

编号 _____



南京航空航天大学

本科毕业设计（论文）

题 目

基于目标检测的孔探图像裂纹识别
方法研究

学生姓名

杜伟

学 号

071951116

学 院

通用航空与飞行学院

专 业

交通运输（民航维修工程）

班 级

0720902

指导教师

陈果教授

二〇二四年六月

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）所涉及的研究工作做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： 2024 年__月__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： 2024 年__月__日

日期： 2024 年__月__日

摘 要

在现代航空工业中，传统的孔探检测方法凭借其直观、易操作的特点，曾在早期的航空发动机维修保养中发挥了不可替代的作用。当航空业规模越大时，此方法的局限性也愈发明显。目前，航空发动机内部损伤的检测主要依赖于检测人员通过观察发动机内部的图像来判断是否存在损伤或缺陷。这种方法虽然直观有效，但在实际操作过程中，由于个人经验、视觉疲劳等原因，检测人员的判断可能会出现偏差，带来了巨大的人为错误的风险。所以，亟需寻求一种既能有效地提高探测精度，又能有效地提高探测效率的方法。

为此，本项目拟采用深度卷积神经网络来实现对航空发动机内部结构的高精度、实时性的识别。该系统利用深度学习算法处理复杂的图像数据，自动识别和诊断发动机内部的微小损伤，实现了对孔探图像的自动化分析。主要工作体现在以下几方面：

(1) 对不同类型的损伤进行分类，并对每个损伤部位进行精确的标注，确保训练的模型能够覆盖所有可能出现的损伤情况。

(2) 通过改进的 YOLOv4 网络模型，对已有的图像标记数据进行训练。结合深度神经网络的特点，实现对复杂场景下的目标检测。在此过程中，我们要不断地对参数进行调整，以保证模型能够对各种类型的损伤进行精确的判定。

(3) 通过对训练参数的调整和改进，我们进一步提高了模型的平均精确率，平均精度 MAP (mean average precision) 约为 86.6%。

经过实际试验验证，表明本文研究的检测方法展现出了较高的性能，不仅提高了检测的精度，而且大幅度降低了人力成本和错误率。

关键词：航空发动机，损伤检测，目标检测，孔探图像，故障诊断，深度学习

ABSTRACT

In the modern aviation industry, the traditional hole detection method has played an irreplaceable role in the early maintenance of aviation engines by its intuitive and easy to operate characteristics. As the industry gets bigger, the limitations of this approach become more apparent. At present, the detection of internal damage of aero engine mainly relies on the inspection personnel to judge whether there is damage or defect by observing the images inside the engine. Although this method is intuitive and effective, in the actual operation process, due to personal experience, visual fatigue and other reasons, the judgment of the detection personnel may be biased, which brings a huge risk of human error. Therefore, it is urgent to seek a method that can effectively improve the detection accuracy and detection efficiency.

Therefore, this project intends to use deep convolutional neural network to realize the high-precision and real-time recognition of the internal structure of the aero engine. The system uses deep learning algorithm to process complex image data, automatically identifies and diagnoses the tiny damage inside the engine, and realizes the automatic analysis of the borehole image. The main work is reflected in the following aspects:

(1) Classify different types of injuries and accurately label each injury site to ensure that the trained model can cover all possible injury situations.

(2) Through the improved YOLOv4 network model, the existing image labeling data is trained. Combined with the characteristics of deep neural network, the object detection in complex scenes is realized. In this process, we need to constantly adjust the parameters to ensure that the model can accurately determine various types of damage.

(3) By adjusting and improving the training parameters, we further improved the average accuracy of the model, and the mean average precision MAP (mean average precision) was about 86.6%.

The test results show that the detection method presented in this paper not only improves the accuracy of detection, but also greatly reduces the labor cost and error rate.

Keywords: aeroengine, Damage detection, Target detection, Borehole image, Fault diagnosis, Deep learning

目 录

第一章 绪论	- 1 -
1.1 研究目的与意义	- 1 -
1.1.1 研究目的	- 1 -
1.1.2 研究意义	- 3 -
1.2 国内外研究现状	- 3 -
1.2.1 孔探检测技术发展概况	- 3 -
1.2.2 孔探智能检测技术发展现状	错误!未定义书签。
1.3 问题的提出	错误!未定义书签。
1.4 本文的主要研究工作与组织结构	错误!未定义书签。
第二章 深度学习理论基础	- 10 -
2.1 引言	- 10 -
2.2 卷积神经网络概述	- 10 -
2.2.1 卷积层	- 11 -
2.2.2 池化层	- 12 -
2.2.3 完全连接层	- 13 -
2.3 基于 one-stage 的目标检测算法	- 14 -
3.3.1 YOLO	- 14 -
3.3.2 SSD	- 14 -
2.4 基于 two-stage 的目标检测算法	- 15 -
2.4.1 R-CNN	- 15 -
2.4.2 fast R-CNN	- 16 -
2.4.3 Faster R-CNN	- 16 -
2.5 搭建深度学习实验环境	- 17 -
2.5.1 硬件环境配置	- 17 -
2.5.2 软件环境配置	- 17 -
2.6 本章小结	- 18 -
第三章 孔探图像的获取与预处理	- 19 -
3.1 引言	- 19 -
3.2 航空发动机常见故障类型	- 19 -
3.3 孔探图像数据获取方法	- 21 -
3.4 孔探图像预处理	- 22 -
3.4.1 调节图像尺寸	- 22 -
3.4.2 图像平滑处理	- 22 -
3.4.3 图像几何变换	- 23 -
3.4.4 孔探图像标注	- 25 -
3.5 本章小结	- 25 -
第四章 基于 YOLOv4 的孔探图像训练方法试验验证	- 26 -
4.1 引言	- 26 -
4.2 方法流程	- 26 -
4.3 实验方案及内容	- 26 -
4.4 实验验证结果	- 32 -
4.5 本章小结	- 32 -
第五章 结论与展望	- 33 -

5.1 结论	- 33 -
5.2 展望	- 34 -
参 考 文 献.....	- 35 -
致 谢.....	- 37 -

第一章 绪论

1.1 研究目的与意义

1.1.1 研究目的

在航空业中，为了保证飞行的安全性，飞机必须定期进行维修和保养。高效率和高质量的维修是保证飞行安全的关键。航空发动机是飞行器的“心脏”，工作在高速、高温、高压等苛刻条件下，其叶片受外物打伤、转静碰摩、燃烧、腐蚀等，极易产生各种故障或损伤^{[1][2]}，如叶片磨损、卷曲、裂纹等。





图 1.1 某发动机中的裂纹与腐蚀照片

叶片作为航空发动机的核心部件，因其数量众多、外形单薄、服役环境恶劣、服役环境复杂等特点，已成为发动机服役与试验过程中失效率较高的部件。从设计到制造、使用到维护等整个发动机生命周期的各个阶段，曾因失效导致了重大的经济损失和严重的军事后果。随着无损检测技术的发展，内窥式损伤技术^{[3][4][5]}已被引入到发动机维护工作中，并逐渐发展为航空发动机的故障监控与诊断，其对航空发动机的内部损伤状态起着非常重要的作用。孔探技术通过光学图像传输内部状态，由工作人员对光学图像进行观察和判断，从而对航空发动机的内部状态进行评价，即使是一些很难拆卸或容易到达的零件，也可以用上述方法进行检测。



1—低压压气机；2—高压压气机；3—外涵道；4—燃烧室；5—涡轮；6—加力燃烧室

图 1.2 某航空发动机内部结构示意图

航空发动机孔探探伤是指在发动机壳体上开一道观察孔，用孔探仪对其进行可视化检查，该方法无需拆卸，即可直观地观察发动机的内部情况。高压低压压气机和高压低压涡轮的关键零部件，如轮盘，叶片，燃烧室，都是难以拆卸和检测的零件，目前主要采用孔探技术进行检测和监控。有效的延伸了人类视觉范围^{[6][7]}，该技术能够将不能用肉眼直接看到的部件以图象的方式呈现在显示屏上，从而极大地提升了工作效率，为发动机的日常监测、节约维护费用，同时也为准确评价发动机的内部损伤和及时修复提供了重要的理论依据。

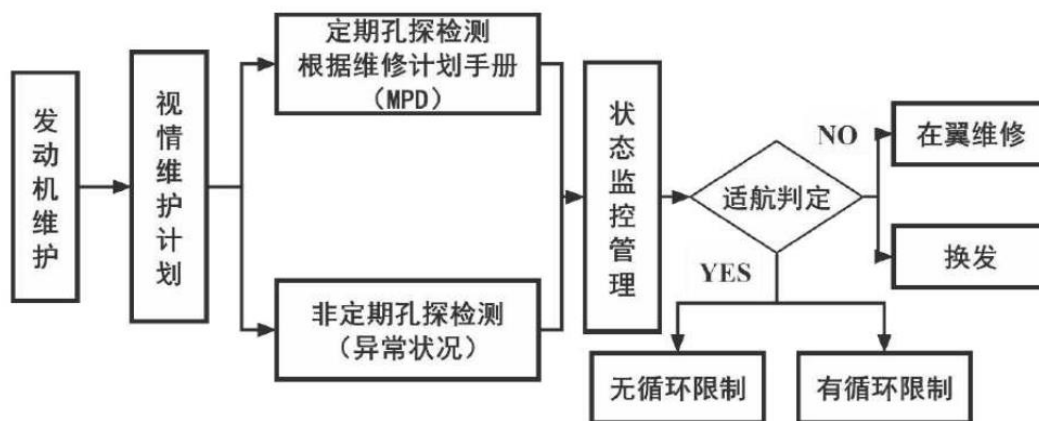


图 1.3 孔探检测流程

孔探检测技术能够发现发动机内部的剥落、锈蚀、裂纹、烧熔和积碳等损伤情况，对于了解发动机的工作状况，寻找故障点，保证发动机的安全可靠运行有着十分重要的作用。正常情况下，发动机需要按规定做孔探，但也有例外，例如引擎超载、踢震、发现异物、外部异物损伤、某些参数不正常等等。孔探检测技术是航空设备维护人员对发动机内部状况的一种非常有效的检测方法。因此，在航空发动机的维护和维护工作中，采用孔探技术是必不可少的。



