



同濟大學

TONGJI UNIVERSITY

硕士学位论文

(专业学位)

基于图像的空调系统故障
诊断算法研究

姓名：罗为

学号：1630907

所在院系：机械与能源工程学院

专业学位名称：工程

专业领域：动力工程

指导教师：许鹏 教授

副指导教师：

二〇一九年六月



同濟大學
TONGJI UNIVERSITY

A dissertation submitted to

Tongji University in conformity with the requirements for
the degree of Master

Research on HVAC System FDD Algorithm Based on Image

Candidate: Luo Wei

Student Number: 1630907

School/Department: School of Mechanical Engineering

Discipline: Engineering

Major: Power Engineering

Supervisor: Prof. Xu Peng

June, 2019

基于图像的空调系统故障诊断算法研究

罗为

同济大学

学位论文版权使用授权书

本人完全了解同济大学关于收集、保存、使用学位论文的规定，同意如下各项内容：按照学校要求提交学位论文的印刷本和电子版本；学校有权保留学位论文的印刷本和电子版，并采用影印、缩印、扫描、数字化或其它手段保存论文；学校有权提供目录检索以及提供本学位论文全文或者部分的阅览服务；学校有权按有关规定向国家有关部门或者机构送交论文的复印件和电子版；在不以赢利为目的的前提下，学校可以适当复制论文的部分或全部内容用于学术活动。

学位论文作者签名：

年 月 日

同济大学学位论文原创性声明

本人郑重声明：所呈交的学位论文，是本人在导师指导下，进行研究工作所取得的成果。除文中已经注明引用的内容外，本学位论文的研究成果不包含任何他人创作的、已公开发表或者没有公开发表的作品的内容。对本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。本学位论文原创性声明的法律责任由本人承担。

学位论文作者签名：

年 月 日

摘要

空调系统的故障诊断是保持空调系统正常运行、降低建筑能耗的重要手段。然而，目前的故障诊断方法不仅面临着数据难题，还会因为成本高、实施难等原因难以在实际中得到应用。因此，本文选取空调系统热水管道、电机和方形散流器作为研究对象，开发了基于可见光图像和红外图像的故障诊断算法，其中，可见光图像用于设备的分类和定位，红外图像用于故障诊断。相比于传统的故障诊断算法，该算法诊断所需数据类型单一，具有无接触、成本低和部署简单的优点，在实际中可配合建筑巡检机器人完成诊断，实现空调系统的智能化管理。

算法的第一步是判断采集到的图像属于哪种设备。因此，对于空调系统热水管道、电机、方形散流器三种设备类型，本文提出了基于 AlexNet 卷积神经网络（CNN）的设备分类模型，模型输入为设备可见光图像，输出为设备类型。

在热水管道方面，本文针对保温层破损、脱落和漏水故障，开发了相应的故障诊断算法，包括了图像分割、特征分析和故障诊断三个部分。图像分割采用了阈值分割和形态学处理；特征分析包括了温度分析、管径分析和缺陷分析，分别判断管道区域是否存在温度异常、管径异常和缺陷异常；故障诊断根据特征分析的结果，输出诊断的管道类型。检验结果表明，该算法在实验数据和实际数据中具有较高的诊断准确率。

在电机方面，本文先提出了采用基于区域的卷积神经网络（R-CNN）的电机图像分割方法，再在实验条件下模拟了单相电机的通风不良故障，并对其进行了动态分析和静态分析。根据分析结果，本文采用 K 近邻算法，将高温区域面积占比和更高温区域面积占比作为输入，得到了电机的通风不良故障诊断模型。

在方形散流器方面，本文提出的图像分割方法采用了 R-CNN 目标检测算法、边缘检测算法和形态学处理方法，可以实现各个工况红外图像风口区域的提取。在此基础上，本文开发了基于决策树的风口运行工况分类算法，可实现风口出热风、出冷风和出常温风或未出风三种工况的分类。最后，本文在实验室条件下分析了制热风口送风不均匀故障，并建立了基于支持向量机的故障诊断模型。实验数据和实际数据的检验结果表明，该故障诊断模型具有较高的准确率和一定的通用性。

关键词：空调系统，故障诊断，计算机视觉，红外图像

ABSTRACT

The fault detection and diagnosis(FDD) of Heating, Ventilation, and Air-conditioning(HVAC) system is an important means to maintain the normal operation of the system and reduce the building energy consumption. However, a variety of reasons, from data challenges to financial constraints and implementation obstacles, account for the absence of widespread availability and deployment of FDD systems. Therefore, we chose hot water pipelines, motors and square ceiling diffusers as research objectives and developed an FDD algorithm based on RGB images and infrared images. In this algorithm, RGB images are used to classify and locate the equipment while infrared images are used to detect the faults. Compared with traditional FDD algorithms, the proposed algorithm requires only RGB and infrared images and does not need to contact with the equipment. Also, the algorithm can be easily deployed and the cost is low. In practical application, the algorithm can be deployed on the inspection robot with RGB and infrared cameras to fulfill the automated FDD process, and eventually the management of HVAC system will be smart and automated.

The first step of the algorithm is to determine which component type the acquired image belongs to. Therefore, for hot water pipelines, motors and square ceiling diffusers, this paper proposed a classification model based on AlexNet convolutional neural network (CNN) , whose inputs are RGB images and outputs are component types.

In the aspect of hot water pipeline, for the damage and stripping of the thermal insulation layer and water leakage, this paper developed an automatic diagnosis algorithm, including image segmentation, feature analysis and fault diagnosis. Image segmentation part uses threshold segmentation and morphological processing; feature analysis consists of temperature analysis, pipe diameter analysis and defect analysis, respectively to determine whether there are temperature anomalies, pipe diameter anomalies and defect anomalies in the pipeline zone; fault diagnosis unit outputs the diagnosed pipeline type based on the results of feature analysis. The test results showed that the algorithm has high diagnostic accuracy in experimental data and actual data.

In terms of motor, this paper first proposed a motor image segmentation method based on R-CNN, and then simulated the poor ventilation fault of single-phase motor under experimental conditions and carried on the dynamic analysis and static analysis. According to the analysis results, this paper took the ratio of high-temperature area and higher-temperature area as input, developing a diagnosis model for motor poor ventilation fault based on K-nearest neighbor(KNN) algorithm.

As for square ceiling diffuser, the image segmentation method proposed in this paper adopted R-CNN target detection algorithm, edge detection algorithm and morphological processing method, which can extract the diffuser region in infrared images under various working conditions. Furthermore, a classification decision tree is developed to classify diffuser working conditions into three types: heating, cooling and others. Finally, the paper analyzed the uneven heating fault of square ceiling diffusers under laboratory conditions, and established a fault diagnosis model based on SVM. The test results of experimental data and actual data showed that the fault diagnosis model has high accuracy and a certain degree of versatility.

Key words: HVAC, FDD, computer vision, infrared image

目录

摘要.....	I
ABSTRACT.....	II
第 1 章 引言.....	1
1.1 研究背景.....	1
1.2 空调系统故障诊断现状.....	1
1.3 基于图像的空调系统故障诊断.....	2
1.4 红外热成像基本原理.....	3
1.5 空调系统红外诊断的研究现状.....	5
1.5.1 水管红外图像诊断方面的研究现状.....	6
1.5.2 电机红外图像诊断方面的研究现状.....	8
1.5.3 风口红外图像诊断方面的研究现状.....	10
1.6 研究内容及技术路线.....	11
第 2 章 基于卷积神经网络的设备分类.....	13
2.1 卷积神经网络.....	13
2.1.1 卷积层.....	14
2.1.2 池化层.....	16
2.1.3 全连接层.....	16
2.2 AlexNet 卷积神经网络.....	16
2.3 基于 AlexNet 的设备分类.....	18
2.3.1 数据增强.....	18
2.3.2 图像大小归一化.....	20
2.3.3 网络训练和分类结果.....	21
2.4 本章小结.....	22
第 3 章 热水管道故障诊断算法的开发.....	24
3.1 水管图像分割方法.....	25
3.1.1 粗分割.....	25
3.1.2 保留面积最大连通域.....	26
3.1.3 细分割.....	27
3.1.4 水管区域红外图像.....	30
3.2 特征分析.....	31

3.2.1 温度分析.....	31
3.2.2 管径分析.....	34
3.2.3 缺陷分析.....	36
3.3 故障诊断.....	40
3.4 检验结果与讨论.....	41
3.4.1 评价指标.....	41
3.4.2 实验分析.....	42
3.4.3 案例分析.....	45
3.5 本章小结.....	47
第 4 章 电机故障诊断算法的开发.....	48
4.1 电机常见故障及红外诊断现状.....	48
4.1.1 电机常见故障.....	48
4.1.2 电机红外诊断现状.....	49
4.2 基于 R-CNN 的电机检测.....	50
4.2.1 R-CNN 目标检测算法.....	50
4.2.2 R-CNN 检测器训练及检测结果.....	53
4.3 电机图像分割方法.....	54
4.3.1 粗分割.....	55
4.3.2 判别电机运行状态.....	56
4.3.3 细分割.....	57
4.4 电机通风不良故障分析.....	58
4.4.1 动态分析.....	59
4.4.2 静态分析.....	60
4.5 本章小结.....	66
第 5 章 方形散流器故障诊断算法的开发.....	68
5.1 风口图像分割方法.....	68
5.1.1 风口 R-CNN 检测器.....	69
5.1.2 粗分割.....	70
5.1.3 细分割.....	70
5.2 风口运行工况的分类.....	72
5.2.1 输入数据.....	72
5.2.2 决策树算法.....	74
5.2.3 分类模型.....	74
5.3 风口送风不均匀故障分析.....	77

5.3.1 图像采集.....	77
5.3.2 图像分析.....	78
5.3.3 风口送风不均匀故障诊断.....	80
5.3.4 实际数据的检验.....	81
5.4 本章小结.....	81
第 6 章 总结和展望.....	83
6.1 总结.....	83
6.2 主要贡献.....	84
6.3 展望.....	85
致谢.....	86
参考文献.....	87
个人简历、在读期间发表的学术论文与研究成果.....	91

第1章 引言

1.1 研究背景

根据美国能源信息署（Energy Information Administration, EIA）统计的能源数据，从1980年到2016年，全球能源消耗量和CO₂排放量分别增长了104%和106%，能源形势严峻^[1]。大多数人在室内度过90%的日常生活，建筑已成为全球最大的能源消耗品。1980年到2010年，美国建筑用能占总能耗的比例从33.7%上升到了41.1%^[2]。随着我国城市化的进展，城市人口和建筑面积的日益增加，建筑能耗也呈现出持续增长的趋势。从2001年到2015年，我国的建筑运行能耗从3.09亿吨标准煤（tce）增长到8.57亿吨标准煤（tce），增长率高达177%，在能源消费总量中占比20%左右^[3]。

在建筑的全生命周期中，能源的消耗包括了建筑制造、建筑施工、建筑运行和建筑拆除四个部分，其中，大部分的能耗消耗于建筑物的运行，即建筑物机电系统以及其他终端设备使用所产生的能耗^[4]。空调系统作为维持室内热舒适环境的工具，其产生的能耗约占建筑运行能耗的50%，若运行不当，将造成大量的能源浪费。

空调系统的高效运行建立在其各个子部件正常工作的基础上，如果出现故障而维护检修不及时，将导致室内舒适度下降、能耗增加、设备使用寿命变短等不良后果。香港机电工程署（Electrical And Mechanical Services Department, EMSD）的调查显示，商业建筑中15%至30%的能源浪费是由于空调系统性能下降，控制策略不当以及系统故障造成的^[5]。美国国家标准技术研究所（National Institute of Standards and Technology, NIST）提供的数据显示，有效的故障诊断可以帮助暖通空调系统节省10%至40%的能源消耗量^[6]。因此，故障检测与诊断(Fault Detection and Diagnosis, FDD)对于保持空调系统正常工作，延长设备寿命，满足室内舒适度要求和节约能源至关重要。

1.2 空调系统故障诊断现状

在空调系统中，故障是指系统或某个部件运行处于异常状态，出现了不可容忍的偏差，可以表现为功能下降，也可表现为完全失灵。故障检测与诊断(Fault Detection and Diagnosis, FDD)通过对空调系统可测变量的观察来发现故障，并诊断引起故障的原因，在对故障的严重性、安全性等方面进行评估后做出相应决策，从而降低系统维护的成本，保证系统的良好运行。不同于核能、航空航天、自动

化等领域的故障诊断研究，空调系统的故障诊断研究起步较晚，始于二十世纪八十年代末。在这三十年里，研究者们提出了各种各样的方法，诊断的层次不断深入，覆盖到了各个子系统的元件和传感器故障。这些方法包括了基于定量模型的诊断方法（如详细和简化的物理模型）、基于定性模型的诊断方法（如基于规则的诊断方法和专家系统法）和基于历史过程的诊断方法（如黑箱模型法和灰箱模型法），诊断的对象包括了整体建筑系统层面，子系统层面例如空调水系统和系统部件层面例如冷水机组、水泵、空气处理机组、变风量末端和传感器等。

