的 train loss 在不断下降的同时，val loss 也在不断下降，说明模型在训练集和验证集上都表现良好，网络仍在学习。

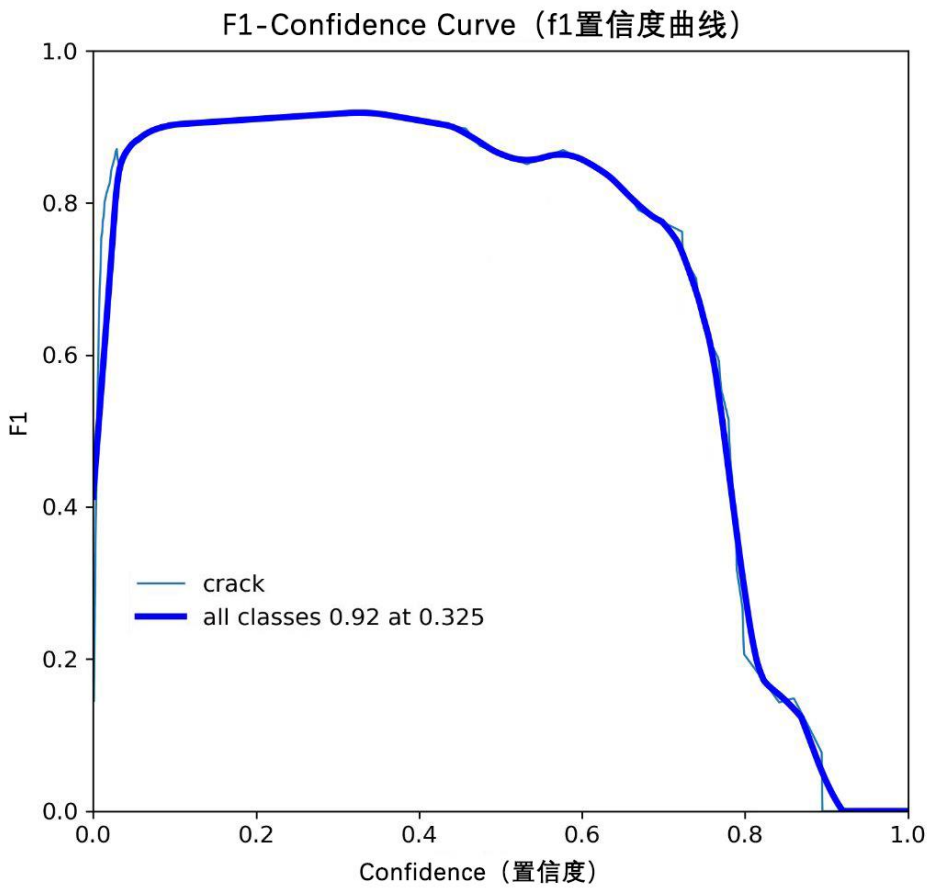

图 4.3.5 F1-Confidence Curve

如图 4.3.5 所示，横坐标代表置信度这一参数，纵坐标则对应 F1-Score 指标。展示 F1-Score 随 Confidence 增长而变化的，正是 F1-Confidence Curve 这一曲线。当 Confidence 处于较低水平时，可以观察到较高的 F1 得分值。实例表明，在 0.1 至 0.5 区间内设置 Confidence 参数时，稳定维持在 0.9 附近的 F1 值被获得。由此可见模型在此阶段具有较好的训练效果。随着 Confidence 数值的持续增大，逐渐下降的 F1 得分趋势被观察到。

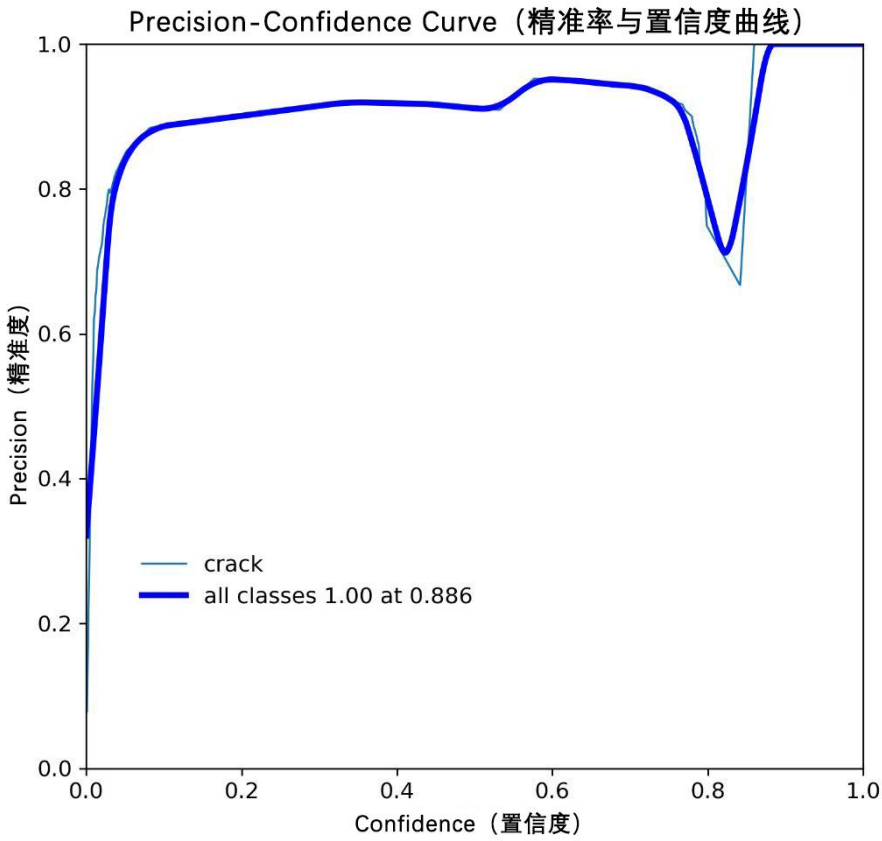

图 4.3.6 Precision-Confidence Curve

在图 4.3.6 中展示的，是 Precision 与 Confidence 指标间存在的关联性。尽管当 Confidence 数值达到 0.8 时，可以观察到 Precision 值发生了短暂性下降现象，但随着置信度指标的持续上升，检测准确率总体上呈现出递增态势。实例表明，该模型的训练效果具有较好表现。