图 1.4 工程师在使用孔探仪检查发动机

1.1.2 研究意义

孔探检测技术由于其非接触、直观、快速等优点，目前已被广泛用于航空探伤。目前，利用孔探影像进行结构损伤评估主要依赖于专家的经验，容易造成大脑疲劳和注意力下降，同时，工作人员对损伤评定标准的理解不一^{[8][9]}，操作熟练程度参差不齐，损伤叶片尺寸的测量受到人为干扰较大。上述各种原因都会导致操作失误，从而对飞机的运行造成一定的安全风险。所以，在飞机众多、分布广泛、专家稀少的条件下，很难对飞机引擎的损坏进行及时的评价。

因此，开展基于目标探测的孔探图像探测与识别方法研究，在军民两个领域都有着广阔的应用前景。

1.2 国内外研究现状

1.2.1 孔探检测技术发展概况

孔探技术是利用光学仪器将被封闭物的内部状态通过小孔传输，进而对其进行评价、检测和诊断。孔探技术能够扩展人眼的视觉范围，使其能够自由地改变视野，并能精确地观测到被测物体的内部情况。此外，在孔探探测时，没有与目标物相接触，没有造成任何的损坏或损坏，也没有必要对目标物体进行拆解或拆卸。该方法是实现工业无损检测（NDT）的一种重要方法，尤其在航空检验等方面具有广阔的应用前景。孔探仪（以下简称内窥镜）是孔探探测的硬件，而孔探图像的特征提取和分析是其软件的依据，两者是影响孔探探测效果的关键因素。



图 1.5 奥林巴斯内窥镜镜头

在目前的研究中，孔探技术主要分为硬棒式、软管式光纤镜和软管式电子镜三个时期。1806年，德国科学家 Philipp Bozzini 发明了首部医疗内窥镜。1921年，美国开发出了世界上首部工业内窥镜。1954年，英国首次提出光纤光导光纤，三年后，全球首架光纤式十二指肠镜问世，标志着第二代内视镜的问世。1970年，电荷耦合件（Charge Couple Device, CCD）诞生。1983年，美国韦林公司经过8年的研发，成功研发出全球第一套电子内窥镜，并成功投入临床使用，标志着该仪器已发展到第三代。其中，刚性棒内窥镜因不能弯曲，探测距离较短，所以经常被应用于一些距离较短的直线腔内。柔性光导纤维作为导光和传像元件，具有较好的导光性能和较宽的视场角，得到了广泛的应用。



图 1.6 韦林孔探仪的发展示意图

目前，光纤镜面中的光学导纤通常由上万根束扎成，存在着光学元件容易折断、成像过程中容易出现黑点等问题。该产品涉及一种内视镜、光源、影像处理中心、影像显示系统、影像录制系统、辅助设备等。电子显微镜（TEM）的出现，极大地拓展了孔探测的应用领域，它不但可以用于静态空腔、容器、管道等的巡视，还可以对人体器官、旋转机械的运动进行实时成像观测、记录与显示，对于发动机等机械设备的内部损伤检测与故障诊断有着重要的意义。电子孔探仪是近年来发展起来的一种新型仪器，它的功能与性能得到

了很大的改善。日本奥林巴斯（OLYMPUS），美国韦林（Everest VIT）等几家知名的仪器制造商，其产品都是世界上最先进的仪器。

孔探技术的发展离不开光电技术、计算机技术和传感技术的共同发展，奥林巴斯就是凭借着它的尖端 CCD 技术，才在国际上占据了一定的地位。孔探检测技术的发展趋势如下：

（1）自动化（automatic）。既可以采用无线方式，也可以通过有线方式进行远程控制，既可以降低设备对操作者的专业要求，又可以防止孔探仪损坏。

（2）3D 显示。为维修工作提供指导，使维护费用降到最低。

（3）现场内窥式维护。利用孔探仪对叶片叶片的卷曲、碳粒的清除等进行无需拆卸的作业，从而大大节约了维护的时间与人力成本。

（4）专业化。利用神经网络、机器学习和专家系统等计算机手段，对采集到的孔探图像和视频资料进行全面的分析和处理，给出具有一定参考意义的意见或评估报告，从而减少由于人为因素导致的测量误差或偏差。

现阶段，仅仅通过将测试数据录入软件，无法精确地判断出缺陷的严重程度，因此，在实际工作中，仍需要操作者通过对影像中的损伤检测，再对照工作手册和工作单卡片来进行判别。基于已有的研究成果，本项目拟在前期工作基础上，深入开展基于孔探影像的结构损伤自动识别^[10]与精确测量方法研究，对减少从业人员的工作难度、工作经验、节约专业训练费用具有重要意义。

1.2.2 孔探智能检测技术发展现状

（1）深度学习方法概述：

新兴深度学习方法已开始应用于图像目标检测，其发展可分为 R-CNN(Regions with CNN features)家族为代表的两阶段(Two-Stage)目标检测算法和以 YOLO(You only look once)及其衍生算法为代表的单阶段(One-Stage)目标检测算法。

Two-Stage 目标检测算法第 1 阶段主要是寻找目标位置并得到候选区域，第 2 阶段才聚焦于分类候选区域并得到 1 个更加准确的目标位置，“两步走”策略在提高探测准确率的同时，也带来了模型庞大、资源消耗大、探测速度慢等问题，无法满足实时性的需求。后续的衍生化算法被不断完善，以进一步提升探测的速度和准确性。在这些方案中，YOLOv4 的探测能力较好，探测速度较快，基本上可以达到对终端设备的性能及速率的需求，更适于在终端上使用。

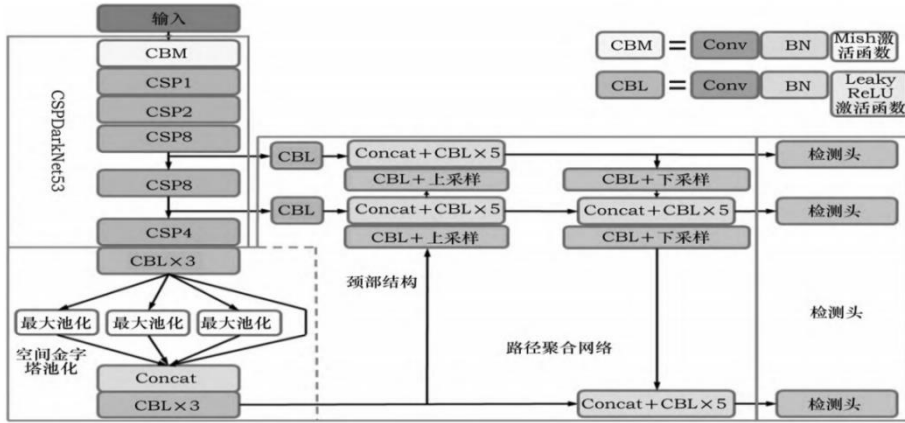


图 1.7 YOLOv4 网络结构模型

(2) 深度学习方法的应用：基于机器学习的方法在近年来得到了广泛的关注和应用，其主要思想是通过训练模型，自动识别和分类检测的故障类型和位置。卷积神经网络（CNN，Convolutional Neural Network）是目前常用的一种基于深度学习的孔探探测方法。卷积过程示意图如图 1.8。CNN 能够从原始的振动信号中学习到有关故障模式的高级特征，进而实现对孔探目标部位的准确诊断。此外，还有一些研究基于深度学习模型改进的方法，如使用残差模块（Residual Block）来增强模型的性能和稳定性。




图 1.8 卷积过程示意图

(3) 综合方法：国外的研究工作注重跨领域合作和实际应用。研究者们与机械工程师、领域专家和工业界合作，共同开展孔探检测的研究。他们利用实际工况下的数据集进行实验和验证，评估算法的性能和适用性。

综上所述，国内外的研究者在基于目标检测的孔探图像裂纹识别领域开展了丰富的研究工作。传统机器学习方法和深度学习方法被广泛应用于故障诊断任务，通过提取有效的特征和利用高级模型实现了一定程度的成功^{错误!未找到引用源。}。

1.3 问题的提出

尽管目前孔探检测技术在孔探设备、图像采集与再现、判识等方面都有了很大的发展，但是，在外场维修中，装备的孔探测试设备大多为单物镜孔探仪，存在零部件种类多、故

障类型多、难以获得海量孔探图像样品等问题，限制了诸如立体视觉、模式识别等前沿科技的发展。根据目前的装备状况，通过调研、总结和分析，指出了目前我国航空发动机的孔探测试中仍存在的若干技术问题有待解决。

孔探数据处理与特征提取等方面的研究亟待改进。目前，在航空发动机的外场试验中，利用图像中的缺陷特征来进行检测，主要依靠操作员的经验，再将其与真实的零件尺寸进行比较，进而进行大致的转换或估计。然而，在实际应用中，由于人为因素的影响，往往会出现错误的评定结果，从而给飞机带来严重的安全隐患和浪费。为此，急需进一步完善孔探资料的处理和特征提取技术。本项目拟将当前较为成熟的小孔探成像技术引入孔探检测，研究快速高效的孔探图像特征提取方法，降低人工经验对探测结果的依赖程度，提升探测精度，提升探测工作的效率，消除探测过程中存在的安全隐患，降低人为因素带来的损失。

提高了系统的故障诊断精度与自动化程度。然而，目前对其进行检测的方法还不够完善，这就给故障的诊断和判定带来了困难和精度的下降。另外，航空发动机维修手册种类繁多，缺乏系统性，散落在多本维修手册中，现有的故障判定方法以手工为主，遇上困难时需参考相关说明书，较为复杂的问题则交给维修专家解答。这不仅给现场工作人员带来了很大的工作量，同时也降低了伤情鉴定的精度，延长了伤情判断和判断的时间。因此，亟需开发一套既能有效降低操作人员工作负荷，又能提升故障诊断的精度与效率的航空发动机故障快速准确诊断技术。