尽管空调系统的故障诊断方法研究已经近乎完备，却至今未在实际楼宇中得到广泛的应用。从研究层面来看，目前所发展的故障诊断方法大多基于理论或者实验室层面，未在实际楼宇中得到灵敏度以及误报率的检验，缺乏实际依据。此外，研究者在探究方法的时候往往没有考虑该方法诸如成本收益率、传感器安装等实际应用的因素，造成了建筑故障诊断远没有商业化的局面。

从实际层面来看，现有楼宇数据的稀缺和质量差是空调系统故障诊断应用面临的主要难题。随着智能建筑的兴起，建筑自动化系统（Building Automation System, BAS）及能源管理系统（Building Energy Management System, BEMS）得到了广泛的应用。这些管理系统对建筑机电系统进行实时的监测和控制，产生了大量的运行数据，可为空调系统故障诊断提供重要的信息基础。因此，为了实时地访问空调系统运行数据，提高故障诊断的自动化水平，越来越多的故障诊断工具基于建筑自动化系统而被开发。然而，目前国内的建筑自动化系统应用水平还较低，控制性能差，运行能耗高，无法达到设计预期的目的，实际使用率低^[7]。高精度的传感器价格昂贵，由于成本的原因，建筑自动化系统所安装的传感器数量有限，一个传感器监测多个部件的情况并不少见。因此，系统所采集的运行数据往往不足以用于故障的诊断。即使安装了足够的传感器，也无法避免长时间运行后传感器出现漂移等故障，数据的可靠性也随之降低。此外，由于建筑自动化系统控制网络可靠性较差，还容易出现数据缺失、误报、标识混乱等问题。

因此，在空调系统故障诊断研究领域中，依旧需要开发具有经济性、可靠性和通用性的故障诊断方法。

1.3 基于图像的空调系统故障诊断

随着人工智能和图像识别技术的迅猛发展，计算机视觉已经广泛应用于各个领域。在安全监控方面，计算机视觉被用于人脸识别，行李检测和交通监控等；在军事领域，计算机视觉被用于侦察机和无人机等；在医学方面和农业方面，计算机视觉被用于疾病的诊断和农作物品质的检测等等。

当然,在暖通空调领域,计算机视觉也发挥着重要作用。相关研究人员将计算机视觉用于室内人员的计量、室内占用密度的检测和室内人员的定位,以优化暖通空调系统的控制策略和提高室内人员舒适度^[8-11]。为了实现风管清洗和检查的自动化,风管清洗机器人的视觉导航以及风管缺陷与污染物的检查也用到了图像识别技术,相比于人工检查,管道的自动检查具有更高的效率和经济性^{[12][13]}。此外,在人体热舒适方面,有学者使用室内人员面部或身体图像来推断其体温调节状态,根据用户的实际热需求来优化空调系统的控制,提高能效^[14-17]。另外,在建筑围护结构方面,研究者们并不局限于采用 2D 红外热图像检测围护结构热缺陷,开发了基于计算机视觉的建筑物 3D 热模型的建立方法,不断提高着建筑改造的质量和效率^[18]。

面对计算机视觉技术的不断成熟和目前空调系统故障诊断方法所存在的问题,本文提出了基于可见光和红外图像的空调系统故障诊断方法,其中,可见光图像主要用于设备的分类和物体的定位,红外图像用于故障的诊断。相比于传统的空调系统故障诊断方法,基于图像的故障诊断方法主要具有以下几点优势:(1) 诊断所需数据仅为图像数据,种类较少且易于获得,克服了设备运行参数难以获取以及数据质量差的现状;(2) 独立于现有自控系统,无需对现有监控平台进行更新改造,可直接应用于实际暖通空调系统监控平台;(3) 无接触地对设备进行图像数据的采集,在诊断过程不对暖通空调系统运行产生影响,可实现安全可靠的监测与故障诊断;(4) 成本较低,实施方便,易于推广。传统的故障诊断算法大多基于设备运行参数,需要在系统中安装的传感器数量多且种类多,对其精度也有一定要求,所需成本高且实施较为困难。而基于图像的故障诊断方法可配合机房摄像头或巡检机器人进行实施,方便且灵活,还可取代物业管理人员进行定时巡检的工作,最终实现大楼暖通空调系统的智能化管理。

1.4 红外热成像基本原理

19 世纪初,英国科学家威廉·赫歇尔通过实验发现了在可见光谱外的电磁波段存在一种肉眼不可见的热射线,该部分电磁波因其位于红色光线外侧而被称为红外线,由此人类开始了对红外线(Infrared, IR)的研究和应用^[19]。如图 1.1 所示,红外线波段位于可见光和微波波段之间,其波长为 0.78-1000 μm 。实际上,只要物体的温度高于绝对零度,就会向外界源源不断地辐射能量,该现象被称为热辐射^[20]。对于一个黑体,其单位面积在单位时间内向外辐射的总能量可用斯特藩-玻尔兹曼定律表示。不同温度的黑体辐射发射特性存在差异,根据维恩位移定律,当黑体温度升高时,其发出的热辐射峰值波长将会逐渐减小。

斯特藩-玻尔兹曼定律:

$$E = \sigma \cdot T^4 (m \cdot K) \quad (1.1)$$

其中 $\sigma = 5.67 \times 10^{-8} W \cdot m^{-2} \cdot K^{-4}$ 。

维恩位移定律:

$$\lambda_{max} \cdot T = 2.8976 \times 10^{-3} (m \cdot K) \quad (1.2)$$




图 1.1 电磁波光谱

物理学研究发现,实际物体向外发射的红外辐射强度不仅与温度有关,还与物体本身的固有性质如材料、表面粗糙度等。因此在使用红外进行测温时,还需要根据被测量物体的材料进行校准。

红外成像设备通过将接收到的物体的热辐射转化为电信号,最终通过处理转化为具有温度场分布信息的图片。图 1.2 表示的为物体的辐射通过红外成像设备生成红外图像的一般过程,其中虚线框中的为红外热成像仪器内部的处理过程^[21]。物体的辐射通过大气辐射进入到红外成像仪器内,该仪器通过镜头与热成像传感器捕捉该辐射信息,该辐射信号通过信号放大器和信号转化器生成对应的电信号。信号放大器完成的主要是对信号的增益、偏置调整等功能;信号转化器实现非均匀性校正、无效像元补偿等功能。最终处理完成的电信号通过内置或外置的显示设备输出。

红外热像仪中最核心的部件为红外传感器,其基本原理是通过某些对温度敏感的物质来探测接收到的红外辐射的能量。其中常见的探测原件有热电探测器、铁电探测器、热电偶探测器、微型热敏电阻探测器等,目前行业内的红外成像传感器多采用氧化钒 (VO_x) 和多晶硅 ($\alpha-Si$) 等半导体制成的微型热敏电阻。




图 1.2 红外成像原理

红外热成像在故障诊断等领域较其他成像技术以及接触式温度传感设备有着明显的优势。首先，红外热成像技术与激光或者雷达等技术相比，不会对被测物体或设备的运行产生影响，因其隐蔽的特点得到了军事方面广泛的应用。其次，红外热成像技术往往能够很容易地捕捉肉眼或者其他仪器较难检测到的温度场分布。通过红外图像采集到的图像信息，结合工程实践经验，可用于各种工程分析。如图 1.3 所示，通过对建筑玻璃幕墙的红外图像进行初步分析可以发现其中一块玻璃存在传热方面的缺陷。

图 1.3^[22] 红外图像的工程应用

1.5 空调系统红外诊断的研究现状

温度是设备和部件结构运行正常的最常见指标之一。机器故障，电气连接受损和材料组件损坏等都可能温度分布的异常。红外热成像技术是一个监测温度的强大工具，它可远程测量物体的温度，并提供整个组件或机器的热图像，因此可以较为容易地检测到引起温度分布异常的故障，从而在产生损失前进行预防性的维护。

红外热成像技术最早在建筑诊断方面的应用是土木工程和文化遗产保护，后在 21 世纪初，逐渐被应用于电机和机械设备诊断。在国际能源署（International Energy Agency, IEA）阐述了其在项目 Annex40（2004）和 Annex46（2010）中在检测热工缺陷方面的重要性后，逐渐被用于能源审计，在墙体和屋顶的保温性

能检测、热桥的检测、气密性的检测、墙体凝结问题的检测等方面得到了广泛的应用。

红外热成像技术不仅在评估建筑围护结构热工性能方面是一个有效的工具，在空调系统故障检测方面也具有一些潜在的用途。Balaras^[23]等人对希腊办公建筑进行能源审计的时候发现，红外热成像技术可以观测管道表面的热变化来检测管道内部的腐蚀问题，对风口进行红外图像的采集可轻松判断其是否发生阻塞或部分叶片关闭。此外，电动机由于轴承故障、润滑不足等问题导致的过热现象也可通过红外热像仪识别出来。

在风系统方面，Wang^[24]等人使用移动管道机器人采集到的风管内部红外图像，结合大律法、水平集法和形态学法三种图像分割算法，开发了基于图像处理的风管缺陷自动检测算法。实验结果表明该算法在区分不同形状缺陷的风管图像上具有 90% 以上的准确率，比其他传统方法具有更好的性能。

由于本文的研究对象为空调系统中的热水管道、电机和方形散流器，因此，文献综述将围绕水管、电机和风口三个部分进行详细展开。

1.5.1 水管红外图像诊断方面的研究现状

随着高分辨率红外热像仪的发展，以及红外热成像技术本身具有的无接触、部署简单，无有害辐射等优势，近年来红外热像仪在管道故障检测方面取得了一定的研究进展。

Fan^[25]等人分析了利用红外图像来检测锅炉系统热管道保温层缺陷和泄漏的可能性，并提出了红外热图像中最高温度与管道缺陷大小和深度的关系。虽然他们没有提出自动检测的算法，但验证了红外热像仪用于监测锅炉系统管道的有效性。

Wu^[26]等人以埋地管道为研究对象，将管道泄漏过程中红外热像仪记录的温度场和 CFD 软件模拟的温度场进行比较，发现红外热成像技术可以准确显示管道泄漏过程中温度场的变化特征，从而判断管道泄漏点的具体位置。

Manekiya^[27]等人将红外热成像技术应用于地暖管道泄漏的检测，在 MATLAB 中对管道泄漏红外图像进行了图像分析。他们采用基于阈值的图像分割方法来得到管道泄漏区域，并计算该区域的面积。

Shakmak^[28]等人对基于红外热成像技术的埋地管漏水检测展开了研究。实验采用了低分辨率和高分辨率两种红外热像仪，并通过图像处理来定位到泄漏点的位置，结果表明低分辨率和高分辨率热像仪均能有效检测出管道的泄漏问题。他们采用了插值法对红外图像进行预处理，并绘制了管道横截面方向的温度曲线，

认为曲线发生凹陷的地方即为管道泄露处。除此之外，为了从更高和更高的视角拍摄图像，他们还评估了利用四轴飞行器无人机和氦气球等远程技术来检测水系统泄漏的潜力。

Bach^[29]等人采用红外热成像技术在墨尔本的 27 个管道泄露处进行了现场评估，其结果显示该项技术能清楚识别 59% 的泄漏点。他们认为红外热像仪采集到的图像受到许多因素的影响，如天气条件、土壤和路面状况。根据采集到的红外热图像，他们还总结了四种不同情景下管道发生泄漏时其红外图像所具有的热特征。

Atef^[30]等人开发了一种使用透地雷达（GPR）和红外热像仪来检测和定位输水管网泄漏点的方法。其中，GPR 用于检测管道位置，红外热像仪用于检测泄漏点。为了估算泄漏点的位置，他们采用区域生长的图像分割方法将图像分为泄漏和非泄漏区域，并计算每个泄漏区的面积和质心。最后，引入 GPR 图像与红外图像重叠，比较管道质心和泄漏区质心，以判断泄漏是由管道的顶部、底部还是侧面引起。

在基于红外图像的水管故障诊断方面，国内学者也展开了相应的研究。

哈尔滨工业大学的赵玉娇^[31]进行了基于红外热像仪的供热直埋管道泄漏的研究，通过搭建在哈尔滨热力集团供热三公司动力厂换热站的试验台，获取了无直埋管、直埋管无泄漏和直埋管泄漏的红外图像，在分析了不同条件下红外图像的特征后，提出了适用于现场红外检测的温差判定法和红外档案库法。

张强等^[32]指出采用红外热成像技术检测供热管道内壁腐蚀情况是可行的，认为未腐蚀管道红外图像具有更小的温度极值变化、标准方差和温度频率分布范围。此外，他们还指出管道红外图像与管道内部受损程度有关，腐蚀管道的凹陷越深，红外图像捕捉到的温度值越高。