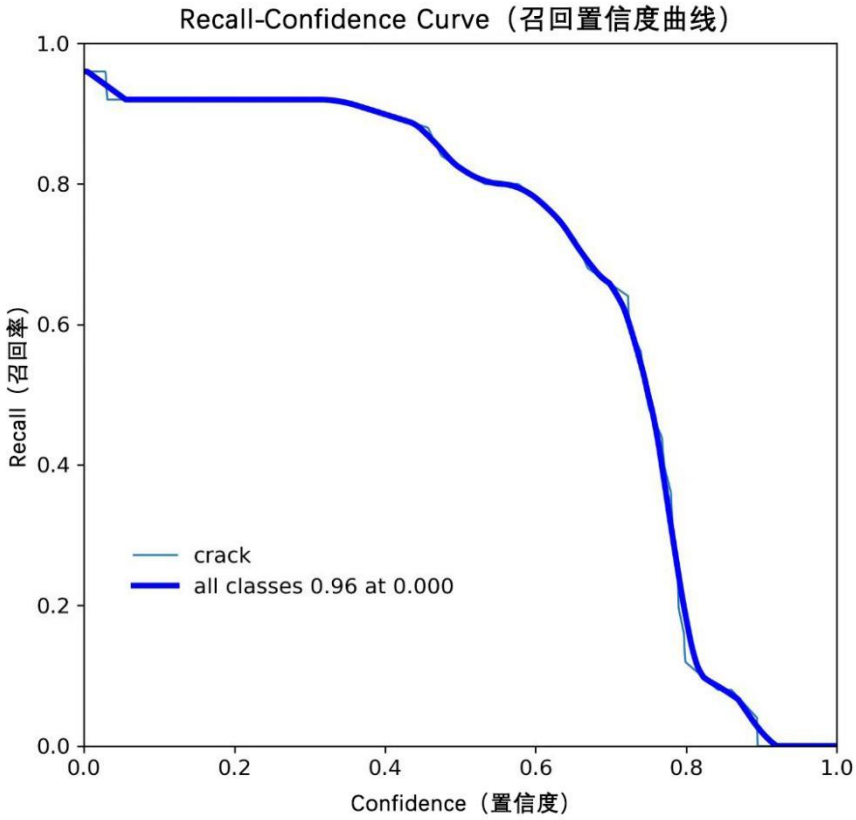

图 4.3.7 Recall-Confidence Curve

如图 4.3.7 所示，Recall 与 Confidence 间之关系被展示。随着置信度数值的持续升高，召回率之准确度呈现下降态势被观察到。实例表明，模型训练过程所得出之结果，与理论预期具有一致性。

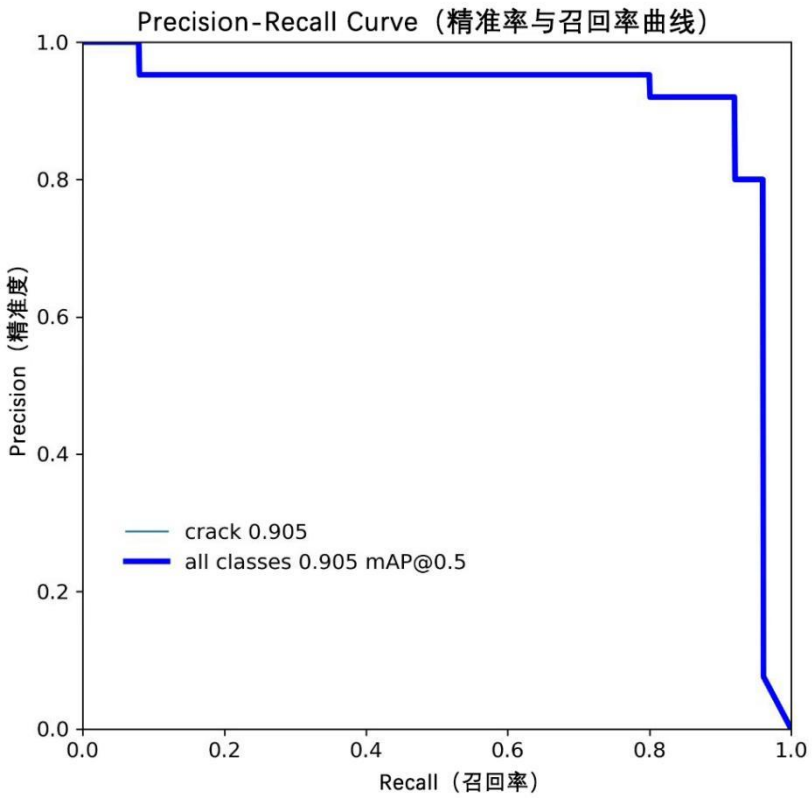

图 4.3.8 Precision-Recall Curve

图 4.3.8 中，模型精确度(Precision)与召回率(Recall)之间关系得以展示。靠近坐标轴左上角时，PR 曲线所呈现之态势更优，正样本识别正确性随之提升；右侧区域则相反，模型对正样本识别能力之不足显现。实例表明，0.0-0.8 区间内召回率条件下，模型性能表现优异，样本判别准确性维持高位状态；直至 0.95 召回阈值前，准确率仍保持较高水准。mAP 指标方面，90.50%的平均精准率均值被观测到，模型检测精度水平由此得以确认。