综上所述，根据目前的航空发动机孔探检测技术现状，研究并应用孔探图像特征提取技术^{错误!未找到引用源。错误!未找到引用源。}，实现发动机缺陷特征的精确测量与自动快速判决迫在眉睫。

监督学习（Supervised Learning）与无监督学习（Unsupervised Learning）是机器学习中的两种基本方法。它们的主要区别在于数据的使用方式不同。

监督学习是从已有的标记数据中学习模型。具体来说，监督学习算法会接收一组输入数据，然后根据这些数据产生相应的输出或结果，这些结果已经被标记为正确答案。机器学习算法会通过对比其产生的答案和真实答案，不断调整模型参数，以尽可能提高预测准确性。

无监督学习则是让算法自行从没有标记的数据中找出规律和结构。无监督学习主要用于数据的降维、聚类、降维和关联规则挖掘等等问题。例如，K-means 聚类算法可以将高维数据降至低维，同时将相似的数据点聚集在一起。虽然监督学习和无监督学习在很多情

况下都是独立的，但它们也可以结合使用。例如，在深度学习中，常见的做法是先用无监督学习对数据进行预处理，然后再用监督学习进行模型的训练和优化^{错误!未找到引用源。}。

在实际应用中，选择哪种学习方法取决于具体的问题和数据。对于那些有大量标记数据的问题，监督学习通常是更好的选择，因为它可以利用这些数据来训练出精度更高的模型。而对于那些没有标记数据或者需要找出数据内在结构的问题，无监督学习则更有优势。如图 1.9，在故障诊断中会提取信号的多个特征，图中横坐标与纵坐标分别表示样本特征的两个维度，图中使用两个维度进行示意。总的来说，无监督学习相比监督学习，前者具有更广泛的应用领域、更好的数据探索和分析能力、更好的适应性和鲁棒性等优势。监督学习和无监督学习是机器学习的两个重要分支，各有其适用的场景和优势。理解它们的差异和特点，对于更好地应用机器学习技术来解决实际问题具有重要的意义。

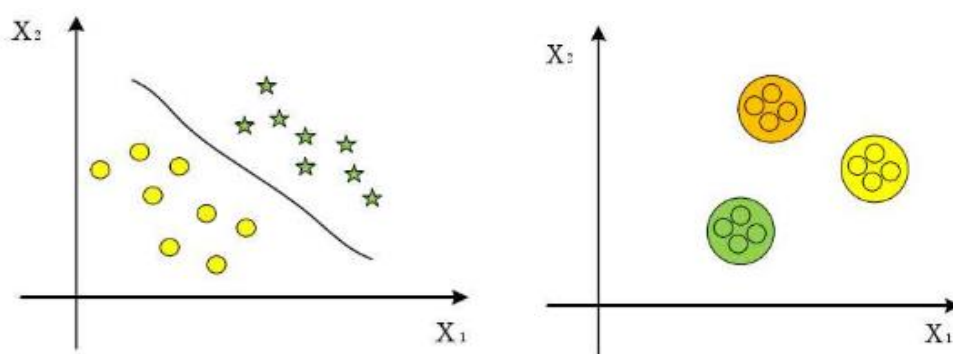


图 1.9 监督学习与无监督学习区别

通过无监督学习的目标检测的孔探图像裂纹识别方法研究^{错误!未找到引用源。}，我们可以深入了解孔探检测的方法，为相关领域的研究提供重要的参考和支持。

首先，无监督学习方法能够从未标记的数据中学习和发现发动机故障的潜在模式和规律，避免了依赖大量标记样本的限制。这为大规模发动机故障诊断提供了可行的解决方案，减少了人力和时间成本。

其次，基于无监督学习的方法能够充分利用孔探检测的运行数据，实现对多维特征的自动提取和学习，从而更全面、准确地评估发动机的健康状态。这不仅有助于及早发现发动机的早期故障迹象，还能提供有效的预警和预防措施，避免故障的扩大和设备的停机。

此外，基于无监督学习的方法具有较强的泛化能力^{错误!未找到引用源。}，可以适应不同类型和规模的发动机。这为不同行业和领域的工程师和维护人员提供了通用的故障诊断工具，有助于提高设备的可靠性和运行效率。

1.4 本文的主要研究工作与组织结构

本文主要围绕基于目标检测的孔探图像裂纹识别方法在航空发动机孔探损伤识别的运用进行研究，针对当前发动机孔探技术的实际应用现状，通过对航空发动机结构、孔探技术原理、识别其损伤类别、卷积神经网络、深度学习等深入学习，实现对航空发动机内部损伤的智能检测，文章分为四个章节，各章节安排如下。

第一章，主要围绕本课题的研究背景、研究意义、孔探技术的国内外发展现状、孔探检测图像识别技术的运用以及近些年目标检测的研究现状展开论述，指出了研究本课题的实际应用价值。

第二章，主要对卷积神经网络、深度学习进行了概述，分析了目前主流的基于目标检测模型的深度学习算法，主要包含 two-stage 检测的 R-CNN 系列以及 one-stage 检测 YOLO、SSD，对本课题所选用的 YOLOv4 算法、深度学习框架性能进行了详细的分析研究。对比分析各个参数（卷积核大小、学习率等参数）对模型分类精度的影响程度，并依据结果确定合适的模型参数；对比验证不同目标检测算法分类的精度，说明本文方法的优势。

第三章，主要对孔探图像数据集的获取与预处理进行概述。首先，使用孔探仪作为获取设备，对航空发动机内部进行图片拍摄或视频拍摄，获得航空发动机内部损伤的图片。孔探仪拍摄的图片可以直接选择其中包含损伤的图片作为损伤图像数据；拍摄的视频可以分解为多张图片，选择其中包含损伤的图片作为损伤图像数据。其次，需要对损伤图像进行图像数据增强^{错误!未找到引用源。}，常见的图像增强方法有拉伸、旋转、缩放、平移、噪声等，再将所有图片的损伤部位和损伤类别进行人工标注，增强轮廓特征。获得所有图片对应的标注文件，将所有图片以及对应的标注文件分为训练集、测试集，最后将其中的训练集导入目标检测网络训练。

第四章，基于 YOLOv4 的孔探图像训练方法试验验证，利用现有的带机匣的转子试验器，以及含损伤叶片的盘，采集孔探图像数据，并进行处理。将处理后的孔探图像作为目标检测模型的输入，完成对目标检测模型的训练，实现对孔探图像数据的分类识别，通过提取损伤类型，结合损伤位置、损伤大小和发动机型号，进行维修综合决策。本文提出一种基于目标检测图像的孔探检测方法，该方法利用图像的颜色，纹理，形状，物体的位置，并对试验设备和研究目标等因素进行分析和评价，并用模拟的方式对其进行检验。

第二章 深度学习理论基础

2.1 引言

深度学习（Deep Learning）是一种机器学习技术，它通过模拟人类神经网络的结构和功能，来实现对数据的自动分析、学习、以及自我修正。与传统机器学习不同的是，深度学习更侧重于对数据的抽象和特征提取，而非模型本身。本章对深度学习理论基础展开阐述，对比选择了适合的网络模型建立深度学习网络架构。

2.2 卷积神经网络概述

卷积神经网络（CNN，Convolutional Neural Network）是模拟动物大脑视皮层的工作机理而形成的一种多层神经元网络，不同于完全连接的神经网络，各层神经元通过局域连接来实现^{错误!未找到引用源。}。如图 2.1 中所示，完全联接和局部联接相比。该特性可以很好地解决传统的针对全连接型神经网络在处理图像时，因参数量较多而造成运算时间较长、运算速度较慢等问题。CNN 作为深度学习的主流模型，在图像分类、目标检测、人脸识别、医学影像分析等方面有着广阔的应用前景。




图 2.1 全连接（左）与局部连接（右）对比

一个完备的 CNN 由输入层（Input Layer）、卷积层（Convolution Layer）来获取图像特征，以及激活层（Activation Function）实现多个特征之间的非线性映射，池化层（Pooling）用于压缩特征图，全连接层（Fully Connected Layer）用于分类，卷积神经网络结构图如 2.2 所示。




图 2.2 CNN 结构示意图

2.2.1 卷积层

在 CNN 操作中，卷积运算（如图 2.3）是一个非常核心的操作，用来提取图像的特征，这就是卷积神经网络的名字的由来。卷积网络并非一次就能获得图像的全部信息，它需要先在层中的神经元对其进行局部感知^{错误!未找到引用源。}，然后再经过上层处理才能获得该图像的特征。

卷积神经网络将数据处理分成两个步骤：

- (1) 通过卷积核对特征图进行局部扫描，实现对特征图的加权合并；
- (2) 通过自左至右和自顶向下滑动，实现卷积核对特征图的卷积计算。

在卷积结束后，通过引入 ReLU 函数^{错误!未找到引用源。}，可以有效地训练较为复杂的数据，从而提高了模型的拟合精度。ReLU 函数如图 2.4 所示。卷积神经网络中常用的 sigmoid 函数其函数表达式如 (2.1) 所示，sigmoid 函数的图像如图 2.5 所示。

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$




图 2.3 卷积示意图




图 2.4 ReLU 函数




图 2.5 sigmoid 函数图像

2.2.2 池化层

池化层^{错误!未找到引用源。}是一种实现图像采样的方法，主要作用是对图像进行池化操作。在卷积神经网络中，卷积运算所使用的卷积核一般都比较小（如 $1 \times 1, 3 \times 3, 5 \times 5$ ），因此，在卷积神经网络中引入池化层，将卷积后的特征图降维，降低各特征图的参数。

对卷积后的特征图进行降维，从而减少各个特征图的参数，保证特征图拥有平移不变性。从而降低计算过程的复杂度，提高计算效率，并避免了过拟合。

在具体实践中，根据采集模式的差异，将其划分为两种类型：极大池和均值池。在此过程中，通过调整滑动框的大小和按一定步长移动滑动框，完成特征图的“池化”，再取所有数值的平均值（平均值）或最大值（最大值）。与池化之前相比，利用池化操作得到的新的特征图，能够将特征图的规范约减少一倍，进而提高卷积神经网络的训练效率，实现降采样。