吴晋湘等^[33]利用红外热像仪在实验条件下记录了埋地供热管道泄漏和保温层破损时土壤表面温度和湿度的变化，开发了相应的检测方法。在用红外热像仪进行检测时，如果只发现一处温度异常区，则可断定此处管道出现泄漏；如果发现多处温度异常区，则需要将温度异常区的湿度与温度正常区的湿度进行比较，两者相近则为管道保温层破损故障，两者差值较大则为管道泄漏故障。但用于区分保温层破损和管道泄漏两种故障的湿度差值并未设定明确的阈值，究竟差值多小被划分为保温层破损故障，差值多大被划分为管道泄漏故障，文中没有给出明确的界限。此外，该方法也未在实际中得到有效性的检验。

1.5.2 电机红外图像诊断方面的研究现状

状态监测技术已经在电动机的故障检测与诊断中得到了广泛的应用，是减少电动机停机时间和生产损失的有效工具。目前，用于电动机故障诊断的状态监测技术通常基于振动和电流信号。尽管这两种技术都可有效地检测各种电气和机械故障，但其成本昂贵，需要安装传感器以及数据采集系统，且计算复杂，故障诊断较为耗时。

电机表面温度也是评估电机运行状态的重要参数，电机的绕组短路、转子断条、负载过大和通风不良等故障都会引起电机表面温度分布异常。红外热成像技术以非接触的方式可为任何表面提供快速、准确和可靠的温度分布，具有测量安全、部署简单的优点，在电动机故障诊断领域逐渐受到了研究者的青睐。

Eftekhari^[34]等人利用红外热像仪来检测电动机定子绕组中的匝间短路故障，提出了一种基于红外热图像的故障检测算法，并通过实验验证了其有效性。该算法选取红外图像中电机部分的灰度平均值，电机最热区域与包含其凸集区域面积的比值，以及电机最热区域与电机区域面积的比值作为特征值来检测定子绕组的匝间短路故障并评估故障严重程度。

同样地，针对感应电动机的匝间故障，Singh^[35]等人提出了利用红外图像在电动机启动期间和稳态期间的检测方法。在电动机启动期间，他们对电动机的温度进行瞬态监测，发现了异常的电动机比正常的电动机具有更大的温升速率。而在稳态条件下，他们先采用基于阈值的图像分割方法提取出了红外图像中的电动机部分，再根据国际电气测试协会（International Electrical Testing Association, NETA）制定的红外检测标准（如表 1.1 所示），将电动机与环境的温度差值分为 1-10℃、10-20℃和>20℃三个等级，在图像中用不同的颜色进行表达，最终将温差大于 10℃的像素点数和总像素点数的比值作为热指标来判断电动机是否发生故障。

表 1.1^[37] NETA 电气设备红外检测标准

优先级	类似负载下高于相似部件温度值 (°C)	高于环境温度值 (°C)	建议措施
4	1-3	1-10	可能存在缺陷，需要进一步的调查
3	4-15	11-20	可能存在缺陷，尽快进行维修
2	-	21-40	存在缺陷，持续监测直至维修完成
1	>15	>40	存在严重缺陷，立即维修

类似的研究还有 Glowacz^[36]等人提出的关于单相感应电动机定子绕组短路

的故障诊断算法。他们将提出的状态区域选择方法（Method of Area Selection of States, MoASoS）和图像直方图结合在一起生成特征向量，采用最近邻分类器（Nearest Neighbor Classifier, NNC）和高斯混合模型（Gaussian Mixture Models, GMM）对正常和不同程度绕组短路的电机红外图像进行分类，得到了良好的实验结果。

除了分析同一故障不同严重程度的电机红外图像外，学者们对于区分不同故障类型的电机红外图像也展开了相应的研究。

Garcia-Ramirez^[38]等将电机分为主框架和轴承两个部分，以图像的均值和标准差作为统计特征，分析了轴承缺陷、质量偏心 and 不对中三种机械故障情况下的电机红外图像。与正常电机的红外图像对比发现，不对中故障下的红外图像具有最高的标准差值和温升值。

匝间故障和冷却系统的故障都会导致电机定子温度的升高，从而很难通过红外热图像对其进行区分。基于 NETA 标准，Singh 和 Naikan^[39]统计了电机温度与环境温度的差值高于 3°C 和 10°C 的像素点数，比较了两种故障的电机红外图像的差异。其结果发现，具有匝间故障的电机红外图像中高于环境温度 3°C 的像素点数较于正常电机来说并未显著增加，而具有冷却系统故障的电机，由于定子和风扇整流罩温度的增加，高于环境温度 3°C 和 10°C 的像素点数均有显著增加。

Glowacz^[40]分析了三相异步电动机正常、转子断条和端环故障三种状态的红外热图像，开发了基于图像差异的区域选择方法（Method of Areas Selection of Image Differences, MoASoID），并结合图像直方图获得特征向量，采用最近邻分类器（Nearest Neighbor Classifier, NNC），K 均值（K-means）和反向传播神经网络（Back-propagation Neural Network, BNN）三种分类方法对图像进行识别。实验结果表明，三种分类算法均具有 100% 的图像识别率。

在国内方面，对于基于红外图像的电机故障诊断研究，学者们大多只是分析其可行性并根据红外图像中电机表面温度的分布进行人为的诊断，极少数结合图像处理方法自动化诊断过程。

杨宝东等^[41]分析了应用红外热成像技术对电机过热故障进行诊断的可能性，并利用该技术诊断了某船用空调冷却电机的表面过热故障，指出用红外方法测量电机表面温度时应该注意风力冷却和反射温度的影响。

倪紫峰等^[42]将红外图像技术用于定子绕组故障的无损监测和诊断当中。作者对一台外部绝缘状态正常的定子进行诊断，红外图像显示其中一个线圈的温度显著高于其周围绕组，拆除后发现该线圈的引线发生断裂。

孙斌^[43]等通过红外图像进行异步电机轴承故障的诊断，通过对比正常轴承

和故障轴承在电机运行状态下的红外图像发现,当轴承出现故障时,电机端盖轴承安装位置与其周围的边界轮廓较为清晰,而正常的轴承该边界相对模糊,因此这一由电机机械故障引起的温度变化可由红外图像捕捉到。

张强等^[44]建立了电机负载实验台,通过红外热像仪采集三相异步电动机在不同运行工况下的红外图像,分析得到了异步电动机的定子在工作状态下温度场以及温度-频率的关系,并总结了电机定子线圈存在缺陷时的红外特征。实验研究表明,通过对定子线圈红外图像的分析能有效诊断及预测其故障。

郑小荣等^[45]通过红外图像发现一艘艇中频发电机轴的温度低于轴承的温度,而正常运行中的电机转轴温度应高于轴承,因此判断轴承存在故障。最后通过检测发现该轴承存在润滑不良的问题。

华中科技大学的韦先霜^[46]设计了一个基于红外图像的电机故障诊断系统,该系统由红外采集器、图像处理算法、数据库和诊断算法等模块组成,诊断算法模块通过计算电机的局部温度和温升是否超过允许值来判断电机是否出现故障。

西安科技大学的王霄菲^[47]开发完成了机电设备的红外监测系统,其中集成了表面温度判断法、相对温差法、热像特征(特征图谱)判别法等判别机电设备故障的方法。以发电机为例,根据《带电设备红外诊断技术应用导则》推荐的表面温度判断法,当定子绕组温度超过 105°C 时或转子绕组温度超过 100°C 时可认为发电机出现故障。

1.5.3 风口红外图像诊断方面的研究现状

室内温度场和气流组织影响着室内热舒适度,成为了越来越多人关注的话题。随着计算机的发展,计算流体力学(CFD)已成为分析室内空气分布的强大工具,但存在计算时间长、模拟结果不够真实可靠的缺点。红外热像仪可记录大空间的温度分布,相比之下是分析室内温度场更简单的工具,且更具有实际意义。风口作为空调风系统的末端装置,主导了室内的空气流动,有学者利用红外热像仪将风口周围的气流可视化,与 CFD 模拟的结果对比以验证 CFD 模拟的有效性^[48],也有一些学者验证了红外图像用于风口故障诊断的可行性。

Svai'c^[49]等人发现红外热图像可以成功显示空调系统空气射流的几何形状,为确定空气运动模式和量化温度等参数提供重要依据。

Balaras^[23]等人在其研究中指出天花板的风口难以到达,红外热像仪可以记录大空间的温度分布,从而快速识别有问题的出风口。以实际拍摄到的红外图像(如图 1.4)为例,他们指出左侧红外图像中散流器顶部叶片的温度与其他部位的温度存在较大差异,因此散流器供风异常,而右侧则为正常运行的散流器。




图 1.4^[23] 故障散流器（左）和正常散流器（右）的红外图像

Cehlin^[50]等人开发了基于红外热成像技术的测量技术，使用红外热像仪拍摄平行与供气流方向的屏幕，快速显示该横截面上的气温和气流模式，对于检测不同环境中的通风系统性能非常有效。由于该技术可实现实时的测量，还可在现场实时校正和改善散流器的性能。

1.6 研究内容及技术路线

空调系统的故障诊断对于建筑节能、延长设备寿命和维持室内热舒适度都具有重要意义。本文以空调系统热水管道、电机和方形散流器作为研究对象，开发了基于可见光图像和红外图像的故障诊断方法，可见光图像用于设备的分类和物体的定位，红外图像主要用于故障诊断。在实施诊断时，首先采用 AlexNet 卷积神经网络对设备进行分类，再按照设备类型使用相应的故障诊断算法对其进行诊断。因此，本文首先开发了用于设备分类的卷积神经网络，再针对热水管道、电机和方形散流器三种设备分别开发了故障诊断方法，形成了如图 1.5 所示的技术路线。

根据图 1.5，本文的研究内容如下：

第 2 章：基于卷积神经网络的设备分类

首先介绍了卷积神经网络的经典结构和 AlexNet 卷积神经网络的具体结构，再针对空调系统水管道、电机和方形散流器三种设备，训练得到基于 AlexNet 的设备分类模型，为后续故障诊断提供基础。

第 3 章：热水管道故障诊断算法的开发

第一部分首先提出了结合阈值分割和形态学处理的水管图像分割方法；第二部分阐述了水管图像的特征分析方法，包括了温度分析、管径分析和缺陷分析；第三部分将特征分析转换为数学式，制定了热水管道保温层破损、脱落和漏水的故障诊断流程；最后，第四部分用实验图像数据和实际楼宇图像数据对开发的故

障诊断算法进行验证。

第 4 章：电机故障诊断算法的开发

第一部分介绍了电机的常见故障以及引起电机过热的原因，并总结了电机红外故障诊断的研究现状。第二部分介绍了 R-CNN 目标检测算法，将其应用于电机的检测。第三部分提出了采用了 R-CNN 算法、阈值分割和形态学处理的电机图像分割方法，其中还包含了电机运行状态的判别。第四部分在实验条件下制造了电机通风不良故障，并对其进行了动态分析和静态分析，虽然动态分析可以有效检测出电机通风不良故障，但具有瞬时性的静态分析更有实用价值，所以在此基础上建立了基于 K 近邻（KNN）的故障诊断模型。

第 5 章：风口故障诊断算法的开发

第一部分介绍了风口图像分割方法，该方法采用了 R-CNN 目标检测算法、边缘提取算法和形态学处理方法，对任何工况的风口均适用。第二部分提出了采用决策树的风口运行工况分类算法，以实现风口出热风、出冷风和出常温风或未出风三种工况的分类。最后，第三部分在实验条件下分析了风口送风不均匀故障，并开发了基于支持向量机（SVM）的故障诊断模型。




图 1.5 本文技术路线

第2章 基于卷积神经网络的设备分类

不同的设备理应具有不同的诊断方法,因此在进行设备故障诊断之前我们要先对采集到的设备可见光图像进行分类。

在本章中,第一部分首先介绍了卷积神经网络的发展演变和典型结构,第二部分分析了本文采用的 AlexNet 卷积神经网络的具体结构,最后一部分对基于 AlexNet 的典型设备分类方法进行了说明并对识别结果进行了讨论。

2.1 卷积神经网络

20 世纪 60 年代,加拿大神经科学家 Hubel 和 Wisel 在对猫的视皮层神经元研究中提出了“感受野”(receptive field)的概念。日本学者福岛邦彦在此概念基础上,于 1980 年提出了神经认知机(neocognitron)模型,被认为是卷积神经网络的前身。1998 年,LeCun 等人正式提出了基于梯度学习的卷积神经网络,取名为 LeNet,该网络在手写数字识别任务中取得了极高的准确率,被广泛应用于美国邮政系统邮编的识别。

随着深度学习概念的提出和大数据的发展,2012 年在 ImageNet 大赛上摘得桂冠的 AlexNet 给卷积神经网络带来了历史性的突破,它不仅在 LeNet 基础上加深了网络结构,采用了大数据进行训练,还应用双 GPU 进行计算和 Dropout 防止过拟合,具有远高于传统机器学习算法的准确率。自此,深度卷积神经网络在社会各界掀起了一阵狂潮并得到了迅猛的发展,更优秀的网络例如 VGG、GoogLeNet、ResNet 被相继提了出来,如图 2.1 所示^[51]。