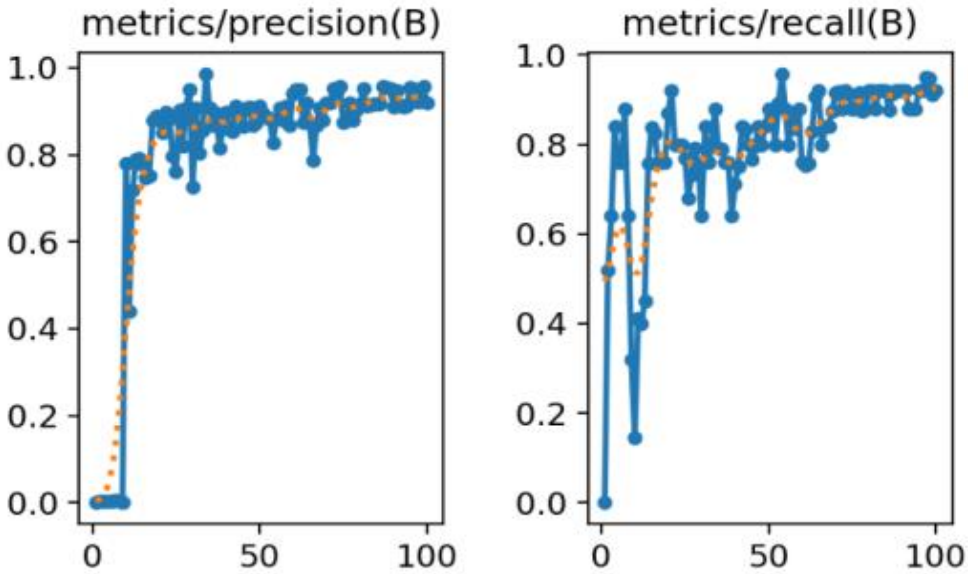

图 4.3.9 综合图

metrics/precision 图呈现如下特征：精度（Precision）作为模型预测正样本正确性的衡量指标，在该图中得以展示。预测边界框与真实边界框的重合现象明显可见。上图表明，模型预测结果具有较高的准确性。

metrics/recall 图所反映的情况需要特别关注：召回率（Recall）用于表征模型对真实正样本的识别能力。图中可观察到，真实边界框与预测边界框之间存在着显著的重叠区域。由此可见，该样本被成功召回的事实得到验证。