一般情况下，不更新权重，且仅对池层进行研究下降。不重复的区域由于卷积层的池化作用，生成的图像在两个维度中可下降一倍。池化层的过滤器使用了一种更为方便的平均值或者最大值的运算。

公式如 (2.2) 所示：

$$x_j^i = f \left[\beta_j^i \text{down}(x_i^{l-1}) + b_j^i \right] \quad (2.2)$$

x_j^i 即池化层输出的 j 个特征图， $\text{down}(x)$ 即池化函数符号，每个输出图都会有专门定义的 b 和 β_j^i 。

2.2.3 完全连接层

完全连接层（见图 2.6）通常位于卷积神经网络的末端，其作用与完全连通的神经网络相似，包括权值向量和激活函数。完全连接层通过卷积、池化等运算将多维度数据进行拉伸，并将其转换成一种高度抽象的一维向量，并通过权重向量和激活函数增强其非线性表达能力。在进行了一种或几种的全连接运算后，得出的新数据将与样本数据之间有很好的映射关系^{错误!未找到引用源。}。全连接层的输出计算公式如 (2.3) 所示。

$$D = f(wx + b) \quad (2.3)$$

其中 f ， w 和 b 分别代表完全连接层的激活函数，权值矩阵，偏置值； x 和 D 分别代表全连接层的输入和输出。




图 2.6 三层神经网络结构

2.3 基于 one-stage 的目标检测算法

one-stage 算法的典例是 SSD、YOLO 系列等，其特点是该方法无需生成候选框，可直接生成目标的概率及空间坐标，从而提高了检测速度。

3.3.1 YOLO

YOLO 目标检测的核心是把目标区域的预测与目标的类别预测相结合^{错误!未找到引用源。}。YOLO 序列利用单一神经网络对物体的边界及类别概率进行预测，因此能够从终端对终端进行目标检测。由于在产生候选点时花费的时间较少，因此检测率得到了很大的提高，其检测率高达 45 FPS。尽管 YOLO 算法能够在图象中迅速地识别出目标，但是对于一些微小的对象，却很难进行准确的定位。其网络架构如图 2.7 所示。




图 2.7 YOLO 网络架构

3.3.2 SSD

在 2005 年，YOLO 算法提出的同年,Wei Liu 等学者提出了 SSD 算法，该算法借鉴了 YOLO 将检测问题转化为回归问题的思想，结合 Faster R-CNN 中锚框思想，改善了多尺寸目标检测的处理方式^{错误!未找到引用源。}。区别于 YOLOv1 仅对最上层特征图进行预测，SSD 通过对多层卷积后的特征图进行独立检测，以达到对不同大小物体的有效检测，大范围特征映射和小尺度特征映射用于大目标的探测，以充分利用特征信息，SSD 的网络结构如图 2.8。

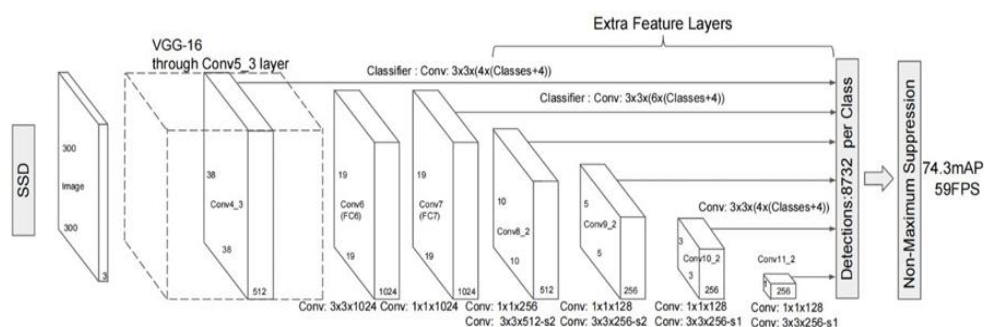


图 2.8 SSD 网络架构

2.4 基于 two-stage 的目标检测算法

两阶段目标检测算法（**two-stage**），顾名思义，整个算法主要经历两个阶段，第一阶段先对输入的图像进行区域生成候选框，第二阶段是通过卷积神经网络进行特征提取并分类^{错误!未找到引用源。}。自 R-CNN 被提出以来，两阶段的目标检测方法得到了快速的发展，目前已发展成为快速 R-CNN、FasterR-CNN、MaskR-CNN 等多种方法。双阶段目标检测方法与单阶段目标检测方法最大的区别在于：先是生成待选区域，然后再对待选区域（背景、物体）进行识别，然后再对目标进行初步定位，因此算法计算量大、检测速度慢，但可以极大地提高识别精度，其检测流程如图 2.9 所示。

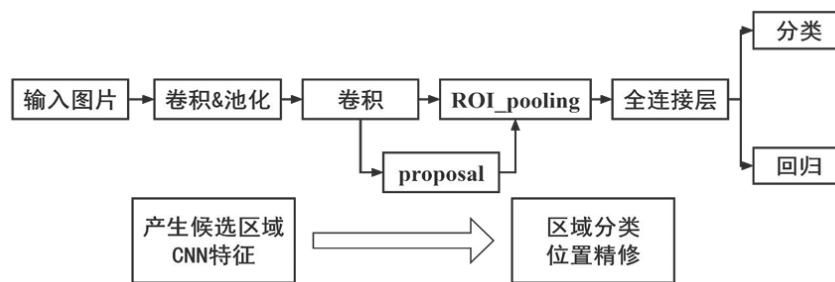


图 2.9 two-stage 检测基本流程

2.4.1 R-CNN

区域建议神经网络（R-CNN）实现了将深度学习技术运用到目标检测技术中，其网络结构如图 2.10。R-CNN 首先利用 Selective Search 算法搜索并生成一系列的候选区域，其原理是对输入的图像按像素进行分组，对全图的像素纹理进行计算，将纹理相近的像素进行组合，然后对组合后的同类像素组不断进行合并^{错误!未找到引用源。}。此阶段会产生 2000 个候选框，然后将生成的候选框送入 CNN 进行卷积，提取区域特征，通过支持向量机 SVM 对图像进行分类。R-CNN 中有 20 个不同的 SVM 分类器，每个分类器都会对生成的候选区域进行二分类并计算分类得分，再通过非极大值抑制 NMS(Non-Maximum 11 Suppression)对最后预测的候选区域进行筛选，其原理是选取得分最高的候选区域，与其余候选区域进行交并比 IoU 计算，按需求设定 IoU 阈值，将 IoU 大于阈值的检测结果进行输出。




图 2.10 R-CNN 目标检测流程

2.4.2 fast R-CNN

Fast R-CNN 是在 R-CNN 基础上发展,其先用 Selective Search 生成 2000 个候选区域,再将整张待识别图像输入卷积神经网络进行特征提取^{错误!未找到引用源。},将前面生成的候选区域的坐标信息映射到卷积神经网络最后一层的特征图上,利用 RoI 池化层对特征图上各候选区域进行最大池化操作,使输入的候选区域进入全连接层时尺寸大小相同,再利用 Softmax 和 bbox regression 完成分类和候选框微调,其结构如图 2.11。与 R-CNN 相比,降低了卷积神经网络的计算量,并且利用神经网络分类替代 SVM 分类,优化了训练过程,降低了训练耗时。




图 2.11 Fast R-CNN 网络结构图

2.4.3 Faster R-CNN

针对 Fast-RCNN 网络中基于选择性搜索的搜索过程耗时过长、检测和训练耗时的问题, Ren S 等人对快速 R-CNN 进行了改进,将 RPN (RPN)引入到快速 R-CNN 网络中,取代传统的 Selective 搜索算法,从而大大加快了候选区域的生成速度。FasterR-CNN 网络结构的 2.12 表示.从该图可以看出,图像是先通过骨干网产生一个特征图形,然后再将该特征图形输入 RPN 得到一个预先选择的框架,然后再进行快速 R-CNN 的处理。

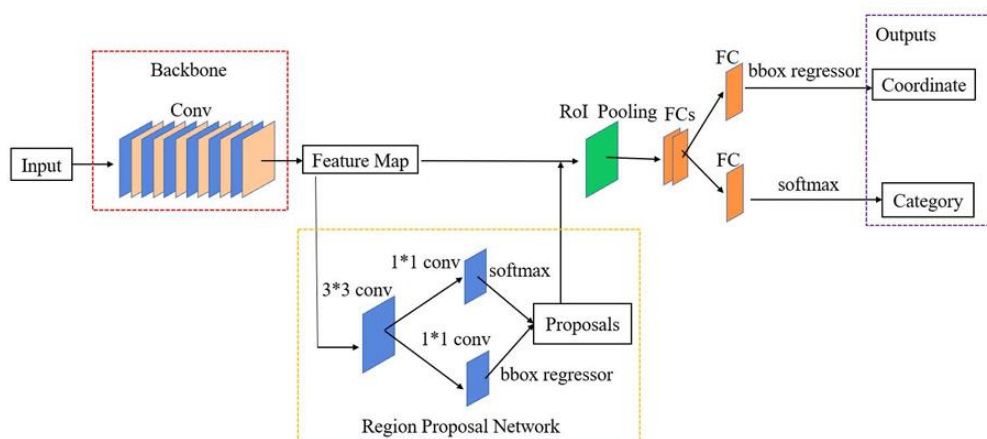


图 2.12 Faster R-CNN 网络结构图

2.5 搭建深度学习实验环境

2.5.1 硬件环境配置

硬件环境配置如表 2.13 所示。

表 2.13 硬件环境配置

设备名称	Lenovo Y7000P
处理器	12th Gen Intel(R) Core(TM) i5-12500H 3.10 GHz
机带 RAM	16.0 GB (15.8 GB 可用)
系统类型	64 位操作系统, 基于 x64 的处理器