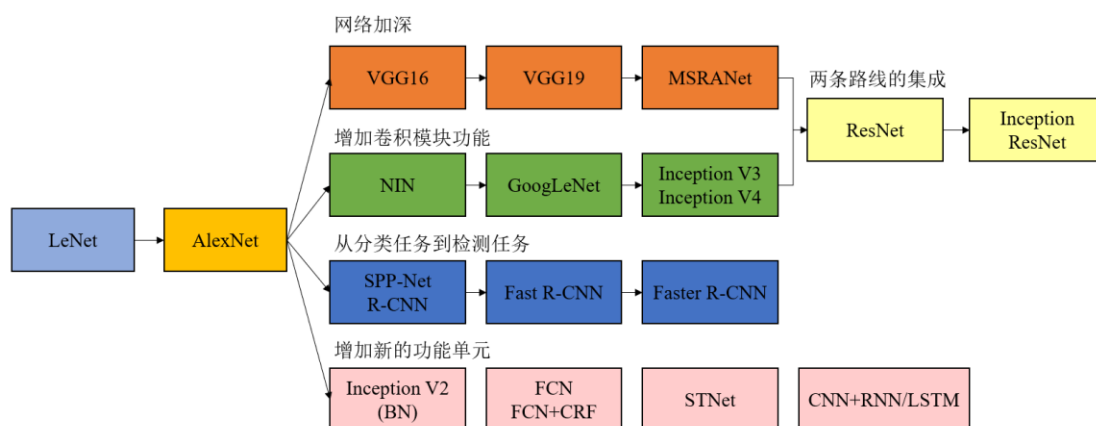


图 2.1^[51] 卷积神经网络的发展演变

卷积神经网络主要包括输入层、卷积层、池化（Pooling）层、全连接层和输出层（如图 2.2）。输入层为输入的图像，卷积层进行图像特征的提取，池化层进行图像特征的降维，全连接层进行分类，输出层则输出分类结果。




图 2.2 卷积神经网络典型结构

2.1.1 卷积层

卷积是一种常见的线性图像处理方法，可以进行图像的锐化、模糊以及边缘检测。图 2.3 详细介绍了图像卷积运算的过程，首先将卷积核旋转 180°，再以特定的步长（Stride）滑过输入图像，乘以并累加它的所有值。




图 2.3 图像卷积运算

卷积层常见的参数有卷积核大小及数量、滑动步长和图像边界填充。其中卷积核滑动步长为卷积核在图像上滑动时每次移动的像素个数，图像边界填充是在图像周围放置零像素以防止图像边界信息的丢失。假设输入图像大小为 $W \times W$ ，卷积核大小为 $K \times K$ ，滑动步长为 S ，边界填充像素数为 P ，则输出图像的大小 N 为：

$$N = \frac{W - K + 2P}{S} + 1 \quad (2.1)$$

卷积层中卷积核的参数是由网络训练得到的，类似于普通神经网络中的权重，一般为 5×5 或 3×3 的大小。卷积运算后生成的图像被称为特征图(feature map)，由上述的卷积运算可以看出，特征图的每一个像素点只对应原图像的一部分，这也是卷积神经网络具有的一大特点：局部连接。权重共享是卷积神经网络的另一大特点，即卷积核在图像上滑动时，参数不会发生改变，整张图像共享卷积核内的参数。

卷积是一种线性运算，因此，在卷积层输出结果之前，会有激活函数处理卷积运算产生的特征映射，非线性化网络，加强网络的表达能力。在卷积神经网络中，最常用的激活函数是线性整流函数(ReLU)，它的定义和函数图像如下所示：

$$f(x) = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (2.2)$$




图 2.4 ReLU 函数图像

2.1.2 池化层

池化层一般在卷积层之后，它的目的是对卷积层提取到的特征进行降维，减少网络内的参数和计算量，防止过拟合。常见的操作有最大值池化、最小值池化和平均值池化，图 2.5 举例说明了最大值池化操作和平均值池化操作。




图 2.5 池化计算

事实上，池化层也是进行卷积运算，但与卷积层不同的是池化层的卷积核是确定的且卷积区域一般不重叠。此外，池化层输出的特征在一定程度上具有平移不变性，所谓平移不变性就是当我们将要识别的物体移动到图像的其他位置时，池化层的大多数输出基本可以保持不变。

2.1.3 全连接层

全连接层在卷积神经网络中的任务是根据提取到的特征进行分类。当上一层为非全连接层时，它采用与上一层输出结果同样宽度和高度的卷积核进行卷积运算，将上一层输出的每一张特征图都变为该层的一个节点；当上一层为全连接层是，它采用 1×1 的卷积核将该层节点与上一层的节点连接。

2.2 AlexNet 卷积神经网络

AlexNet 在 2012 年的 ILSVRC (ImageNet Large Scale Visual Recognition Challenge) 大赛中，以 Top-5 错误率为 15.3% 的成绩摘得桂冠，远低于第二名 26.3% 的 Top-5 错误率^[52]。正如之前所说，AlexNet 是卷积神经网络发展史上的转折点，在它之后，深度卷积神经网络引起了社会各界的关注，更多的深度卷积神经网络在它基础之上被提了出来。

表 2.1 为 AlexNet 详细的网络结构，相比于之前的网络，它主要具有以下特点：采用 ReLU 激活函数，收敛速度快且不会引起梯度弥散；双 GPU 进行网络的训练；使用最大值池化且池化区域重叠，尽管池化层中卷积操作滑动步长小于卷积核的大小会引起计算量的增大，但可以降低错误率并防止过拟合；在标准化层采用局部响应归一化（Local Response Normalization, LRN），提升了模型的泛化能力。

表 2.1 AlexNet 网络结构

层数	参数	输出大小
输入层	大小： $227 \times 227 \times 3$	$227 \times 227 \times 3$
卷积层 1	卷积核： 11×11 （大小）、96（数量）；步长：4；填充：0；激活函数 ReLU	$55 \times 55 \times 96$
最大值池化层 1	卷积核： 3×3 （大小）；步长：2	$27 \times 27 \times 96$
标准化层 1		$27 \times 27 \times 96$
卷积层 2	卷积核： 5×5 （大小）、256（数量）；步长：1；填充：2；激活函数 ReLU	$27 \times 27 \times 256$
最大值池化层 2	卷积核： 3×3 （大小）；步长：2	$13 \times 13 \times 256$
标准化层 2		$13 \times 13 \times 256$
卷积层 3	卷积核： 3×3 （大小）、384（数量）；步长：1；填充：1；激活函数 ReLU	$13 \times 13 \times 384$
卷积层 4	卷积核： 3×3 （大小）、384（数量）；步长：1；填充：1；激活函数 ReLU	$13 \times 13 \times 384$
卷积层 5	卷积核： 3×3 （大小）、256（数量）；步长：1；填充：1；激活函数 ReLU	$13 \times 13 \times 256$
最大值池化层 3	卷积核： 3×3 （大小）；步长：2	$6 \times 6 \times 256$
全连接层 6	4096 个神经元；Dropout；激活函数 ReLU	4096
全连接层 7	4096 个神经元；Dropout；激活函数 ReLU	4096
全连接层 8	1000 个神经元；Softmax	1000

此外，AlexNet 网络中的第一个和第二个全连接层中还应用了 Dropout 方法，在网络训练过程中以 0.5 的概率将每一个隐藏层的神经元输出置为 0，以减少节

点之间的依赖性，并有效防止过拟合。最后一个连接层采用了 Softmax 函数将神经元的输出转换为每个类别的概率值，具体公式如下：

$$f_j = \frac{e^{a_j}}{\sum_{k=1}^T e^{a_k}} \quad (2.3)$$

其中， f_j 为类别 j 的概率值， a_j 为类别 j 的原始值， T 为类别总数。

相应的 Softmax 损失函数为：

$$L_n = -\log(f_i) \quad (2.4)$$

其中， L_n 为第 n 个样本的损失函数， i 为样本的真实类别。

不难发现，当 f_i 的值为 1 时， $L_n = 0$ ，此时是最理想的情况。网络的训练过程就是最小化损失函数的过程。上式为单个样本的损失函数，网络整体的损失函数为数据集中 N 个样本损失函数的平均值，表达式如下：

$$L = \frac{1}{N} \sum_{n=1}^N L_n \quad (2.5)$$

其中， N 为数据集样本总数。

2.3 基于 AlexNet 的设备分类

在本节，我们主要讨论基于 AlexNet 网络的设备的分类方法，针对的设备类型为水管、电机和方形散流器。我们首先将原始数据集按照 8:2 的比例分为训练集和测试集，并各自进行了数据增强扩充数据集。其次，我们将所有图片的大小修改为 $227 \times 227 \times 3$ ，以满足 AlexNet 网络的输入要求。最后，我们采用了迁移学习的方法，修改预先训练好的 AlexNet 卷积神经网络的最后一个全连接层，保留其他层的参数不变，再使用准备好的数据集进行模型的训练和验证。

2.3.1 数据增强

在本文中，数据增强是在有限数据集的情况下通过图像处理来扩充数据集，防止模型过拟合。本文的原始数据集共有 1672 张图像，其中包含了水管图像 297 张、电机图像 927 张和方形散流器图像 448 张。经数据增强后，数据集扩增到了 80256 张图像，为原始数据集的 48 倍。

2.3.1.1 裁剪

数据增强的方法之一是裁剪操作，具体如图 2.6 所示，我们处理的结果是在原图像的基础上得到了另外五张不同的图像。图 2.6 左侧一系列的图像为原图像，

橙色方框为裁剪框，右侧图像为裁剪框裁剪得到的图像，一行代表一组图像，共计五组。裁剪框的大小是原图像宽度和高度的五分之四，假设原图像的宽为 W ，高为 H ，那么裁剪框的宽和高分别为 $0.8W$ 和 $0.8H$ 。本文选择的裁剪位置为原图像的左上角、左下角、右上角、右下角和中心。




图 2.6 图像裁剪

2.3.1.2 几何变换

此外，我们还采用了旋转和垂直翻转的几何变换方法，假设点 (x_0, y_0) 绕原点逆时针旋转了 θ 度，那么变换后的坐标 (x_1, y_1) 为：

$$[x_1 \ y_1 \ 1] = [x_0 \ y_0 \ 1] \begin{bmatrix} \cos \theta & \sin \theta & 0 \\ -\sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (2.6)$$

点 (x_0, y_0) 经过垂直翻转后的坐标 (x_2, y_2) 为：

$$[x_2 \quad y_2 \quad 1] = [x_0 \quad y_0 \quad 1] \begin{bmatrix} 1 & 0 & 0 \\ 0 & -1 & H \\ 0 & 0 & 1 \end{bmatrix} \quad (2.7)$$

其中 H 为图像高度。

本文选取了 $\theta=90, 180, 270$ 三个角度对裁剪处理后得到的图像和原图像进行旋转操作，并在此基础上进行垂直翻转，处理结果见图 2.7。不难发现，经过裁剪和几何变换，数据集扩增到了原始数据集的 48 倍。