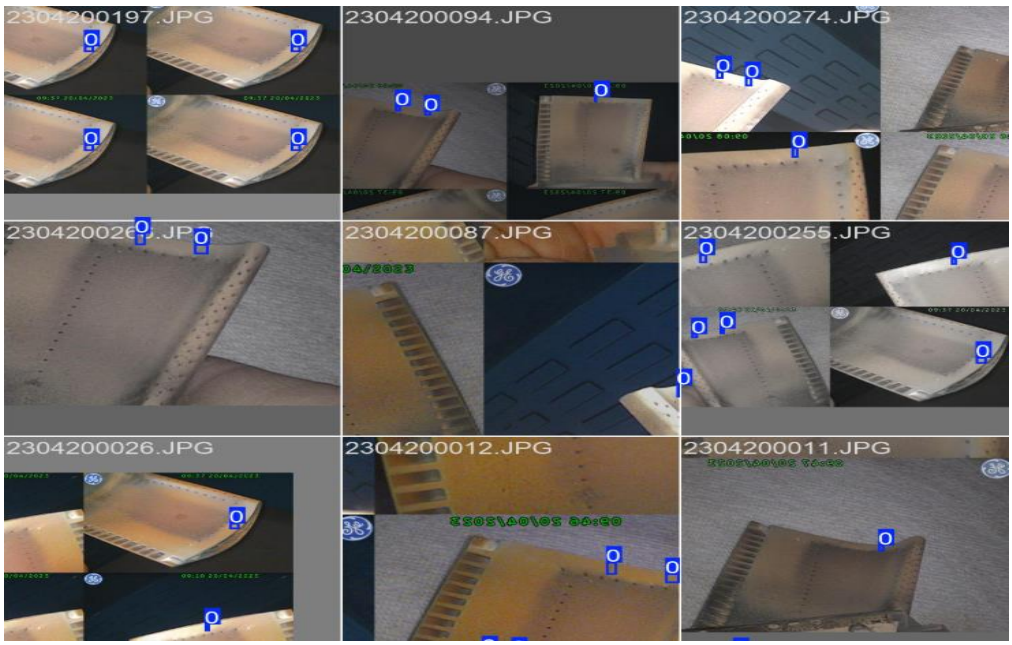

图 4.3.10 检测效果图

图 4.3.11 检测效果图

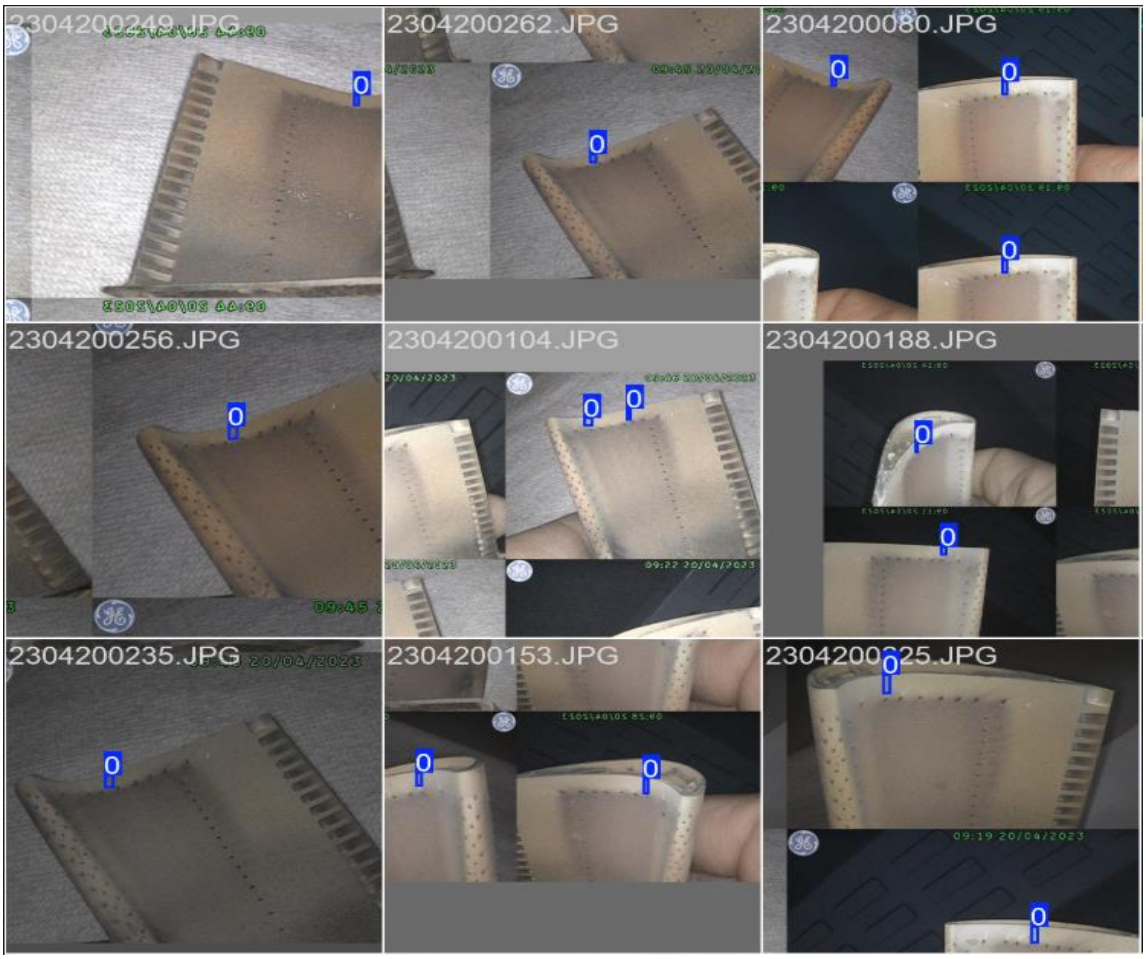

图 4.3.12 检测效果图

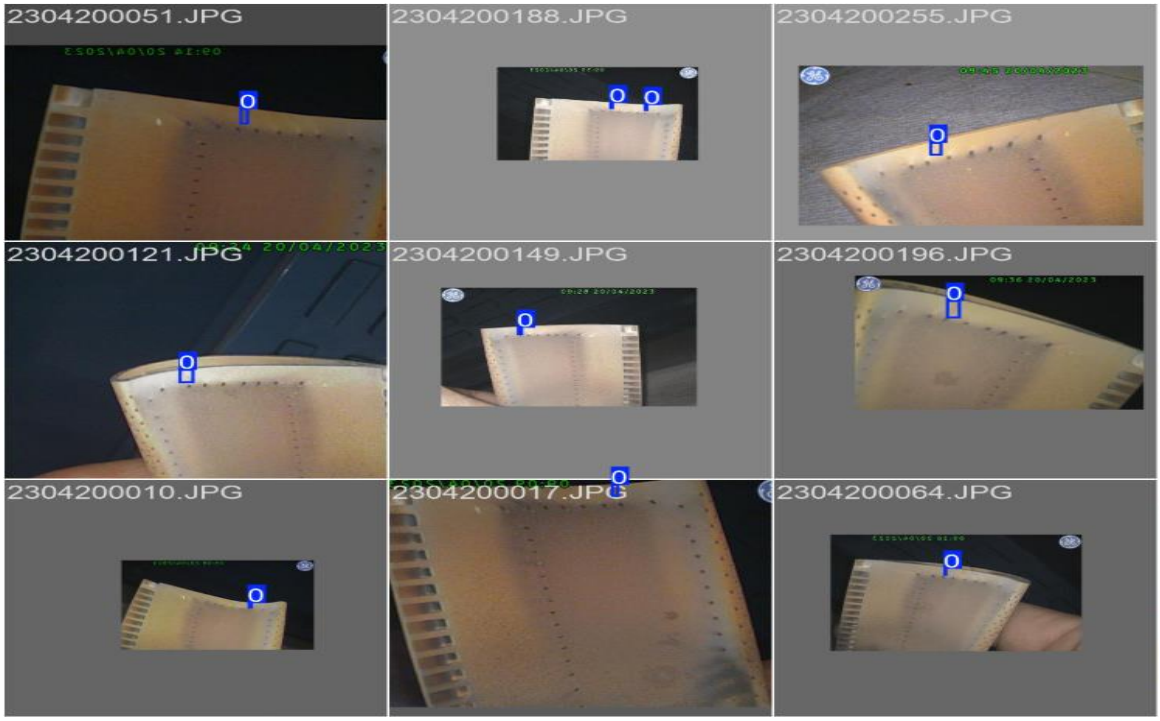

图 4.3.13 检测效果图

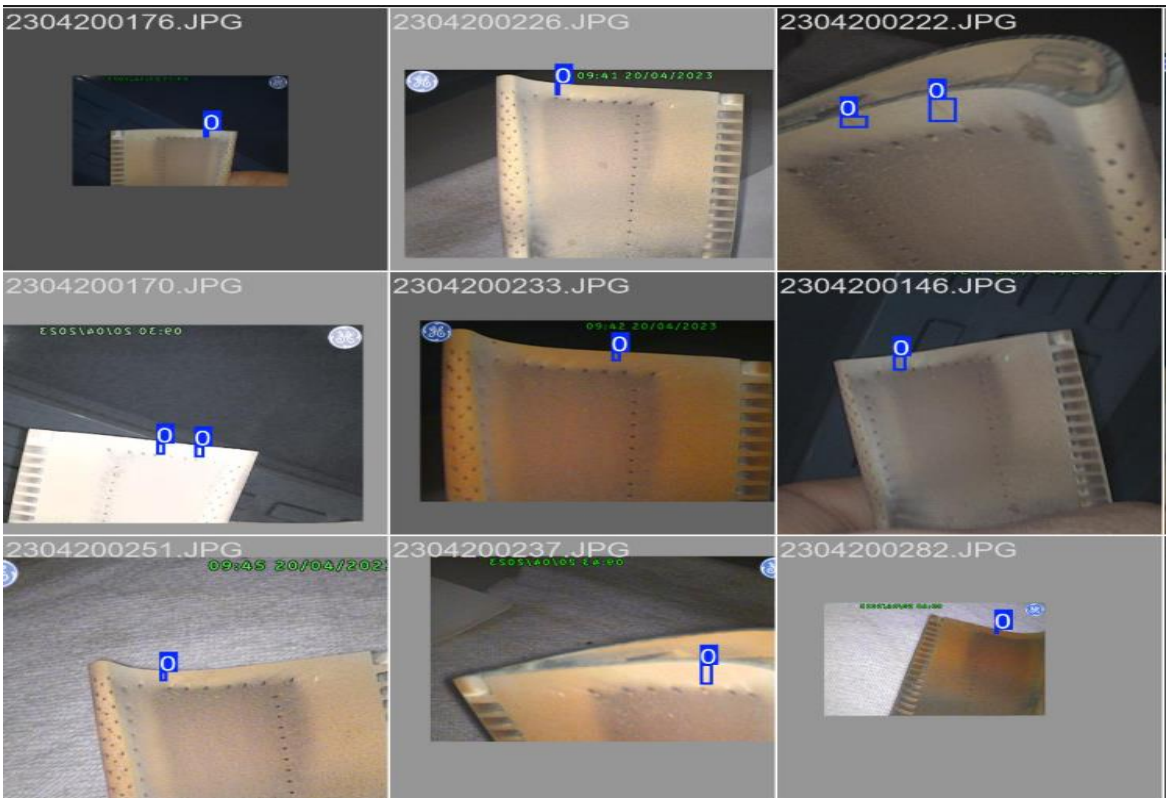

图 4.3.14 检测效果图

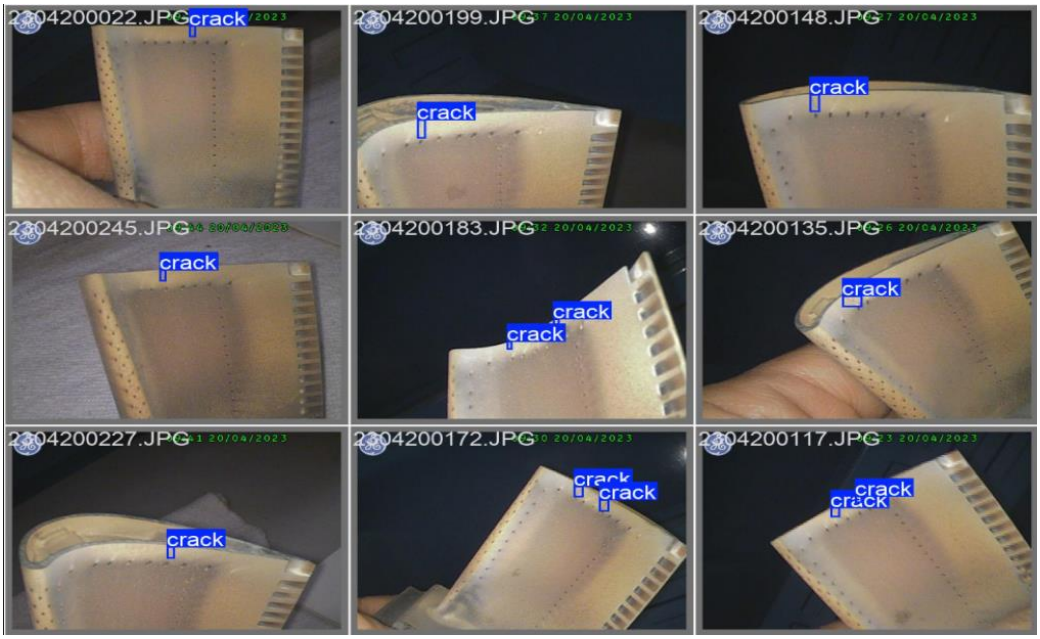

图 4.3.15 检测效果图

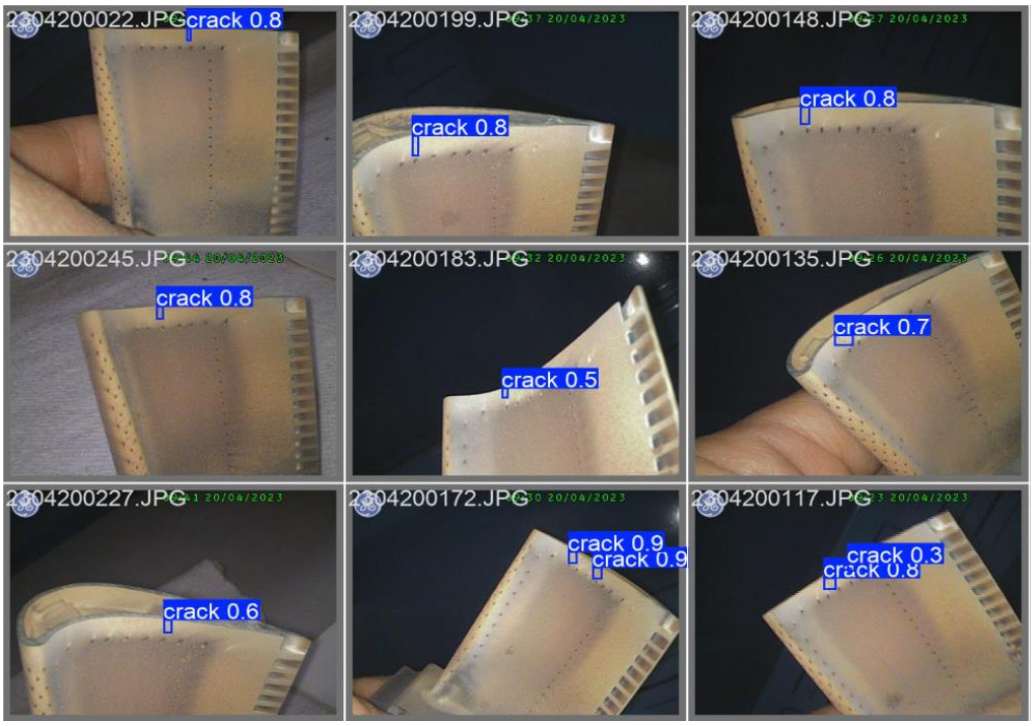

图 4.3.16 检测效果图

从图 4.3.10 至图 4.3.16 的检测效果图，是通过模型的 predict.py 所预测出来的图片，将其组合起来的显示。其中，图 4.3.10 至图 4.3.14 为将损伤设置成“0”时，模型训练后预测得到的效果图，可以看到此时模型依旧可以准确识别到损伤的具体位置。图 4.3.15 至图 4.3.16 则是将损伤类别设置为“crack”时，通过训练模型所得到的预测图，可以看到模型同样也可也准确识别到损伤的具体位置，在此基础上设置不同的置信度标准，我们可以看到模型依旧可以在不同的置信度标准下准确识别出损伤的具体位置。