2.5.2 软件环境配置

软件环境配置如表 2.14 所示。

表 2.14 软件环境配置

软件	版本
Python	3.9
Pycharm	2022
Visual Studio	2021

2.6 本章小结

在本章中，我们详细地探讨了目标检测算法的发展历程，这是一个不断发展、创新的领域。文章首先概述了卷积神经网络的起源与发展，揭示了它如何从最初的简单网络演变成如今复杂的深度学习结构。接下来，我们深入讨论了这些网络的基本结构及其工作机制。此外，本章还重点介绍了基于 one-stage 的目标检测算法，包括快速增长的流行模型 YOLO（You Only Look Once）和 SSD（Single Shot Multibox Detector）。这些方法专注于直接预测目标位置，而不是对图像进行完整的区域检测。通过对比分析这些算法的工作原理和实现细节，可以更好地理解它们是如何逐步成为高效、准确的检测工具的。

另一方面，本章节也涵盖了基于 two-stage 的检测器，如 R-CNN（Region Convolution Neural Network）、fast R-CNN 和 faster R-CNN。这些技术进一步细分为多个步骤，允许模型更精细地定位和识别目标。文章详细介绍了这些两阶段检测器的基本网络结构和它们如何协同工作来提高检测精度。

最后，为了能够直观地了解和评估所介绍的算法，本章还构建了一个深度学习实验环境。这个环境提供了一系列的算法框架、预训练模型以及评估指标，使得研究人员和开发者可以轻松地将理论知识应用到实际的实验中。通过这样的实验环境，可以更加便捷地探索目标检测技术的前沿进展，并在实践中验证理论的有效性。

第三章 孔探图像的获取与预处理

3.1 引言

孔探图像是一种特殊的光学成像，因此它对图像的质量要求很高。在实际应用中，一般采用孔探专用镜头获得高质量的图像。在孔探图像采集过程中，由于环境、设备及操作等诸多因素的影响，图像往往会出现多种噪声，导致图像质量下降。这时就需要一些预处理方法提高图像质量，以便于更好的检测出损伤位置。

3.2 航空发动机常见故障类型

航空发动机一般包括风扇、压气机、燃烧室和涡轮机等多个部分。航空发动机长时间工作在高温、高压、高速等工况下，存在着大量的安全隐患。

航空发动机核心部件的故障^{错误!未找到引用源。}通常有如下几个方面的原因：

高压压气机故障，主要是由于收到吸入空气的冲击，产生巨大的噪音，导致叶片损伤，还可能导致发动机喘振，导致机体疲劳损伤，如图 3.1。转子和静子作为压气机中的两个重要部件，直接关系到压气机的工作性能。压缩机转子既是高速旋转的部件，又是承载体，在承受弯矩和转矩等载荷的同时，还要承受离心力的作用。与转子不同，压气机定子是由叶片、内壳体等构件构成的静止承载体，承担着来自其它结构部位的轴向力、转矩、振动等载荷。与静液静压转子相比，压气机转子在空气动力、交变载荷及离心载荷下的工况更加苛刻，不仅要承受气动载荷、交变载荷和离心载荷的作用，而且还会受到来自进气道的外部载荷（FOD）和风沙的侵蚀，因而更容易失效，其常见的故障如图 3.2。



图 3.1 高压压气机位置




图 3.2 常见压气机故障

燃烧室失效，在飞机飞行中，发动机长期工作在较高的温度下，极易发生燃烧室失效。长期处于高温环境中，其主要失效形式为燃烧室的烧蚀、烧穿、脱落等热破坏，如 3.3 所示。如果在此过程中，没有使用孔探技术，而是让飞机继续飞行，那么燃烧舱的漏气就会导致外壳的破损，一旦破损，那就是灾难性的。所以，在对柴油机燃烧室的故障进行分析时，必须对喷油嘴进行检查。




图 3.3 燃烧室各区分布图

高压涡轮故障，导叶工作区温度极高，极易受不合理温度分布、温度场突变和不稳定燃烧等多种因素的影响，造成导叶前缘烧蚀、尾缘开裂、变形甚至脱落，如图 3.4。在高速旋转条件下，高转速下的涡轮转子同样易发生烧蚀、卷曲、脱落、烧蚀、开裂、积碳等。



图 3.4 高压涡轮故障发生区域

3.3 孔探图像数据获取方法

目前，孔探探伤^{错误!未找到引用源。}是一种常用的诊断方法，它是以前探仪为采集装置，通过拍照或者录像的方式，对飞机发动机的内部结构进行拍照或者录像，从而得到飞机发动机的内部损坏情况，然后在南京航空航天大学智能诊断专家实验室进行图像分析，具体流程如图 3.5。

本文孔探图像数据通过前往西安某研究所，获取发动机孔探图像数据约 200 张并进行分类，如图 3.6。利用孔探仪采集到的影像，将其分解成若干幅影像，并以此影像资料为基础，建立了孔探影像资料数据集。航空发动机叶片工作环境苛刻，多处于高温高压工况，其主要失效形式有剥落、开裂和腐蚀等，图 3.7 显示了一种飞机发动机 (a)掉块，(b)裂纹和 (c) 腐蚀。



(a) 实物图 1



(b) 实物图 2



图 3.5 孔探仪采集与计算机检测同步实现示意图




图 3.6 某类发动机孔探图像数据（部分）



图 3.7 发动机常见缺陷

3.4 孔探图像预处理

由于孔探仪是一种手持式设备，在实际工作中，由于手持设备不稳定，发动机内部光线较暗，故障种类较多，导致采集到的部分原始图像含有较多的噪音，所以必须对其进行数据平滑、降噪、去重等预处理工作。在此基础上，本项目拟开展基于几何变换、高斯噪声处理、随机裁剪等方法的数据增广研究。

3.4.1 调节图像尺寸

已获取的原始孔探影像分辨率通常为 $720*480$ ，但在实际应用中，部分图像侧面往往存在了多余的边界信息与无需探测的物体。因此，通过调节孔探图像的尺寸，使其能够在一批次内对多幅图像进行训练。

3.4.2 图像平滑处理

在进行孔探探测时，由于发动机内光线条件不佳^{错误!未找到引用源。}，采集图像受到了很大的干扰。在探伤过程中，由于噪声的存在，使得图像的质量变差，不利于对其进行有效的特征提取。图像平滑处理实质上就是一个低通滤波器，它能滤除高频的干扰成份及噪音，同

时保留低频讯号，使图象更平滑。均值滤波器又称线性滤波器，是一种常用的近邻平均方法。该算法的主要思想是将原始图像中每一个像素的值替换为均值，但该算法在去除噪声的过程中存在着对图像细节的损失

标签平滑（Label Smoothing），即对最终分类置信度的修正方法，它是一种正则化的方法，只不过这种方法是通过在 label 中添加噪声，从而实现对模型的约束，目的是防止模型在训练时过于自信地预测标签，防止过拟合，提高模型的泛化能力。

机器学习^{错误!未找到引用源。}中的数据往往含有少量的错误标签，这种标签过多会降低预测结果的准确性。标签平滑化的思想是在训练阶段就假定标记有可能出错，从而避免对训练样本的标记“过分”地信任。

当目标函数为交叉熵时，这一思想有非常简单的实现。使用平滑标签方法后，可以将卷积神经网络的训练目标从 1 调整为 0.95 或是 0.9，这个值由人为设定，这样会使得卷积神经网络对于自身的判断没有 100% 的把握。平滑标签的计算方法如式（3.1）所示。

$$L = y \times (1 - l) + \frac{l}{n} \quad (3.1)$$

其中 L 为进行标签平滑后的数值，y 为不同类别的置信度，l 为设定的标签平滑的参数，本文中取值为 0.01，n 为所有种类的数量。

在大多数情形下，标签平滑都能得到更好的校正网络，进而更好地去泛化网络，对未知的生产数据进行更精确的预测。因此，标签平滑应该是大多数深度学习训练的一部分。

3.4.3 图像几何变换

孔探图像的几何转换^{错误!未找到引用源。}是指对图像进行翻转、旋转（90°、180°、270°）、裁剪、缩放、调节对比度与亮度等操作，在不同的空间转换模式下，能够产生不同的图像增强效果。在实际的发动机孔探测试中，相机的视角一直在不断地改变，所以对于零件的表面缺陷方位不太敏感。通过对同一类型的缺陷进行几何变换，使同一类型的缺陷具有不同的视觉信息，从而保证了所获取到的缺陷特征能够满足工作要求。

（1）裁剪。是指从原始图片中随机裁剪一张图片，然后把这张图片放大到原来的尺寸，这就是随机裁剪。该方法能够在不完全获取对象信息的情况下，对待辨识对象进行随机裁剪，从而提高了目标检测网络的普适性能力，如图 3.8 所示。




图 3.8 图像裁剪前后对比

(2) 缩放。缩放是将原始图片按一定的比例在一定的范围内进行等比例的缩放。经过缩放运算后，可以将影像中的像素值进行变换，如图 3.9。





图 3.9 缩放前后对比

(3) 旋转。就是在一个特定的区域中，随机选择一个特定的角度，然后顺时针或逆时针转动。由于原始图像的视角相对固定，因此采用旋转的方法可以很好地解决这一问题，从而实现了从多个角度对物体进行有效的识别，如图 3.10。



3.10 旋转前后对比

3.4.4 孔探图像标注

使用 Labelimg 软件分别对各类损伤的孔探图像进行分类标注^{错误!未找到引用源。}，通过该软件可以识别所有的孔探图像数据集，对每一张孔探图像输入其对应的损伤类别后，再对损伤区域进行标注。标注文件在 Annotations 文件夹下，图像文件在 JPEGImages 文件夹下。再将数据集放置在根目录的 VOCdevkit\VOC2007 下。Labelimg 软件标注后如图 3.11 所示。