图 2.7 旋转和垂直翻转示意图

2.3.2 图像大小归一化

如前所述，AlexNet 网络输入层对图像的大小有要求，因此，需要将所有图像的大小调整为 $227 \times 227 \times 3$ 。

插值算法被广泛应用于图像缩放中，常见的有最近邻 (Nearest-neighbor) 插值法、双线性 (Bilinear) 插值法和双立方 (Bicubic) 插值法，如图 2.8 所示。最近邻插值法是将原图像中距离新像素最近的像素灰度值赋予给新像素的方法，是三种方法中最简单的方法，但变换后的图像容易出现灰度值的不连续和图像失真。双线性插值法是二维的插值方法，它不仅要进行列方向的插值，还要进行行方向的插值，由于选择了 4 个最近像素灰度值去计算新像素的灰度值，计算量会相对增加，但处理的结果也会更好。比双线性插值法更复杂的就是双立方插值法，也是本文采用的方法，双立方插值法包括了 16 个最近邻点，其计算公式如下^[53]：

$$v(x, y) = \sum_{i=0}^3 \sum_{j=0}^3 a_{ij} x^i y^j \quad (2.8)$$

其中, (x, y) 为待赋予灰度值的新像素位置, $v(x, y)$ 为新像素灰度值, a_{ij} 为系数, 由 16 个最近邻点写出的未知方程确定。

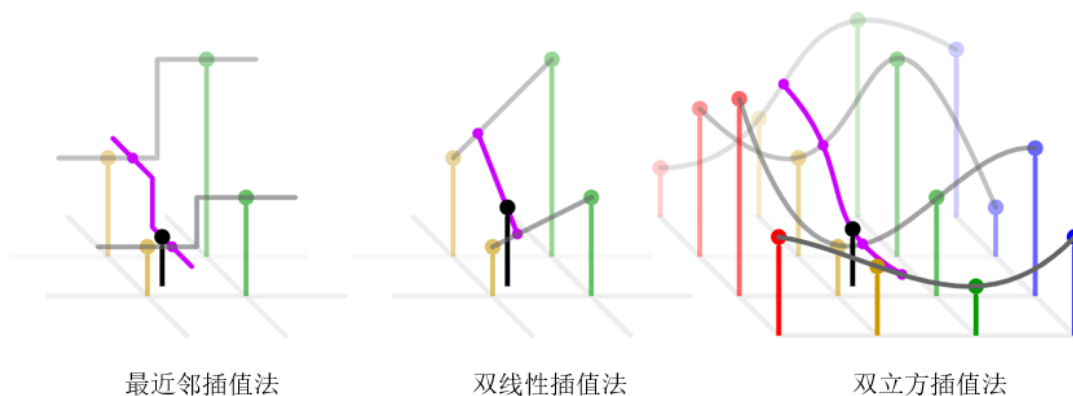


图 2.8^[54] 三种插值法的比较

2.3.3 网络训练和分类结果

迁移学习可以在节省网络训练时间的基础上获得不错的分类效果, 因此, 本文采用迁移学习的方法来训练和测试用于设备分类的卷积神经网络, 软件环境为 MATLAB。

由于 AlexNet 网络是对 1000 个物体进行分类, 最后一个全连接层有 1000 个神经元, 而本文只针对水管、电机和方形散流器三种设备类型进行分类, 因此, 我们将最后一个全连接层的大小修改为 3, 并将该层权重学习率和偏置学习率分别设为 50 和 50。调整好预训练的 AlexNet 卷积神经网络后, 我们将准备好的训练集和测试集对网络进行训练和测试, 并采用准确率来评价训练得到的卷积神经网络性能, 其定义为:

$$\text{准确率} = \frac{\text{分类正确的样本数}}{\text{样本总数}} \times 100\% \quad (2.9)$$

图 2.9 为网络训练过程损失曲线, 网络训练相关参数的设置见表 2.2 所示。训练过程共 30 个回合数 (epoch), 每个回合对一批样本的训练为一次迭代 (iteration)。由图 2.9 可以看出, 当回合数大于 6 时, 网络的损失函数值已趋于稳定并接近于 0, 因此, 还可减少回合数来缩短网络训练的时间。




图 2.9 训练过程损失曲线

由表 2.2 可以看出，训练得到的网络在测试集上的分类准确率达 99.68%，说明了该网络能较为准确地进行设备图像的分类。为了更直观地表达该网络分类设备图像的准确性，图 2.10 列举了部分图像的分类结果，分类结果为水管的图像被划为水管类型，分类结果为水泵电机的图像被划为电机类型，分类结果为风口的图像被划为方形散流器类型。

表 2.2 迁移学习训练参数和测试结果

权重学习率	偏置学习率	批样本数	初始学习率	回合数	准确率
50	50	128	0.00005	30	99.68%



图 2.10 部分图像分类结果

2.4 本章小结

本章首先介绍了卷积神经网络的经典结构，主要包括输入层、卷积层、池化

层、全连接层和输出层五个部分。其次，介绍了 AlexNet 卷积神经网络的具体结构，分析并总结了其具有的特点。最后，进行数据增强和图像尺寸归一化，采用迁移学习的方法，修改预训练 AlexNet 网络的最后一个全连接层大小来训练用于设备分类的卷积神经网络。从网络的测试结果可以看出，训练得到的深度卷积神经网络可以较好地满足本文设备分类的要求。

第3章 热水管道故障诊断算法的开发

空调系统水管道由于长时间的运行难免会出现保温层破损、保温层脱落和漏水等故障，如果维护检修不及时，将造成能耗的增加、水资源的浪费、水系统失调和室内舒适度下降等不良后果。

温度是监测设备部件运行是否正常最常见的指标之一，当管道发生上述故障时，温度分布会出现明显的异常，红外热像仪则可在不干扰管道运行的情况下将这些异常记录下来。因此，红外热像仪是检测管道故障的有效工具。如前文所述，尽管已有学者进行了相关的研究，但大多基于地理管道，诊断过程缺乏自动化，算法准确性未得到检验，难以在实际中得到应用。

因此，本章在 MATLAB 环境下，开发了一种基于红外图像的热水管故障自动检测算法，包括图像分割、特征分析、故障诊断三个步骤（如图 3.1 所示）。图像分割的目的是获取红外图像中感兴趣区域即水管区域。特征分析主要是观察水管区域温度是否存在异常、管径是否发生缩小以及内部是否存在高温缺陷区。故障诊断部分则是根据特征分析的结果判定水管运行状态。实验数据和实际楼宇数据中的检验结果表明，该算法能较为准确地检测出水管保温层破损、保温层脱落以及漏水故障，具有一定的应用价值。




图 3.1 水管故障诊断算法框架

3.1 水管图像分割方法

分割即是將圖像細化為物體，從圖像中提取出感興趣的部分。在本章中，圖像分割的目的是獲取水管部分的紅外圖像和二值圖像，用於後續的特徵分析。本文採用的圖像分割方法如圖 3.2 所示，主要分為粗分割和細分割兩個部分，先使用基於閾值的圖像分割方法進行水管區域的初步定位，再採用形態學方法進一步消除背景部分，填充水管區域隙縫，實現水管區域的精確定位，最終再實現二值圖像到紅外圖像的轉換。




圖 3.2 水管圖像分割流程

3.1.1 粗分割

閾值處理的具體技術是設定閾值將圖像分為背景和目標兩個部分，是一種簡單常見的圖像分割方法，其定義如下：

$$g(x, y) = \begin{cases} 1 & f(x, y) > T \\ 0 & f(x, y) \leq T \end{cases} \quad (3.1)$$

其中 $g(x, y)$ 為閾值處理後圖像， $f(x, y)$ 為原灰度圖像， T 為設定的閾值。

原始紅外圖像為彩色圖像，在進行閾值處理之前，需先將其轉換為灰度圖像。

考虑到热水管道温度比背景区域高，相应地，在红外图像中具有更高的红色分量值，故提取原始红外图像红色分量图像作为灰度图像进行阈值处理。如图 3.3 (b) 所示，在红色分量图像中，水管和背景灰度值差别较大，适合进行阈值处理。

选取合适的阈值对分割结果至关重要，常见的阈值选取方法有双峰法、P 参数法、Otsu 法和最大熵阈值法。Otsu 法是一种最常用的全局自适应阈值分割方法，它通过最大化类间方差和最小化类内方差来确定灰度图像分割的最佳阈值。在本研究中，为了更好地分离出水管区域，去除背景的影响，选取直方图右峰对应的灰度值作为阈值进行图像分割。从图 3.3 中的分割结果可以看出，与 Otsu 法相比，该方法能清除更多的背景区域。




图 3.3 水管粗分割图像处理结果 (a) 原始红外图像 (b) 红色分量图像 (c) 红色分量直方图，红圈表示右峰 (d) 右峰阈值分割结果 (e) Otsu 法分割结果

3.1.2 保留面积最大连通域

在二值图像中，连通域指的是位置相邻的像素值为 1 的点形成的图像区域。根据相邻像素点的关系，连通域分为四连通区域和八连通区域。在四连通区域中，上、下、左、右四个方向相邻的像素点被认为是相邻像素点，而在八连通区域中，除了上、下、左、右四个方向，上左、上右、下左、下右四个方向的相邻像素点也被看作是相邻像素点。以图 3.4 为例，图像中存在两个四连通区域，却只存在一个八连通区域。




图 3.4 7×7 像素大小的二值图像

阈值处理后的二值图像除了水管区域,还存在一些小面积的背景区域需要清除。本研究默认水管区域处于面积最大的连通域中,对二值图像所有的四连通区域进行标记并计算面积,保留面积最大的连通域作为后续分析对象,将其余小面积连通域当作背景清除,处理结果如图 3.5 所示。



图 3.5 连通域处理前图像 (左) 和连通域处理后图像 (右)

3.1.3 细分割

3.1.3.1 膨胀与腐蚀

数学形态学是一种基于集合论、格论、拓扑学和随机函数的非线性图像处理方法,它可以利用一些结构元素过滤掉图像中不感兴趣的结构并加强感兴趣的部分。闭操作和开操作由膨胀和腐蚀组成,因此,在介绍闭操作和开操作之前,我们先介绍膨胀和腐蚀的原理。

膨胀可以看作是使图像目标“变大变粗”的操作, A 被 B 膨胀定义为:

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (3.2)$$

其中, B 为结构元, z 为点集, \hat{B} 为集合 B 基于原点的反射, $(\hat{B})_z$ 为集合 \hat{B} 按照点 z 的平移, \emptyset 为空集。

上述式子可以理解为结构元 B 反射并按照点 z 平移后至少与 A 的一个元素重合,满足该条件的点 z 组成的集合即为 A 被 B 膨胀后的结果。图 3.6 清晰地表达了膨胀处理过程。其中,图 3.6 (a) 为原始二值图像,蓝色表示的是像素值为 1 的点,即前景点。值得注意的是,在形态学图像处理中,二值图像被看作是

像素值为 1 的点的集合，因此蓝色部分为集合 A 。图 3.6 (b) 为膨胀处理的结构元，即上式的 B ，其原点已经用绿色进行标记，由于该结构元关于原点对称，基于原点的反射就是其本身。图 3.6 (c) 为膨胀处理后的图像，像素值为 1 的点即为上式的 z ，它表示当结构元的原点移动到此处时，会与原始图像中的 1 值像素发生重叠，即表示为有交集，标记为橙色的点是集合 A 外满足条件的点，即膨胀处理后图像相比原始图像增加的像素值为 1 的点。明显可以看出，膨胀可以增加图像中像素值为 1 的点的个数，从而使图像目标“变大”。




图 3.6 形态学图像处理过程 (a) 7×7 大小的原始二值图像 (b) 结构元 (c) 经结构元膨胀后图像 (d) 经结构元腐蚀后图像 (e) 经结构元闭操作后图像 (f) 经结构元开操作后图像

与膨胀相反的是，腐蚀是细化、收缩图像目标的操作， A 被 B 腐蚀定义为：

$$A \ominus B = \{z | (B)_z \cap A^c = \emptyset\} \quad (3.3)$$

其中， A^c 是 A 的补集。

与膨胀同理，上述式子可以理解为结构元 B 按照点 z 平移后被包含在 A 中，满足该条件的点 z 组成的集合即为 A 被 B 膨胀后的结果。从图 3.6(d) 可以看出，图像中仅蓝色标记的点满足上述条件，即为最终的腐蚀结果。与膨胀操作相反的是，腐蚀操作会减少图像中像素值为 1 的点（图中灰色标记的即为减少的像素点），因此，从视觉上看，腐蚀会缩小图像目标。

2) 闭操作和开操作

形态学闭操作是先膨胀后腐蚀的运算过程，它可以平滑目标的轮廓，连接细小的断裂处，填充比结构元小的孔洞。 A 被结构元 B 闭操作可表示为：

$$A \bullet B = (A \oplus B) \ominus B \quad (3.4)$$

图 3.6 说明了闭操作的处理过程。先用结构元对原始图像进行膨胀操作得到图 3.6 (c)，再进行腐蚀操作得到图 3.6 (e) 的闭操作处理结果。对比原始图像可以看出，闭操作连接了左下角和右下角的像素点，填充了比结构元小的孔洞。

与之相反的开操作是先腐蚀后膨胀的运算过程，它可以平滑目标的轮廓，除去所有不能包含结构元的部分和断开细小的连接。用结构元 B 对 A 进行开操作可定义为：

$$A \circ B = (A \ominus B) \oplus B \quad (3.5)$$

图 3.6 也显示了开操作的处理过程，首先用结构元对原始图像进行腐蚀操作得到图 3.6 (d)，再进行膨胀操作得到图 3.6 (f) 的开操作处理结果。对比原始图像可以看出，开操作结果少了左下角和右下角两个像素点，如前所述，开操作会除去原图像中不能包含结构元的部分。

图 3.7 为水管细分割部分闭操作和开操作的处理结果。如图 3.7 所示，本文利用闭操作来填充水管区域内的细小缝隙，利用开操作来去除非水管区域。对比图 3.7 (d) 和图 3.7 (e) 可以看出，开操作使二值图像少了右下角的一部分，而从图 3.7 (b) 水管可见光图像可以看出这部分正好是灯管区域。因为灯管温度比水管温度高，若图像分割未将其清除，可能会认为水管区域存在异常高温区，从而将无故障水管划分到故障水管类别，造成诊断错误。因此，利用开操作来断开细小连接，减小背景区域如其他支路管道和机房灯管的影响是十分必要的。

在形态学操作中，结构元的选择是十分重要的，结构元不同，图像处理结果也会因此不同。在本文中，选取闭操作结构元的大小取决于待填充孔洞的大小，

选取开操作结构元的大小取决于红外图像中“噪声”的大小。经反复试验，本文采用 15×15 的结构元素对图像进行闭操作， 20×20 的结构元素对图像进行开操作。




图 3.7 水管细分割图像处理结果 (a) 原始红外图像 (b) 原始可见光图像 (c) 保留最大面积连通域处理结果 (d) 闭操作处理结果 (e) 开操作处理结果