综上所述，我们可以看到随着的模型的训练加深，模型所能预测的结果越来越准确，搭建的模型具有准确识别到损伤的具体位置的能力。

4.4 本章小结

本章首先介绍了如何让进入管理者界面，创造虚拟环境并将其激活，之后在如何下载搭建模型所需要的软件和其对应的相关版本。接着介绍了相关的部分代码，并说明了这些代码的代表意义和如何根据自己的需求去设置合理的参数。然后列出了模型训练之后所得到的数据所需要参考的一些指标，并阐述了这些指标的含义和如何计算这些指标，以及计算公式中的缩写字符的具体含义。

最后再将自己通过训练模型所得到的相关数据和图表展现出来，具体介绍了这些图标的含义和图标上的相关数据，以此来说明建立搭建好的相关模型训练的比较成功，以及可以准确预测损伤的具体位置。最终，通过使用本文方法对孔探图像数据进行试验验证，其检测精

度达到 90.50%，相比传统方法有较大提升。

第五章 总结与展望

5.1 本文总结

本研究针对航空发动机探伤检测的实际需求，构建了一套完整的智能图像识别系统。通过改进卷积神经网络结构，系统在保持运算效率的同时，显著提升了裂纹、烧蚀等典型损伤的识别准确率。

在技术创新方面，系统通过多传感器数据融合技术，成功克服了复杂背景干扰对检测精度的影响。轻量化模型设计使算法能够在移动终端稳定运行，配合模块化硬件平台，实现了从图像采集到结果输出的全流程自动化。