图 3.11 孔探图像标注图

3.5 本章小结

本章对航空发动机的主要部位——压气机、燃烧室和涡轮机等进行了详细的介绍，并对其常见故障进行了分析。随后是孔探图像数据的采集工作，包括采集孔探图像使用硬件设备以及设备的工作过程展示。在此基础上，研究了孔探图像的预处理方法，包括图像几何转换和图像平滑处理等，以实现孔探影像的数据增强，以满足卷积神经网络的训练需求，最后使用 Labelimg 标注工具对孔探图像进行标注工作，建立实验中使用的孔探缺陷图像数据集。

第四章 基于 YOLOv4 的孔探图像训练方法试验验证

4.1 引言

本章描述了试验验证的具体流程，首先使用自航空发动机上现场采集的不同故障状态下的样本数据的孔探数据，再分类进行预处理后，导入搭建的深度学习框架进行试验验证，从而进一步验证本文方法对于真实航空发动机孔探检测技术的有效性。

4.2 方法流程

使用孔探设备获取航空发动机损伤图像数据后，由于拍摄孔探视频的孔探仪为手持设备，在拍摄过程中因手持设备不稳、发动机内部光线昏暗且缺陷类型复杂多变等原因，使得采集的部分原始图像中存在许多噪声污染^{错误!未找到引用源。}，因此需要经过数据预处理。

首先需要对损伤图像进行图像数据增强，例如 Mosaic 数据增强方法、图像平滑、数据去噪、数据去重等。

然后将所有图片的损伤部位和损伤类别进行人工标注，获得所有图片对应的标注文件，将所有图片以及对应的标注文件分为训练集、测试集，将其中的训练集导入改进后的 YOLOv4 目标识别网络训练^{错误!未找到引用源。}。

最后将孔探损伤图像的训练集导入的目标检测网络，使用不同的训练策略训练后，得到不同的目标检测模型。使用测试集分别测试模型的所有类别的平均精确率（MAP, Mean Average Precision），比较模型之间的 MAP，选择最优的模型即可，流程图如图 4.1 所示。

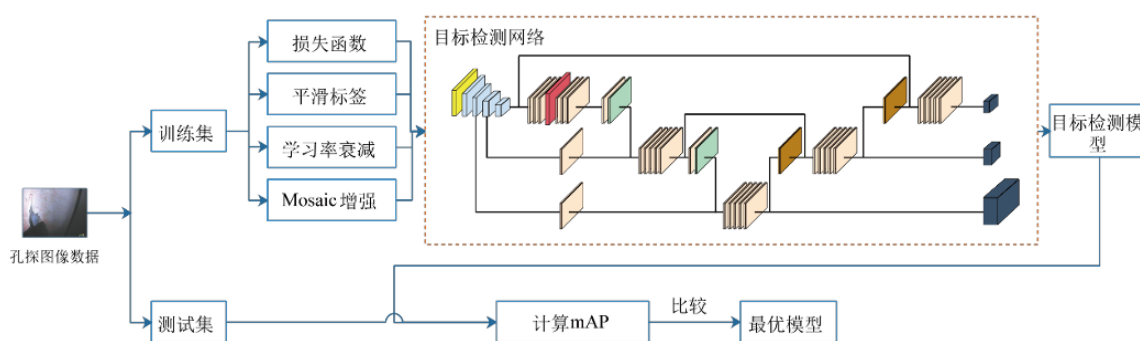


图 4.1 航空发动机损伤检测模型训练流程

4.3 实验方案及内容

为了达成本文章所谈方法在实际情况下的基于 YOLOv4 的孔探图像训练方法试验验证中的可行性，我们收集了一部分孔探图像数据进行实验验证。

(1) 准备数据集

孔探图像数据集采集自西安某研究所，整理分类为三类，分别为掉块、裂纹、腐蚀，后对其使用 `labelimg` 标注，获得图像对应的标注文件。（标注文件在 `Annotations` 文件夹下，图像文件在 `JPEGImages` 文件夹下。再将数据集放置在根目录的 `VOCdevkit\VOC2007` 下）。




图 4.2 孔探图像（部分）

(2) 划分数据集

修改 `model_data\voc_classes.txt` 的种类，再运行根目录下的 `voc_annotation.py` 即可划分训练集和测试集。

keys	values
<code>model_path</code>	<code>logs\last_epoch_weights.pth</code>
<code>classes_path</code>	<code>model_data\voc_classes.txt</code>
<code>input_shape</code>	<code>[640, 640]</code>
<code>phi</code>	<code>n</code>
<code>confidence</code>	<code>0.001</code>
<code>nms_iou</code>	<code>0.5</code>
<code>letterbox_image</code>	<code>True</code>
<code>cuda</code>	<code>True</code>

图 4.3 本次训练参数

(3) 训练

直接运行根目录下的 `train.py` 即可训练，训练好的模型都在 `logs` 文件夹下。（选）可调参数，例如：①`mosaic: True\False`②`mixup: True\False`；③`Label smoothing`: 标签平滑。一般 0.01 以下。如 0.01、0.005。

```

pretrained = False
#-----#
# mosaic      马赛克数据增强。
# mosaic_prob 每个step有多少概率使用mosaic数据增强，默认50%。
#
# mixup       是否使用mixup数据增强，仅在mosaic=True时有效。
#            只会对mosaic增强后的图片进行mixup的处理。
# mixup_prob  有多少概率在mosaic后使用mixup数据增强，默认50%。
#            总的mixup概率为mosaic_prob * mixup_prob。
#
..

mosaic      = True
mosaic_prob = 0.5
mixup       = True
mixup_prob  = 0.5
special_aug_ratio = 0.7
#-----#
# label_smoothing  标签平滑。一般0.01以下。如0.01、0.005。
#-----#
label_smoothing = 0

```

图 4.4 不同参数得出不同结果

（4）测试（可选）

首先打开根目录下的 `yolo.py`，将 `model_path` 改为训练好的模型目录，把所有需要测试的图像放在根目录的 `img` 文件夹中，然后运行 `predict.py` 文件，测试结果会自动生成在 `img_out` 文件夹中。

（5）量化指标（mAP, mean Average Precision）

通过 3.9 版的 Python，使用 2022 版 Pytorch 作为本次试验深度学习框架，在硬件 12th Gen Intel(R) Core(TM) i5-12500H 上实现目标识别模型的训练与测试。模型训练轮次 (Epoch) 设置为 100，前 25 轮设为 0.001，Batch Size 设置为 4，学习率为 0.0001，Batch Size 设置为 2。

首先打开根目录下的 `yolo.py`，将 `model_path` 改为训练好的模型目录，再运行根目录下的 `get_map.py`，会自动生成一个结果，包含 mAP, P-R 曲线, F1 曲线等等。

通过这些实验数据，我们可以对本文提出的方法进行验证，并评估其在实际航空发动机孔探检测中的有效性。

平均准确率 mAP (Mean Average Precision) 表示了不同类型的孔探缺陷的平均 AP 值，能够反映整个模型的整体性能。在 (4.1) 中表示它的计算公式，N 表示孔探缺陷类别的个数。通过对不同类型的缺陷检测，得出相应的 AP 值，并求其平均值。

$$mAP = \frac{\sum_{i=1}^n AP_i}{N} \quad (4.1)$$

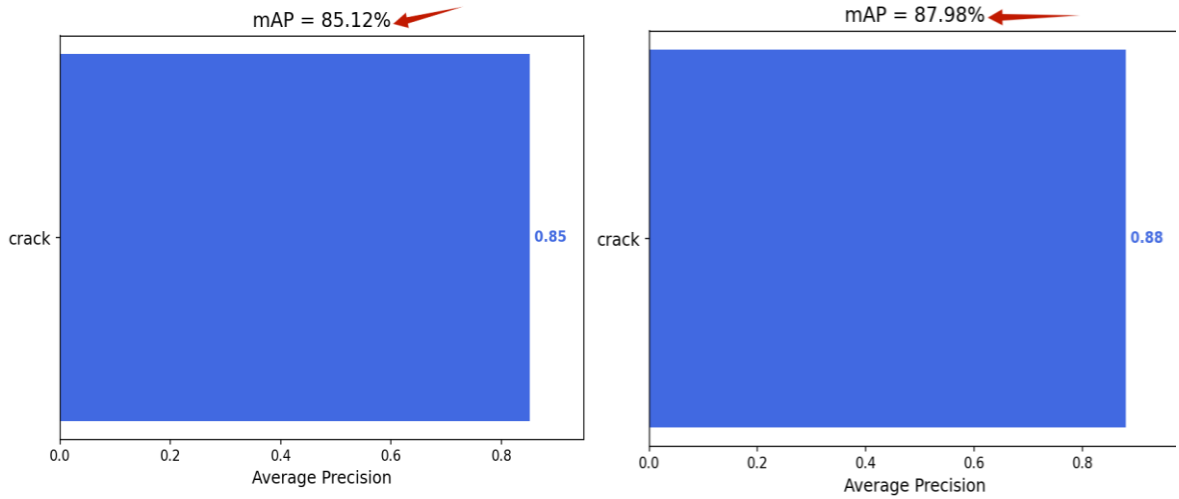


图 4.5 对比试验 MAP 图

在航空发动机孔探缺陷自动检测中，平均准确率 AP（Average Precision）的数值为 P-R 曲线组成的面积，平均准确率的计算式为(4.2)。AP 值越大，说明模型的检测性能越好。