由于开操作会断开细小的连接，处理后的图像可能存在多个连通域，所以在开操作结束后，还需清除小面积的连通域。

3.1.4 水管区域红外图像

上述图像分割的结果为水管二值图像，并不具有温度特征。为了得到水管区域的温度特性，我们需要将二值图像中的水管区域与原始红外图像一一对应起来，保留红外图像中的相应区域，将其他区域设置为背景。

本研究认为水管二值图像中像素值为 1 的像素点组成的区域为水管区域，因此，红外图像中相应区域的像素点的颜色被保留，而其他像素点的颜色被设置为黑色，如图 3.8 (c)。具体实现方法为提取原始红外图像中的红色分量、绿色分量和蓝色分量图像，分别乘以水管二值图像后再合成彩色图像，得到最终的水管红外图像。




图 3.8 水管红外图像的获取 (a) 水管原始红外图像 (b) 水管二值图像 (c) 水管红外图像

3.2 特征分析

特征分析的目的是对图像分割出的水管区域进行分析,包括温度分析判断水管区域温度是否存在异常、管径分析判断管径特点是否符合保温层脱落管道管径特点、缺陷分析判断水管内部区域是否存在高温缺陷区,具体如下:




图 3.9 特征分析框架

3.2.1 温度分析

3.2.1.1 温度与颜色线性关系

电脑只能识别出红外图像存在的颜色信息,要想获得温度信息就必须建立温度与颜色的函数关系。如图 3.10 所示,本研究提取红外图像右侧的温度标尺,识别其上下限温度数值,再采取线性插值法将温度标尺内每个像素点的颜色值与温度值一一对应,最后,利用线性回归的方法得出温度与颜色的函数关系,表达式

如下：

$$t = \begin{cases} 0 & R = 0 \text{ 且 } G = 0 \text{ 且 } B = 0 \\ aR + bG + cB + d & R > 0 \text{ 或 } G > 0 \text{ 或 } B > 0 \end{cases} \quad (3.6)$$

其中， t 为温度值， R 为当前像素点红色通道值， G 为当前像素点绿色通道值， B 为当前像素点蓝色通道值， a 、 b 、 c 为系数， d 为常数，均由线性回归计算而得。

前文提到，水管红外图像中的背景区域被设为了黑色，在此处，其温度值也被设置为了零。在获得温度与颜色的线性关系后，可以得到整张图像的温度矩阵，由于温度值为零的点对应的是背景，在进行温度分析时，相应地会被剔除。此外，在后文的电机和方形散流器的温度分析中，采用的也是此处的方法。




图 3.10 温度-颜色线性关系建立过程

A. 提取温度标尺上下限图像

红外图像中的温度标尺只有上限和下限两个温度数值，由于本研究中采集到的红外图像均由同一设备获得，上下限温度数值所处位置相同，故直接获取温度上下标的大概位置，从图像中分割获得温度上下限的图像。

B. 字符定位

字符定位是字符分割前的图像预处理，目的是定位字符区域，消除图像中非字符区域，具体算法如下：

1 采用 Otsu 法进行图像二值化

- 2 列方向定位
从最左侧开始计算列方向的像素值之和，若等于零，继续计算，若大于零，则停止计算，并记下当前列数 i ；
从最右侧开始计算列方向的像素值之和，若等于零，继续计算，若大于零，则停止计算，并记下当前列数 j ；
- 3 行方向定位
从最上侧开始计算行方向的像素值之和，若等于零，继续计算，若大于零，则停止计算，并记下当前行数 m ；
从最下侧开始计算行方向的像素值之和，若等于零，继续计算，若大于零，则停止计算，并记下当前行数 n ；
- 4 提取图像中 $i - j$ 列以及 $m - n$ 行的部分

C. 字符分割

数字的组合是无穷无尽的，在识别的时候不可能对整个字符串进行识别，而是需要将其分割为单个字符，进行单独识别。观察字符定位后的图像不难发现，一个字符为一个连通域，从列方向来看，字符与字符之间的区域像素值和为零。因此，本文以此为依据进行字符的分割，具体算法如下：

- 1 从最左侧计算列方向的像素值之和，若大于零，继续计算，若等于零，停止计算，记下当前列数 j ；
- 2 将列数 $0 - j$ 的图像部分分割出来，并另存为图像；
- 3 从上次计算停止的列数开始继续计算列方向的像素值之和，直到像素值之和大于零，记下当前所在列数 m 并继续计算，直到像素值之和等于零，停止计算，记下列数 n ；
- 4 将列数 $m - n$ 的图像部分分割出来，并另存为图像；
- 5 重复 3-4 步骤，直到列数大于图像宽度，停止计算，字符分割完毕。

D. 字符识别

考虑到本研究中红外图像由同一设备采集而得，温度字符形式单一，故采用模板匹配的方法进行识别，简单而且高效。在字符识别之前，需要建立相应的模板库，模板库的来源即为红外图像中不同字符的分割结果。如图 3.10 所示，模板库中有数字 0-9 的二值图像和小数点的二值图像。

模板匹配分类器基于像素分布的特点，将待分类样本与模板库中的每个模板进行一一比较，统计相同坐标下相同像素点的个数，认为相同像素点个数最多的模板即为待分类样本的类别。在本文中，模板库中的所有模板图像均为 7×12 像素大小，因此，字符图像在进行识别前调整到了相同的大小。

字符识别完成后，需要将其整合到一起变成数字。观察红外图像的温度上下限值，只存在三个字符和四个字符两种情况且都保留了小数点后一位数，在判断字符个数后，将最右侧字符的识别结果默认为小数点后一位，右侧第二字符的识别结果默认为小数点，右侧第三字符的识别结果默认为个位数，右侧第四字符的识别结果默认为十位数（若没有右侧第四字符则将其识别结果设置为 0），并输出识别结果。

E. 线性插值

红外图像温度标尺是线性的，在识别出温度标尺的温度上下限数值后，本研究提取了温度标尺图像，取其中一列一共 181 个像素点进行线性插值，公式如下：

$$t_r = t_1 - \frac{r(t_1 - t_2)}{180} \quad (3.7)$$

其中， t_r 为第 r 行像素点的温度值， t_1 为温度值上限， t_2 为温度值下限，温度值上限所在行数为 0，温度值下限所在行数为 180。

F. 线性回归

将线性插值的结果作为训练数据来获取温度与颜色的线性关系。值得注意的是，每张红外图像的温度标尺上下限温度数值不同，温度与颜色的线性关系参数也因此不同。因此，需对每张红外图像求取温度与颜色的线性关系。

3.2.1.2 3σ 准则

3σ 准则是数据清洗中常见的异常数据判别准则，其原理基于正态分布，认为处于 $(\mu - 3\sigma, \mu + 3\sigma)$ 区间外的数据为异常数据。尽管水管温度数据不符合正态分布，但 3σ 准则也可表达数据偏离平均值的程度，因此，本文采用 3σ 准则来判断水管区域是否存在温度异常值。在本研究中，我们取水管区域前 1% 最高温度值的平均值作为最高温度 t_m ，判断其是否高于 $\mu + 3\sigma$ ，若高于，我们认为此水管为故障水管；若低于，我们初步认为水管不存在故障现象。

此外，在识别漏水管道和保温层脱落管道时，我们也采用了温度分析的方法。因为空调热水温度和保温层裸露管道的温度远高于采用了保温措施的管道表面温度，所以我们认为当 $t_m - \mu > 4^\circ\text{C}$ 时，水管发生漏水故障或保温层脱落故障。

3.2.2 管径分析

管径分析的目的是识别保温层发生脱落的管道。如果热水管道保温层发生脱落，脱落处的管径将明显缩小，如图 3.11 (a)。本文针对横向管道，将二值图像

列方向像素值之和作为管径值，计算当前列与后面第 60 列的管径差值来分析管径变化趋势。图 3.11 分别列出了保温层脱落单管、保温层未脱落单管和保温层未脱落三通管三种管道的二值图像以及管径差值曲线图。其中，管径差值曲线图的横坐标为列值，纵坐标为管径差值。不难发现，保温层未脱落单管的列方向管径差值极小，最大值也就 3 个像素，可以认为管径未发生变化。保温层未脱落交叉管与保温层脱落单管的管径差值曲线相似，管径均发生了明显的变化，但交叉管的管径差值明显大于保温层脱落管的管径差值，达到了 100 像素以上。此外，由于交叉管的变化是管径的增加，保温层脱落管的变化是管径的减小，所以对于保温层未脱落交叉管来说，差值最大值所在列数大于差值最小值所在列数，与保温层脱落单管相反。




图 3.11 不同管道管径特性 (a) 保温层脱落单管二值图像 (b) 保温层未脱落单管二值图像 (c) 保温层未脱落三通管二值图像 (d) (a) 的管径差值曲线 (e) (b) 的管径差值曲线 (f) (c) 的管径差值曲线

由于上述分析只针对于横向管道，因此，在对竖向管道进行分析前，本文将其逆时针旋转 90° 转换为横向管道。在本文中，判断竖向管道的方法为获取水管区域的最大行值与最小行值并计算水管区域的高度，若水管区域高度等于图像高度，则认为是竖向管道；否则，认为是横向管道。

综上所述，本文按照下述步骤来判断水管管径是否符合保温层脱落管道管径特点：

- 1 获取水管区域最大行值与最小行值，计算水管区域高度，若水管区域高度等于图像高度，则管道为竖向管道，将图像逆时针旋转 90° ；
- 2 统计列方向像素值为 1 的坐标点个数，将其作为列方向的管径；
- 3 从第 1 列开始，计算第 j 列管径与第 $j+60$ 列管径的差值；
- 4 将差值最大值记为 D_m ，其所在列数为 m ；
将差值最小值记为 D_n ，其所在列数为 n ；
- 5 当 $D_m > 16$ ， $m < n$ 且 $|D_m - D_n| < 10$ 时，水管保温层可能发生脱落；
否则，水管保温层未发生脱落。

3.2.3 缺陷分析

当管道保温层破损较小或深度较浅时，采用温度分析可能不足以检测出故障。因此，本文还对管道进行了缺陷分析，判断管道区域是否存在高温破损区。

3.2.3.1 Canny 算法

在缺陷分析中，我们采用了边缘检测算法来检测水管内部区域是否发生破损。边缘检测是基于灰度突变的图像分割方法，检测这种灰度的变化可以用一阶导数或二阶导数来完成，因此，边缘检测方法可以划分为基于梯度的方法和基于拉普拉斯的方法。常见的边缘检测算子有 Sobel 算子、Prewitt 算子、Roberts 算子和 Canny 算子，而 Canny 算子是最优秀的边缘检测器，它主要分为以下四个步骤。

① 采用高斯滤波器对输入图像进行平滑处理

该步骤的目的是去除噪声，处理后的图像相应地会比原始图像模糊。令 $f(x, y)$ 为输入图像，高斯函数 $G(x, y)$ 为：

$$G(x, y) = e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.8)$$

其中 σ 为标准差，决定了高斯滤波器对图像进行平滑处理后的模糊程度。

将 $G(x, y)$ 和 $f(x, y)$ 卷积，高斯模糊后的图像 $f_s(x, y)$ 为：

$$f_s(x, y) = f(x, y) * g(x, y) \quad (3.9)$$

其中 $*$ 为卷积运算。

② 计算梯度的幅值和方向

在对图像进行高斯滤波后，下一步便是计算每一点梯度的幅值和方向了。图像 $f(x, y)$ 在点 (x, y) 的梯度 ∇f 表示为：

$$\nabla f \equiv \text{grad}(f) \equiv \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (3.10)$$

梯度向量 ∇f 的幅值表示为 $M(x, y)$ ，即：

$$M(x, y) = \text{mag}(\nabla f) = \sqrt{g_x^2 + g_y^2} \quad (3.11)$$

梯度向量 ∇f 的方向表示为 $\alpha(x, y)$ ，即

$$\alpha(x, y) = \tan^{-1} \left(\frac{g_y}{g_x} \right) \quad (3.12)$$

常用的梯度算子有 Sobel 算子、Prewitt 算子和 Roberts 算子，如图 3.12 所示。图 3.12 左上角为图像中的 3×3 区域， Z 代表了该点的灰度值，橙色标记的为计算点，以 Sobel 算子为例，用 Sobel 算子来计算该点的梯度为：

$$g_x = (Z_7 + 2Z_8 + Z_9) - (Z_1 + 2Z_2 + Z_3) \quad (3.13)$$

$$g_y = (Z_3 + 2Z_6 + Z_9) - (Z_1 + 2Z_4 + Z_7) \quad (3.14)$$

Roberts 算子是对对角线方向的边缘较为敏感的二维模板，Sobel 和 Prewitt 算子是对水平和垂直方向的边缘较为敏感的三维模板，相比于二维模板，三维模板会包含图像的更多信息。此外，与 Prewitt 算子相比，Sobel 算子能较好地抑制噪声。因此，Sobel 算子是三者中最常用且性能最好的模板，本章也采用 Sobel 算子进行梯度的计算。