相较于传统检测方式，本系统展现出三方面显著优势：一是通过智能导航与图像增强技术，能够发现人工检测易忽视的隐性损伤；二是采用标准化检测流程，使不同操作者的检测结果具有高度一致性；三是集成化的设计缩短了检测周期，提高了检测效率。这些改进为航空发动机的预防性维护提供了新的技术路径。

值得关注的是，系统在孔探图像智能识别中的优异表现，验证了深度学习算法在细微损伤识别方面的潜力。通过迁移学习机制，系统能够快速适应不同机型和新材料的检测需求，这种灵活性为技术推广奠定了基础。但在实际部署中仍需注意，检测结果的可靠性依赖于持续优化的样本库和规范的设备维护流程。

5.2 未来展望

展望未来，建议在三个方面持续改进：一是加强跨平台数据兼容性研究，建立统一的检测标准体系；二是探索边缘计算与 5G 技术的深度融合，提升野外作业的实时性；三是开发智能决策支持模块，将损伤检测与维修方案推荐有机结合。这些改进方向将推动智能检测系统在航空安全领域发挥更大价值。

参考文献

[1]敖良忠,马瑞阳,杨学文.基于 DenseNet 和 ResNet 融合的发动机孔探图像分类研究[J].计算技术与自动化,2021,40(03):105-110+183.DOI:10.16339/j.cnki.jsjsyzdh.202103019.