$$AP = \int_0^1 P(R) dR \quad (4.2)$$

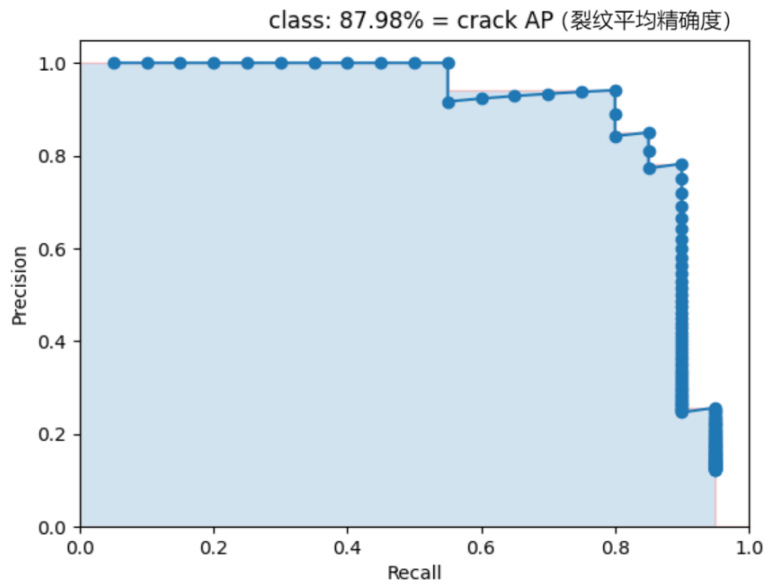


图 4.6 本次训练裂纹 AP

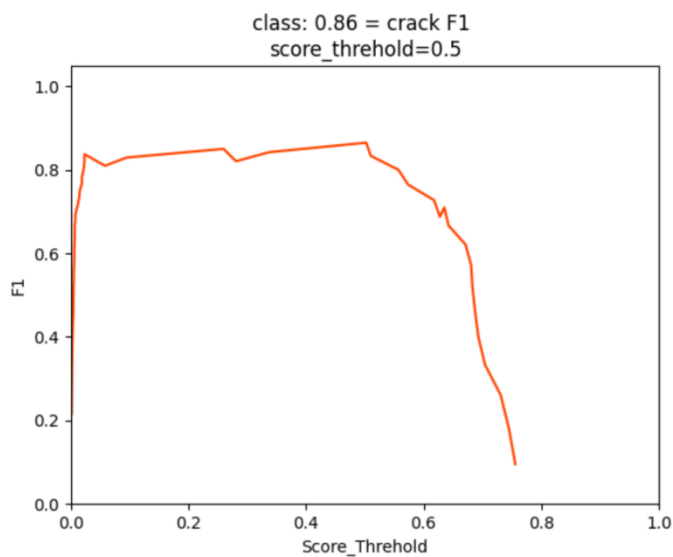


图 4.7 本次训练 F1 曲线

F1-score，全称为 F1 分数，是统计学中用于衡量二分类模型精确度的一种指标。它同时考虑了分类模型的精确率和召回率，是精确率和召回率的调和平均数。F1-score 的取值范围在 0 到 1 之间，其中 1 表示模型完美的分类性能，0 表示模型没有分类性能，越靠近 1，说明性能越好。

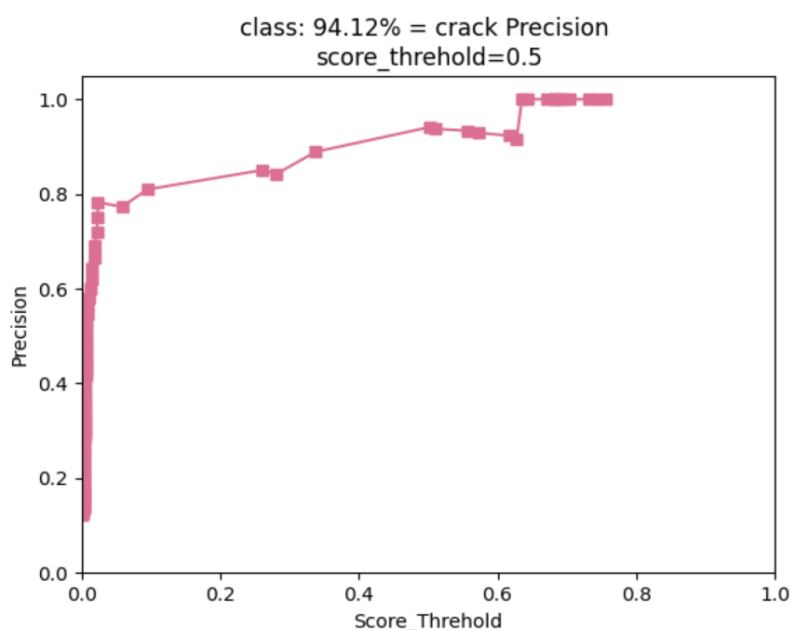


图 4.8 本次训练 crack precision（裂纹精确度）

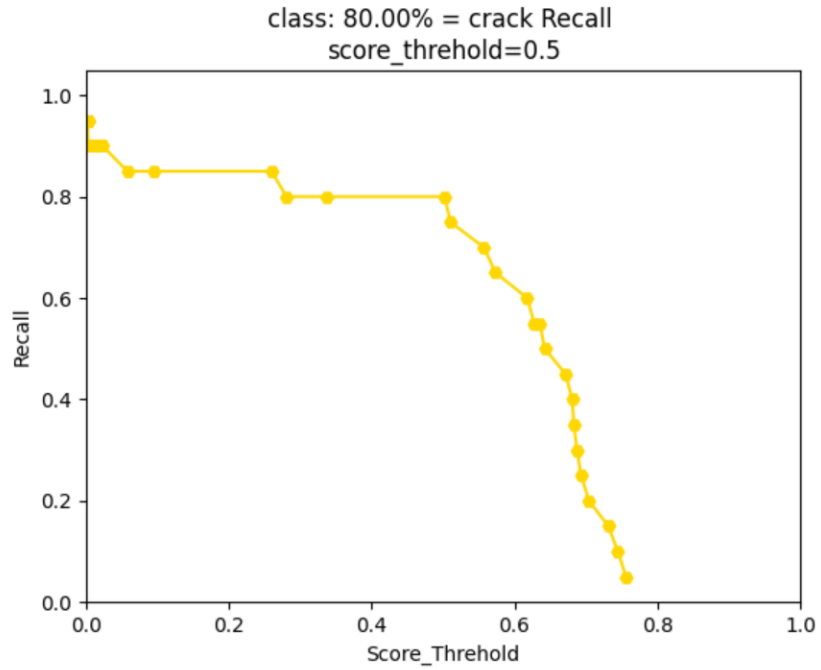


图 4.9 本次训练 Crack recall（裂纹召回）

召回率（Recall）又被称为查全率，表示预测结果为正样本中实际正样本数量占全样本中正样本的比例。

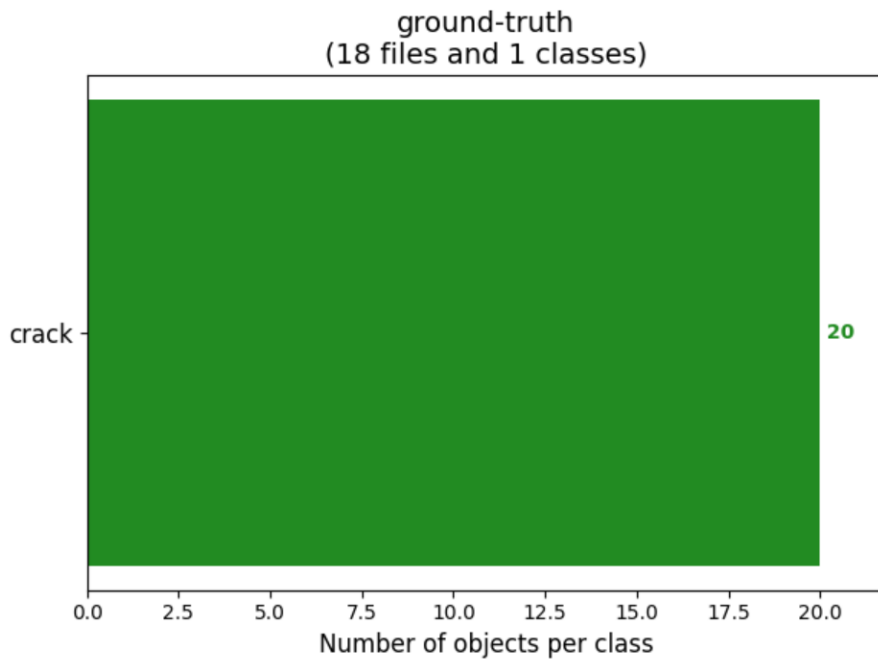


图 4.10 本次训练 ground-truth（真实数据）

4.4 实验验证结果

在本次实验中,采用了大约 200 张各类孔探数据图片,以保证数据的准确性和可靠性。在数据处理过程中,我们按照 8:2 的比例将正常样本划分为训练集和测试集,并使用训练集进行模型的训练。在模型训练完成后,我们将所有的样本用于模型的测试,以验证模型的有效性和泛化能力。

我们进行了在修改各项参数后进行了多次试验,取精度最高的前 5 组实验对比数据如图 4.11 所示,经过实际试验验证,表明本文研究的基于深度卷积神经网络的检测方法展现出了较高的性能。它不仅提高了检测的精度(最高 89.37%, 平均 86.6%),更重要的是,该方法的引入显著提升了检测工作的灵活性和可扩展性,为航空公司提供了更为可靠、经济的解决方案,从而保障了航空安全。

图 4.11 实验数据对比结果

训练组数	Map	裂纹 AP	F1 曲线	crack precision	Crack recall
1	89.37%	89.37%	0.89	95.32%	80.00%
2	88.56%	88.56%	0.88	95.23%	80.00%
3	87.43%	87.43%	0.87	95.18%	80.00%
4	87.24%	87.24%	0.87	94.82	80.00%
5	85.12%	85.12%	0.85	94.12%	80.00%

4.5 本章小结

为了进一步验证本文方法对于真实航空发动机孔探检测技术的有效性,本章使用了自航空发动机上现场采集的数据进行了实验,分别获取了不同故障状态下的样本数据。通过实验数据的处理和模型的训练,验证了该方法在实际航空发动机孔探检测中的有效性,结果表明本文方法为实际航空发动机孔探检测提供了一种新的有效技术途径和方法。

第五章 结论与展望

5.1 结论

孔探检测是解决发动机零件表面缺陷的一种重要方法，它可以有效地消除传统的手工探伤方法中漏检、误检的缺点；传统的工作条件对孔探工人的专业素养、实际工作经验等提出了更高的要求；钻井工人的工作时间以夜间作业为主，工作强度大，工作压力大；人工检验存在着耗时、成本和经济效益较高等问题。