图 3.12 边缘检测梯度算子

③ 对梯度幅值采用非最大抑制

非最大抑制是细化边缘的手段，具体原理是将该点的梯度幅值与正负梯度方向相邻两点的梯度幅值进行比较，如果该点的梯度幅值最大，保留该点的梯度幅值不变，否则将该点的梯度幅值置为 0。

④ 用双阈值处理和连接分析检测并连接边缘

非最大抑制处理的边缘结果并不完美，有些边缘可能实际上并不是边缘，图像中还存在着一些噪声，因此 Canny 算法采用双阈值的方法来消除这些伪边缘。我们设置一个较低的阈值 T_L 和一个较高的阈值 T_H ，像素值高于 T_H 的像素点为强边缘，位于 T_L 与 T_H 之间的像素点为弱边缘，采用 8 连通的连接方法将能连接到强边缘的弱边缘看作是实际边缘并保留，将不能连接到强边缘的弱边缘删除。

然而，由于噪声等因素的影响，Canny 算法提取到的边缘不一定是连续闭合的，所以边缘提取后还需对断裂的边缘进行连接。本文采用的方法是 Peter Kovesi 在其个人主页上提供的边缘连接算法，它先查找图像内的边缘端点和孤立点，再将符合距离要求的点连接起来^[55]。

3.2.3.2 分析步骤

在缺陷分析中，我们首先利用边缘检测方法提取水管内部缺陷的边缘，再对其进行填充，观察其最高温度是否接近于水管区域最高温度，如果填充面积大于零且温度接近于水管区域最高温度，我们则认为水管保温层发生了破损，否则未发生破损，详细的步骤如下所示：

-
- 1 对水管二值图像使用 Canny 算法，提取水管外部边缘，采用 20×20 的结构元素膨胀水管外部边缘，将处理结果记为 H ；
 - 2 提取水管红外图像蓝色分量 I_s ，Canny 算法提取水管外部和内部边缘，记为 I ；
 - 3 计算 $K = I - H$ ， K 为水管内部边缘；
 - 4 计算 $J = I_s \times K$ ，采用 Otsu 法二值化图像 J ，连接断裂边缘；
 - 5 使用 `imfill` 函数填充闭合边缘形成的孔洞，减去 K 获取填充区域；
 - 6 计算填充区域面积 S 和最高温度 t_s ，如果 $S > 0$ 且 $t_m - t_s < 0.1$ ，则保温层破损；否则，保温层未破损。
-

图 3.13 展示了缺陷分析的图像处理过程。首先，我们对水管二值图像采用 Canny 算法提取边缘，并使用膨胀操作加粗了水管外部边缘，如图 3.13 (c) 和图 3.13 (d) 所示。

与之前阈值处理的方法类似，在提取水管区域整体边缘信息时，我们将水管红外图像的蓝色分量图像作为目标灰度图像，原因是水管的缺陷区域在红外图像

中会呈现白色，白色的红、蓝分量值都很高，然而红色的蓝色分量值却很小，因此，在红外图像的蓝色分量图像中水管区域与缺陷区域的灰度值对比较大，有利于边缘的提取。如图 3.13 (e) 所示，水管缺陷部分与水管其他区域有明显的灰度差别。

我们对蓝色分量图像采用 Canny 算法，得到了水管区域整体边缘，如图 3.13 (f) 所示，并采取减法的方式减去水管区域外部边缘获取到了水管区域的内部边缘（图 3.13 (g)）。为了剔除更多的噪声，消除非缺陷区域的边缘，我们用蓝色分量图像和内部边缘图像进行了一个乘法运算，再进行二值化。图像的乘法即为矩阵的乘法，内部边缘图像为二值图像，边缘点像素值为 1，其他点像素值为 0，因此，乘法运算的最终结果是保留蓝色分量图像中内部边缘点像素值，将非边缘点像素值置为 0，如图 3.13 (h)，图像二值化的结果为图 3.13 (i)。




图 3.13 缺陷分析图像处理过程 (a) 水管二值图像 (b) 水管红外图像 (c) 水管外部边缘 (d) 膨胀后的外部边缘 (e) 水管红外图像蓝色分量 (f) 蓝色分量提取到的边缘 (g) 水管内部边缘 (h) 蓝色分量图像中的边缘 (i) 边缘二值化结果 (j) 边缘连接结果 (k) 边缘填充结果 (l) 填充区域

正如图 3.13 (i) 所示，得到的水管保温层缺陷边缘不是连续闭合的。因此，

我们采用 Peter Kovesei 在其个人主页上提供的边缘连接算法进行边缘的连接，该算法先找出边缘的端点，再将满足距离要求的端点连接起来，连接后的边缘为图 3.13 (j)。最后，我们采用了 MATLAB 中自带的 `imfill` 函数填充闭合边缘 (图 3.13 (k))，在减去边缘后获得了填充区域的二值图像 (图 3.13 (l))。在缺陷分析中，我们判断水管区域是否存在保温层缺陷的依据为填充区域的面积 S 和最高温度 t_s ，其中，面积 S 为该区域像素值为 1 的像素点总数，最高温度 t_m 为该区域前 1% 最高温度的平均值。如果填充区域面积 S 大于零，且最高温度 t_s 接近于水管区域最高温度 t_m ，则认为该水管存在保温层缺陷；否则，该水管不存在保温层缺陷。

值得注意的是，在缺陷分析中，相关参数是反复试验得到的结果，例如 Canny 算法的上下阈值、膨胀操作的结构元素等。这些参数应该根据实际情况，包括图像大小，水管大小，缺陷大小等因素来确定的。在本文中，Canny 算法的上阈值为 0.3，下阈值为 0.16；膨胀操作时使用的是 20×20 的结构元素；边缘连接设置的距离为 9 个像素点。

3.3 故障诊断

根据上述三个特征分析，本文制定了如图 3.14 所示的热水管故障诊断流程。




图 3.14 热水管道故障诊断流程

首先是进行温度分析判断水管区域是否存在温度异常点，如果存在异常则进一步判断最高温度与平均温度温差是否大于 4°C ，当不大于 4°C 时，认为水管存

在保温层破损故障；当大于 4℃时，再对管道进行管径分析，如果管径特征符合保温层脱落管道，则判定为保温层脱落故障，如果不符合，则判定为漏水故障。在第一步温度分析中，如果水管区域不存在温度异常点，则下一步进行缺陷分析来判断水管红外图像是否存在高温破损区域，如果存在，则判定为保温层破损故障；如果不存在，则管道无故障。

3.4 检验结果与讨论

为了验证算法的有效性和通用性，我们分别在实验条件和实际条件采集了相关图像数据，包括 290 张实验管道图像和 124 张实际管道图像，并对实验结果和案例结果进行了分析。

3.4.1 评价指标

对于二分类问题，可以将样例的真实值和分类结果的组合分为真正例（True Positive, TP）、真反例（True Negative, TN）、假正例（False Positive, FP）和假反例（False Negative, FN）四种情况，相应的混淆矩阵如表 3.1 所示。

表 3.1 二分类混淆矩阵

预测值	实际值	
	正例	反例
正例	TP	FN
反例	FP	TN

在混淆矩阵的基础上，我们选取准确率（ ACC ）、精确率（ P ）、召回率（ R ）和 $F1$ 作为评价指标，相应的定义如下：

$$ACC = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{TN} + n_{FP} + n_{FN}} \quad (3.15)$$

$$P = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (3.16)$$

$$R = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (3.17)$$

$$F1 = \frac{2 \times P \times R}{P + R} \quad (3.18)$$

其中， n_{TP} 为正确分类的正样本数量， n_{TN} 为正确分类的负样本数量， n_{FP} 为错误

分类的正样本数量， n_{FN} 为错误分类的负样本数量。

准确率是最常用的分类器性能度量指标，代表了所有样本分类正确的比例。精确率表示正样本分类正确的比例，召回率则表示被标记为正样本的样本中实际为正样本的比例。精确率和召回率是一对矛盾的度量，因此，我们还采用了 F1 度量来综合这两个指标。

很明显的是，本章中的水管故障诊断算法是要将水管分为四个类别，是个多分类问题。因此，在计算了各个类别的准确率、精确率、召回率和 F1 值后，我们还分别求取了平均值来评估算法的全局性能。

3.4.2 实验分析

3.4.2.1 实验平台

为了获得正常和不同故障条件下的水管红外图像，我们根据实际空调系统热水管道运行情况建立了实验平台，如图 3.15 所示。

实验所用水箱尺寸为 $500\text{mm} \times 500\text{mm} \times 300\text{mm}$ （长 \times 宽 \times 高），水管为镀锌钢管，直径为 40mm ，为减少系统热损失，水箱和管道外侧均采用了橡塑保温材料进行保温。系统右侧管段被设置为测试管段，两端为丝扣连接，方便拆卸以更换正常和不同故障类型的管段。实验过程采用的红外热像仪型号为 FLIR E6，具体技术参数如表 3.2 所示。

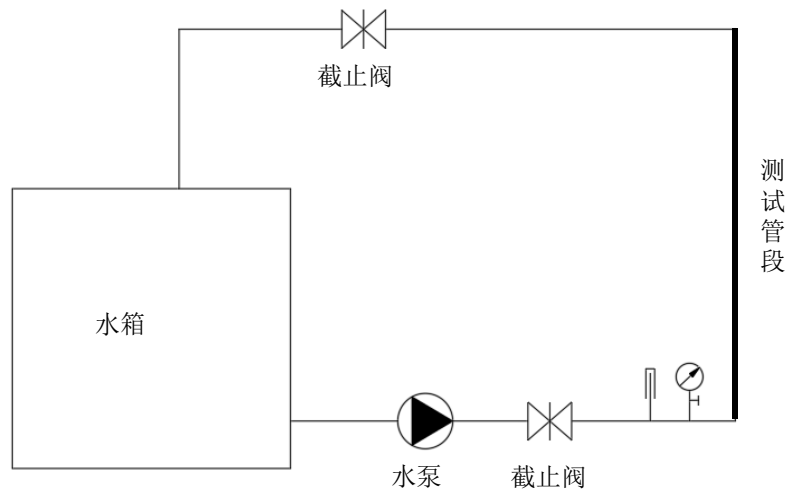


图 3.15 实验平台示意图

实验的目的是对四种不同类型管道进行红外图像的采集，包括正常管道、保温层破损管道、保温层脱落管道和漏水管道。具体实验步骤为：

- 准备好正常或故障管段，将系统完整连接；
- 将水箱内的水充注至标准水位，用电加热器加热至 50 °C；
- 打开水泵，系统开始运行，待系统稳定后，采集测试管段红外图像。

表 3.2 FLIR E6 红外热像仪参数

参数	性能
红外分辨率	160×120
热灵敏度	<0.06 °C
空间分辨率	5.2 mrad
测温范围	-20-250 °C
精度	±2°C或读数的 2%

3.4.2.2 实验结果

图 3.16 列举了四种热水管的实验红外图像，可以明显地看出无故障水管温度分布较为均匀，而故障水管的红外图像具有明显的温度异常。在实验室条件下，我们共采集了 290 张水管红外图像，其中包括无故障水管图像 64 张、保温层破损水管图像 101 张、保温层脱落水管图像 43 张和漏水水管图像 82 张，诊断结果见图 3.17，表 3.3 和表 3.4。

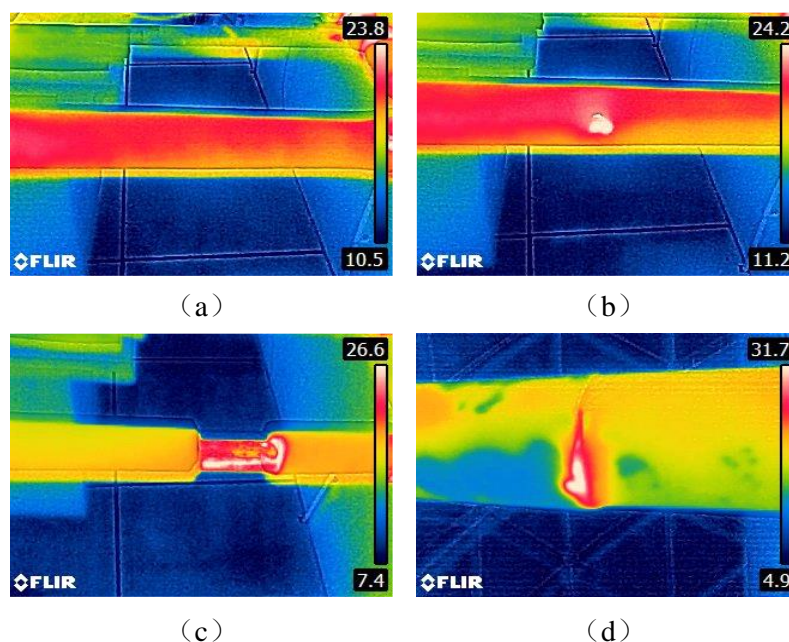


图 3.16 实验红外图像 (a) 无故障水管红外图像 (b) 保温层破损水管红外图像 (c) 保温层脱落水管红外图像 (d) 漏水水管红外图像

图 3.17 为实验数据诊断值与实际值的对比。在图中，管道类型 1 代表无故障

障水管，管道类别 2 代表保温层破损水管，管道类别 3 代表保温层脱落水管，管道类别 4 代表漏水水管；‘□’代表实验样本的实际类别，‘×’代表实验样本的诊断类别。从图中可以明显地看出，实际为无故障水管的图像中有 3 张图像被分类为了保温层破损水管，实际为保温层破损水管的图像中有 3 张图像被诊断为了无故障水管，实际为保温层脱落水管的图像中有 1 张图像被归为漏水水管，而实际为漏水水管的图像均诊断正确。因此，从实验数据整体来看，290 张图像数据中仅有 7 张图像诊断错误，分类正确的样本数占样本总数的比例为 97.59%，说明该算法具有较高的准确性。