[2]陈鑫硕.基于深度学习与数字图像处理的发动机燃烧室裂纹识别方法[D].华中科技大学,2022.DOI:10.27157/d.cnki.ghzku.2022.005334.

[3]黄睿,成旭毅,汪若飞,等.自适应参数分析结果的航空发动机孔探图像损伤检测[J].中国图象图形学报,2023,28(10):3136-3148.

[4]何宇豪,曹学国,刘信良,等.基于 SW-YOLO 模型的航空发动机叶片损伤实时检测[J].推进技术,2024,45(02):197-203.DOI:10.13675/j.cnki.tjjs.2302058.

[5]傅荣春雪,刘君强,冯潇楠,等.基于剪枝和去噪的航空发动机故障图像识别与预测[J].航空计算技术,2023,53(02):40-44.

[6]闫子砚.基于深度学习的航空发动机典型孔探损伤检测方法研究[D].中国民航大学,2023.DOI:10.27627/d.cnki.gzmhy.2023.000082.

[7]何超,陈果,王雨薇.基于深度学习的航空发动机内部损伤实时检测方法[J].航空动力学报,2023,38(08):1857-1864.DOI:10.13224/j.cnki.jasp.20210381.

[8]李小丽,陈新波,吴松华,等.基于图像预处理的发动机叶片掉块损伤自动测量技术[J].推进技术,2023,44(04):220-229.DOI:10.13675/j.cnki.tjjs.210916.

[9]蔡舒妤,何冲.基于 FDG-YOLO 轻量化模型的航空发动机损伤检测方法[J/OL].北京航空航天大学学报,1-11[2025-02-24].https://doi.org/10.13700/j.bh.1001-5965.2024.0024.

[10]李耀华,刘传召.融合注意力机制的轻量化航空发动机表面缺陷检测算法[J/OL].航空动力学报,1-12[2025-02-24].https://doi.org/10.13224/j.cnki.jasp.20240096.

[11]Svensen M, Hardwick D, Powrie H. Deep neural networks analysis of borescope images[C]//Proceedings of the European Conference of the PHM Society. 2018, 4.

[12]Shen Z, Wan X, Ye F, et al. Deep learning based framework for automatic damage detection in aircraft engine borescope inspection[C]//2019 International Conference on Computing, Networking and Communications (ICNC). IEEE, 2019: 1005-1010.

[13]Aust J, Shankland S, Pons D, et al. Automated defect detection and decision-support in gas turbine blade inspection[J]. Aerospace, 2021, 8(2): 30.

[14]Wong C Y, Seshadri P, Parks G T. Automatic borescope damage assessments for gas turbine blades via deep learning[C]//AIAA Scitech 2021 Forum. 2021: 1488.

[15]Zhang D, Zeng N, Lin L. Detection of blades damages in aero engine[C]//2020 Chinese Automation Congress (CAC). IEEE, 2020: 6129-6134.

[16]Li X, Wang W, Sun L, et al. Deep learning-based defects detection of certain aero-engine blades and vanes with DDSC-YOLOv5s[J]. Scientific Reports, 2022, 12(1): 13067.

[17]Upadhyay A, Li J, King S, et al. A deep-learning-based approach for aircraft engine defect detection[J]. Machines, 2023, 11(2): 192.

[18]Wang D, Xiao H, Huang S. Automatic defect recognition and localization for aeroengine turbine blades based on deep learning[J]. Aerospace, 2023, 10(2): 178.

[19]Uzun İ. Damage detection in aircraft engine borescope inspection using deep learning[J]. 2023.

[20]Shang H, Yang Q, Sun C, et al. Superpixel perception graph neural network for intelligent defect detection[J]. arXiv preprint arXiv:2210.07539, 2022.

[21]叶嘉欣. 基于深度学习的两阶段目标检测算法综述 [J]. 互联网周刊, 2023, (05): 16-18.

[22]Girshick R, Donahue J, DarrellT,e t a l.R i c h f e a t u r e h i e r a r c h i e s f o raccurate object detection and semanticsegmentation[C]//Proceedings of the IEEEconference on computer vision and patternrecognition.2014:580-587.

[23]吴素雯,战荫伟.基于选择性搜索和卷积神经网络的人脸检测[J].计算机应用研究2017,(9),2854-2857,2876.

[24]侯明伟.基于空间金字塔池化的卷积神经网络图像分类算法[D].武汉:武汉大学,2018.

[25]杨伟,杜学峰,张勇.基于深度学习的车辆目标检测算法综述[J].汽车实用技术2022,(2):24-26.

[26]G i r s h i c k R. F a s t r-c n n[C]//Proceedings of the IEEE international conferenceon computer vision.2015:1440-1448.

[27]WEI LIU, ANGUELOV DRAGOMIR, ERHAN DUMITRU, et al.SSD: Single Shot MultiBox Detector [C]// European Confer-ence on Computer Vision, 2016: 21-37.

[28]SHIFENG ZHANG, WEN LONGYIN, BIAN XIAO, et al. Sin-gle-shot Refinement Neural Network for Object Detection[C]//IEEE/CVF Conference on Computer Vision and PatternRecognition, 2018: 4203-4212.

[29]朱豪,周顺勇,刘学,等.基于深度学习的单阶段目标检测算法综述[J].工业控制计算机,2023,36(04):101-103.