针对叶片损伤检测中存在的复杂背景，卷积神经网络比传统图像识别方法更具优势。在深入研究和分析 faster-RCNN 以及 YOLOv3 两大主流计算机视觉算法的基础上，通过对采集到的 200 多张样本图像进行处理，增强了数据集的多样性和丰富性，从而提高了模型对于叶片损伤特征的识别能力。特别是针对掉块、撕裂、裂纹以及压坑四种常见损伤类型，我们采用了更为先进的特征提取技术，有效提升了算法在复杂背景下对这些关键特征的辨识精度。此外，还对模型进行了适当的参数调整和超参数优化，使得最终的诊断结果更加精准可靠，能够为叶片健康状况评估提供有力的技术支撑。

在此基础上，提出了一种新的基于 YOLOv4 的方法，并将其与深度学习相结合，进行了一种新的无损检测方法，该方法能够在较短的时间内达到较好的检测效果。其主要工作如下：

(1) 在参考了当前国际上关于发动机孔探缺陷检测的研究成果的基础上，本文采用基于深度学习的目标检测方法，实现孔探缺陷的探测与定位，并将其应用于发动机孔探的检测与定位。

(2) 本文对深度学习中的目标检测方法进行了阐述，并对卷积神经网络的相关理论进行了介绍，并对基于 one-stage 检测器和 two-stage 检测器的神经网络模型进行了分析。在此基础上，搭建深度学习试验平台，进行试验对比，全面、系统地分析和对比主流的神经网络模型在探伤中的准确性和速度，并以此为基础，进行实验验证。

(3) 研究图像数据增强算法，并以此为基础，开展图像数据转换和多元综合算法的试验，验证所提出的算法的有效性，使得卷积神经网络能够更好地进行特征抽取。

(4) 通过研究基于 YOLOv4 的孔探检测网络和目标检测网络，在保持精度为 86% 以上的前提下，加快检测速度，平均 FPS 可达 50 以上，从而实现了对孔探的快速检测。

5.2 展望

本文为实现基于目标检测的孔探图像自动化和实时检测提供了一种有效的思路和方法，但仍有待于进一步深入研究。

（1）在孔探图像损伤目标检测训练之前，常常需要对已获得的孔探图像损伤数据集进行人工标注，这一步人工操作会降低整个流程的效率，因此，如何设计开发一个对孔探图像数据集自动标注的软件将会是未来研究的方向，解决这一问题可实现全流程的自动化。

（2）在此基础上，可以研制出一套基于孔探图像探测的目标探测网络的专用软件，并继续对该仪器的硬件设施进行进一步的深入研究，从而使其达到一个更高的层次，从而使整个孔探检测过程的工作效率得到提升。

（3）近年来，随着科技的不断进步，基于深度学习的技术已经在图像处理领域取得了显著的发展。这种方法以其强大的学习能力和适应性而备受瞩目。展望未来，我们可以预见一个专为孔探图像设计的目标探测网络将产生。这个网络将会集成先进的算法和高效的训练技术，使之能够更精准地识别和检测目标。通过这些新技术，孔探图像的分析与处理将变得更加智能化和高效化，从而大幅提升目标探测的准确性和效率。

参考文献

- [1] 何超. 基于 YOLOv4 的航空发动机内部损伤检测方法[D], 南京航空航天大学, 2022
- [2] 王雨薇. 基于深度学习的智能化孔探图像检测技术及其试验验证[D], 2023
- [3] 张雯雯, 周正东, 管绍林等. 电子内窥镜的研究现状及发展趋势[J]. 中国医疗设备, 2017, 32(01): 93-98.
- [4] 于辉. 孔探技术及其在航空发动机维修中的应用[J]. 航空制造技术, 2005(6): 94-96.
- [5] 谢小荣, 吴德新, 江涛. 立体视觉视频孔探仪及其应用[J]. 机电产品开发与创新, 2008, 21(1): 58-59.
- [6] 兰健. 浅谈发动机孔探检查过程中的风险管理[J]. 科技风, 2014(3): 239-239.
- [7] 张勇. 航空发动机故障诊断中孔探图像特征提取技术应用研究[D]. 国防科学技术大学, 2006.
- [8] 陈果, 汤洋. 基于孔探图像纹理特征的航空发动机损伤识别方法[J]. 仪器仪表学报, 2008, 29(08).
- [9] 张维亮. 航空发动机叶片损伤图像快速识别技术研究[D]. 沈阳航空航天大学, 2014.
- [10] 李华. 基于孔探图像分析的航空发动机故障诊断专家系统研究[D]. 南京航空航天大学, 2015.
- [11] 丁鹏, 李长有, 马齐爽等. 基于小波的航空发动机叶片孔探损伤检测[J]. 北京航空航天大学学报, 2006, 32(12): 1435-1438.
- [12] 孟娇茹, 王娟. 孔探成像在发动机损伤检测中的应用研究[J]. 节能技术, 2009, 27(01): 69-73.
- [13] 徐龙喜, 陈果, 汤洋. 基于 CBR 的远程发动机孔探评估专家系统[J]. 南昌航空大学学报(自然科学版), 2007, 21(03): 58-61.
- [14] 钱征文, 程礼, 赵兵兵, 等. 基于 BP 神经网络的叶片损伤度评估方法[J]. 航空动力学报, 2011, 26(04): 794-800.
- [15] 焦李成, 杨淑媛, 刘芳等. 神经网络七十年: 回顾与展望[J]. 计算机学报, 2016, 39(08): 1697-1716.
- [16] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2014, 18(7): 1527-1554.
- [17] 袁桂霞, 周先春. 基于多媒体信息检索的有监督词袋模型[J]. 计算机工程与设计, 2018, 39(09): 2873-2878.
- [18] Hinton G E, Sejnowski T J. Learning and relearning in Boltzmann machines[M]. Parallel distributed processing: explorations in the microstructure of cognition. Cambridge: MIT Press, 1986. 283-289.
- [19] Braun H, Turaga P, Spanias A, et al. Direct classification from compressively sensed images via deep Boltzmann machine[C]. Proc. of the 50th Asilomar Conference on Signals, Systems and Computers. Pacific Grove: IEEE, 2017.
- [20] 刘凯, 张立民, 孙永威等. 利用深度玻尔兹曼机与典型相关分析的自动图像标注算法[J]. 西安交通大学学报, 2015, 49(06): 33-38.
- [21] Pu Y, Gan Z, Heno R, et al. Variational Autoencoder for Deep Learning of Images, Labels and Captions[J]. arXiv:1609.08976.
- [22] Sproat R, Jaitly N. RNN Approaches to Text Normalization: A Challenge[J]. ar Xiv:1611.00068.
- [23] Hochreiter S, Schmidhuber J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(08): 1735-1780.
- [24] Lecun Y L, Bottou L, Bengio Y, et al. Gradient-Based Learning Applied to Document Recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [25] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]. Proc. of the 25th International Conference on Neural Information Processing Systems. Lake Tahoe: NIPS, 2012. 1097-1105.
- [26] 程国建, 郭文惠, 范鹏召. 基于卷积神经网络的岩石图像分类[J]. 西安石油大学学报(自然科学版), 2017, 32(04): 116-122.
- [27] 周云成, 许童羽, 郑伟, 等. 基于深度卷积神经网络的番茄主要器官分类识别方法[J]. 农业工程学报, 2017, 33(15): 219-226.

- [28] 王娜,傅迎华,蒋念平.基于监督的全卷积神经网络视网膜血管分割[J].软件导刊,2018,17(08):45-48,52.
- [29] Saeedan F, Weber N, Goesele M, et al. Detail-Preserving Pooling in Deep Networks[C]. Proc. of the 30th IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City:IEEE ,2018.9108-9116.
- [30] 唐志文, 浅析数字图像处理技术的研究现状及其发展方向[J], 硅谷, 2010,(05):411-450
- [31] 李龙浦, 基于孔探数据的航空发动机叶片损伤识别研究[D]
- [32] 冯瑶, 数字图像处理技术的应用[J], 重庆工贸职业技术学院学报, 2010,(01):16-20
- [33] 万玲, 马兴数字图像处理的方法与应用[J].科技信息, 2010,(23):1110-1114.

致 谢

行文至此，百感交集，恍惚之间，五载如流不可返；己亥至，甲辰离，天目秋冬始，翠屏春夏终。谨以拙笔，致谢众人。

树高千尺不忘根。感谢我的亲人一直默默付出与支持我的学业，他们或许文化程度不高，但却教会了我最朴实的待人接物；他们的臂膀或许并不是那么坚实，却顶起我去看更高的风景，这些支持与关爱让我感到无比温暖。

自懵懂而来，得满载而归，得益于诸位师长。感谢我的导师陈果教授，治学严谨，待人和善，不但对我的学业有很大的引导和帮助，对我今后的生活也有很大的启发；感谢何超师兄，不厌其烦帮扶我的学习，对于我的学术疑惑悉心解答，得此良师益友相陪，实乃人生之幸。

桃李不言，下自成蹊。感谢我大学期间的导员，如海上的灯塔指引着我的人生方向。导员孙献策如长辈般约束我的学习与生活，虽多为严肃，但用心良苦；导员陈冬在我转专业迷茫之际给予我诸多鼓励，让我有了新的目标；导员柳小营，始终如姐姐般关心我的学习，生活和就业，如春风化雨，润物无声。

山水一程，何其有幸。五载同窗友，天南海北来，风格各异，或开朗，或深沉，或洒脱，或细致，齐学习，同生活，共成长。学贵得师，亦贵得友，感恩天空之子，图书馆之陪伴，弥足珍贵，留于心底。

相聚总有离别日，提笔也有终稿时。

祝母校：年年桃李，岁岁芬芳！

祝师长：工作顺利，生活美满！

祝亲人：身体健康，事事顺心！

愿我，终日乾乾，夕惕若厉，穷且益坚，不坠青云之志！