[30]JOSEPH REDMON, DIVVALA SANTOSH, GIRSHICK ROSS, etal. You Only Look Once: Unified, Real -Time Object Detec-tion[C]// IEEE Conference on Computer Vision and

PatternRecognition, 2016: 779-788.

[31]JOSEPH REDMON, FARHADI ALI. YOLO9000: Better, Faster,Stronger [C]// IEEE Conference on Computer Vision and Pat-tern Recognition, 2017: 6517-6525.

[32]JOSEPH REDMON, FARHADI ALI. Yolov3: An incrementalimprovement[J]. arXiv preprint arXiv:1804.02767, 2018.

[33]KAIMING HE, ZHANG XIANGYU, REN SHAOQING, et al.Deep Residual Learning for Image Recognition [C]// IEEEConference on Computer Vision and Pattern Recognition,2016: 770-778.

[34]TSUNG -YI LIN, PIOTR DOLLAR, ROSS GIRSHICK, et al.Feature pyramid networks for object detection[C]// IEEE Con-ference on Computer Vision and Pattern Recognition, 2017:936-944.

附录 模型部分相关代码

```
nc: 80  # number of classes 数据集中的类别数，也就是你要检测的类别数
depth_multiple: 0.33  # model depth multiple  模型层数因子(用来调整网络的深度)
width_multiple: 0.50  # layer channel multiple 模型通道数因子(用来调整网络的宽度)

anchors: # 表示作用于当前特征图的Anchor大小为 xxx
# 9个anchor，其中P表示特征图的层级，P3/8该层特征图缩放为1/8,是第3层特征
  - [10,13, 16,30, 33,23]  # P3/8，  表示[10,13],[16,30], [33,23]3个anchor
  - [30,61, 62,45, 59,119]  # P4/16
  - [116,90, 156,198, 373,326]  # P5/32


# YOLOv5s v6.0 backbone
backbone:
  # [from, number, module, args]
  [[-1, 1, Conv, [64, 6, 2, 2]],  # 0-P1/2，通过该层之后特征图的大小变成原图的1/2
   [-1, 1, Conv, [128, 3, 2]],  # 1-P2/4，通过该层之后特征图的大小变成原图的1/4
   [-1, 3, C3, [128]],         # 2，通过该层之后特征图的大小不变
   [-1, 1, Conv, [256, 3, 2]],  # 3-P3/8，过该层之后特征图的大小变成原图的1/8
   [-1, 6, C3, [256]],          # 4，通过该层之后特征图的大小不变
   [-1, 1, Conv, [512, 3, 2]],  # 5-P4/16，，过该层之后特征图的大小变成原图的1/16
   [-1, 9, C3, [512]],
   [-1, 1, Conv, [1024, 3, 2]],  # 7-P5/32
   [-1, 3, C3, [1024]],
   [-1, 1, SPPF, [1024, 5]],  # 9
  ]

# YOLOv5s v6.0 head
head:
  [[-1, 1, Conv, [512, 1, 1]],
   [-1, 1, nn.Upsample, [None, 2, 'nearest']], #11 不改变通道数，特征图的长和宽会增
加一倍
   [[-1, 6], 1, Concat, [1]],  # 12 cat backbone P4 与第6层的输出进行特征图的融合
   [-1, 3, C3, [512, False]],  # 13

   [-1, 1, Conv, [256, 1, 1]],
   [-1, 1, nn.Upsample, [None, 2, 'nearest']],
   [[-1, 4], 1, Concat, [1]],  # cat backbone P3，与第4层的输出进行特征图的融合。
   [-1, 3, C3, [256, False]],  # 17 (P3/8-small)

   [-1, 1, Conv, [256, 3, 2]],
   [[-1, 14], 1, Concat, [1]],  # cat head P4，与第14层的输出进行特征图的融合
   [-1, 3, C3, [512, False]],  # 20 (P4/16-medium)
```

```
  [-1, 1, Conv, [512, 3, 2]],
  [[-1, 10], 1, Concat, [1]],  # cat head P5，与第10层的输出进行特征图的融合
  [-1, 3, C3, [1024, False]],  # 23 (P5/32-large)

  [[17, 20, 23], 1, Detect, [nc, anchors]],  # Detect(P3, P4, P5)
]
```

致　　谢

六年的大学生活即将迎来终点，在此刻，内心充盈着感激之情的我，要向那些在学业与成长道路上给予帮助的人们表达最真挚的谢忱。

首当其冲需要感谢的是我的导师陈果教授。从选题确定到框架搭建，从研究开展到细节完善，直至最终论文成稿，倾注了大量心血的您始终以渊博学识与严谨作风指引着我前进的方向。对学术孜孜以求的执着精神，对创新思维的积极鼓励，以及对学生的包容理解，这些品质深刻塑造了我处理问题的思维方式。即便日常教务繁忙异常，仍会定期抽出时间给予悉心指导的您，帮助我攻克了论文写作中遇到的诸多困惑与难题。

必须提及的是何超师兄在研究过程中给予的无私援助。初涉课题时的茫然无措，实验设计阶段的反复修改，经验丰富且专业功底扎实的师兄都提供了有力支持。至今仍保持每日关切的他，常以自身经历为例给出极具价值的建议。对待论文必须一丝不苟的告诫声犹在耳畔，提醒着我每个细节都需要审慎推敲。

这段求学岁月承载了太多难忘片段：初入校园时的雀跃心情、南非航校训练期间的文化冲击、退飞转专业时的迷茫彷徨、直至如今适应新生活的从容淡定。人生难免遭遇挫折磨砺的事实已被深刻认知——学会接纳挫折并从失败中汲取教训的能力正促使着更好的自我不断成长。在此向六年来所有给予支持的师长同窗致以最深切的感恩之意。