图 3.17 实验诊断结果与实际值的对比

表 3.3 实验结果混淆矩阵

诊断值	实际值			
	无故障	保温层破损	保温层脱落	漏水
无故障	61	3	0	0
保温层破损	3	98	0	0
保温层脱落	0	0	42	0
漏水	0	0	1	82

表 3.4 实验结果评价指标

类别	准确率 (%)	精确率 (%)	召回率 (%)	F1 (%)
无故障	97.93	95.31	95.31	95.31
保温层破损	97.93	97.03	97.03	97.03
保温层脱落	99.65	97.67	100.00	98.82
漏水	99.66	100.00	98.80	99.40
平均值	98.79	97.50	97.79	97.64

表 3.3 为实验结果混淆矩阵，详细列出了每个类别诊断正确和诊断错误的样本数，其中，表格对角线为诊断正确的样本数，其余为诊断错误的样本数。表 3.4 为表 3.3 各个管道类别诊断结果的评价指标。从表 3.4 不难看出，每个类别的准

准确率、精确率、召回率和 F1 都在 95%以上，且整体平均值高达 97%以上。其中，漏水水管的误诊率为 0%，无故障、保温层破损和保温层脱落水管的误诊率分别为 4.69%、2.97%和 2.33%。在实际应用中，人们往往担心出现无故障诊断为有故障，有故障诊断为无故障的情况，表 3.4 中的无故障水管诊断准确率表明了出现这种误判的概率为 2.07%。因此，该算法在实验条件下能较为准确地诊断出水管的保温层故障和漏水故障，具有良好的性能。

3.4.3 案例分析

本次研究采集了上海市新江湾文化中心暖通机房内的热水管道图像作为实际数据以验证算法的有效性。图 3.18 列出了在其机房内采集到的保温层破损和无故障水管的红外图像和可见光图像，其中 (a) 和 (b) 为保温层破损水管的红外图像以及可见光图像，不难发现，由于长时间的运行，管道保温层因为脱胶发生了明显的破损。此外，红外图像中管道破损处的温度明显高于水管正常区域温度，比在可见光图像中具有更高的辨识度，因此，采用红外热像仪进行故障的排查比肉眼更加可靠。在对空调水系统的实地调查中我们发现，保温层破损多发生在管道连接处，相关人员或机器在进行故障检测时应多加注意。




图 3.18 实际楼宇水管图像 (a) 保温层破损水管红外图像 (b) 保温层破损水管可见光图像 (c) 无故障水管红外图像 (d) 无故障水管可见光图像

我们共采集了 124 张实际管道红外图像，其中包括了无故障水管图像 27 张和保温层破损水管图像 97 张，由于新江湾文化中心暖通机房内没有保温层脱落

和漏水的管道，我们未能取得这两类管道的实际数据。采用本文研究的故障诊断算法对实际数据进行诊断的结果见图 3.19、表 3.5 和表 3.6。

图 3.19 为案例诊断结果与实际管道类型的对比，其中类型 1 为无故障水管，类型 2 为保温层破损水管，从图中可以清晰地看出除了 9 个点以外，诊断值与实际值一致。其中，实际类型为无故障水管中有 4 张图片诊断错误，被归类到保温层破损的水管；实际类型为保温层破损水管中有 5 张图片诊断错误，被误判为无故障水管一类。




图 3.19 案例诊断结果与实际值的对比

表 3.5 实际结果混淆矩阵

诊断值	实际值	
	无故障	保温层破损
无故障	23	5
保温层破损	4	92

表 3.6 实际结果评价指标

类别	准确率 (%)	精确率 (%)	召回率 (%)	F1 (%)
无故障	92.74	85.19	82.14	83.64
保温层破损	92.74	94.85	95.83	95.34
平均值	92.74	90.02	88.99	89.49

从表 3.5 和表 3.6 可以看出，在实际数据中，该算法整体准确率为 92.74%，无故障和保温层破损的诊断精确率分别为 85.19%和 94.85%，误诊率分别为 14.81%和 5.15%，是较为准确有效的故障诊断算法。

尽管如此，与实验结果相比，该算法在实际楼宇空调水管系统中的诊断准确率有所下降，其原因为实际红外图像比实验红外图像更加复杂。对比图 3.16 和图 3.18 可以看出，实际机房内的热水管道较多，拍摄到的红外图像不仅会受到

周围管道的干扰，还会受到机房内灯光的影响，远远不如实验条件的理想。实际值为无故障管道的图像往往就是受到了周围管道和灯光的影响而被误判为保温层破损管道。

针对第一个原因，可以在图像采集的时候尽量避免周围管道和灯光的影响，选择合适的角度进行拍摄。除此之外，还可在图像分割中的开操作中选择更大的结构元素以清除背景对水管区域的影响。

3.5 本章小结

本章针对空调系统热水管道保温层破损、脱落和漏水故障，提出了一种基于红外图像的自动诊断算法，并在实验数据和实际数据中对其进行了检验，主要得出以下结论：

(1) 红外热像仪可准确记录水管发生保温层故障和漏水故障时出现的温度异常，是诊断该类故障的有效工具；

(2) 图像质量会影响图像分割的结果，从而影响到诊断结果的准确性。本文的算法对图像也有一定的要求，需保证水管在红外图像中为高温区域，尽量减少除水管外的其他热点，如灯管和其他支路水管。因此，在采集图像数据的时候，应选取合适的角度，尽量避免周围管道和机房灯光的影响；

(3) 图像分割部分进行闭操作和开操作的结构元素大小是根据图像大小和管道大小来确定的，若图像大小和管道大小发生变化，建议对相关参数进行调整，同理，在管径分析和缺陷分析中设定的相关阈值也建议进行调整；

(4) 在实际楼宇中，水管保温层破损多发生在水管交叉连接处，巡检人员应多加注意，进行定时的检查与维护；

(5) 该算法在实验数据和实际楼宇数据中的诊断精确率分别为 97.59%和 92.74%，具有较高的鲁棒性和一定的通用性，可配合巡检机器人或机房安置的红外摄像头在实际中得到应用；

(6) 尽管该算法可以较为准确地识别出空调系统热水管道的保温层和漏水故障，但还不能评估其严重程度，进一步的研究需要对此进行展开；

(7) 由于数据的限制，本章提出的算法只基于空调系统热水管道，但事实上对于冷水管道也是适用的。当将该算法应用于冷水管道时，在图像分割步骤中需将“提取红色分量”改为“提取蓝色分量”；在缺陷分析中，应该将“红色分量图像”作为边缘提取目标；在温度分析和缺陷分析等部分进行温度判断时，需检查水管温度是不是低于某值，而不是高于某值。

第4章 电机故障诊断算法的开发

电机被广泛应用于空调系统中的泵和风机，如果出现故障，将直接影响空调系统的正常运行。因此，电机的运行状态监测和故障诊断是必不可少的。

本章第一部分首先介绍了电机的常见故障和红外诊断现状。第二部分介绍了基于 R-CNN 的电机检测方法，以实现图像中电机的粗定位。第三部分详细介绍了在 MATLAB 环境下开发的电机图像分割方法，结合使用了电机的红外图像和可见光图像，并用实际电机图像检验了图像分割方法的有效性。最后，在第四部分，我们在实验条件下制造了通风不良故障，对通风不良造成的电机过热现象进行了动态分析和静态分析，提出了通风不良故障的诊断方法。

4.1 电机常见故障及红外诊断现状

4.1.1 电机常见故障

电机的故障可以分为机械故障和电气故障两个部分，其中机械故障主要包括了轴承故障和偏心故障，电气故障主要为定子故障和转子故障。

轴承故障是最为常见的电机故障，相关调查显示，40%以上的电机故障都与轴承有关^[56]。轴承故障通常是由维护不当造成的，例如润滑过程中污染物进入了电机，油质不好含有杂质，使用了错误的油脂或油，油脂过多等。此外，皮带过紧，过载，不对中，偏心 and 温度过高，都是引起轴承故障的原因。当发生轴承故障的时候，可以明显地感受到振动的异常和噪音。气隙偏心是另一个电机常见的机械故障，它指的是定、转子间径向气隙不相等的情况，具体可分为静态偏心、动态偏心和混合偏心三类。电机装配过程中轴承定位不良、轴承磨损、转轴弯曲都会导致偏心故障，同样地，偏心故障也会增加轴承的磨损，严重时还会导致定转子相互摩擦，烧毁电机。

定子故障主要是由绝缘损坏引起的匝间绕组故障。据观察，约有 19.53%的绕组故障是由过热造成的，温度过高会引起绝缘材料的失效，从而造成短路^[57]。电机的最大允许工作温度额定值取决于绝缘材料的类型，当电机运行温度超过其最高温度额定值时，温度每升高 10℃，绝缘材料寿命就会减少一半。电机的反复启动，三相电源电压的不平衡，电机过载都会增加绕组的温度。此外，瞬态电压也会导致绕组寿命的缩短，定转子摩擦、轴偏转、不对中等产生的机械冲击也会引起绕组故障。转子故障主要为转子条和端环断裂故障，生产工艺、运行操作不

当、工作环境恶劣以及频繁启动都是造成此类故障的原因，而转子断条故障还会进一步导致电机转速波动，转矩脉动，振动，过热和转子叠片损坏。

4.1.2 电机红外诊断现状

温度是衡量电机运行是否正常的重要指标。引起电机过热的原因有很多，大致可以分为电机自身、负载、电源和环境四个方面，具体见图 4.1。电机自身的一些故障例如匝间故障、转子断条等会引起电机的过热，同样地，电机的过热也会引发绝缘老化、轴承磨损、电刷磨损等电机故障的发生。因此，对电机进行温度监测不仅可以诊断出电机现有的故障，还能预防更多故障的发生，具有很大的价值。




图 4.1^[58] 电机过热原因

由于安装热传感器的成本高且难度大，红外诊断技术具有的非侵入式特点使它逐渐引起了相关学者的关注，它不仅可以在轻而易举地获取电机表面大范围的温度信息，还具有测温速度快和部署简单的优点。目前，它已被应用于电机匝间故障、转子断条、通风冷却系统故障和轴承故障的检测。尽管研究者们已开发了多种红外图像分析方法诊断电机故障，但大多数算法都需要相同电机正常运行时的红外图像作为支撑，在实际中应用还需进行相关数据的采集，通用性较差，实施起来不够简单方便。此外，现有的文献几乎未进行电机红外图像的分割，已有的图像分割方法也较为粗糙。因此，本章首先提出了一种较为精细的电机图像分割方法，可以较为精确地提取出电机红外图像中的电机区域，并在实际中得到了有效性的验证。其次，本章针对通风不良故障，提出了相应的故障诊断算法，尽管未能解决算法通用性的问题，但创新性地提出了高温区域面积占比作为故障诊断的指标，在电机未达到热稳定状态时也可检测出通风不良故障，具有一定的理论价值。

4.2 基于 R-CNN 的电机检测

目标检测不同于图像识别，它不仅可以进行多目标的识别，还可以获取目标在图中的具体位置。考虑到电机温度的不均匀性以及背景区域的复杂性，本文采用 R-CNN 的方法来获取图像中的电机位置，完成电机的初步定位，完整的图像分割方法在下一节进行讨论。

4.2.1 R-CNN 目标检测算法

R-CNN 不同于传统的目标检测算法，采用深度卷积网络提取特征，主要包括以下几个步骤：①采用选择性搜索（selective search）从图像中提取约 2000 个候选区域；②调整候选区域大小以满足深度卷积神经网络的输入要求；③采用深度卷积网络提取候选区域特征；④SVM 分类器根据提取到的特征判断是否属于该类；⑤采用回归模型调整候选框的位置。

4.2.1.1 提取候选区域

在提取候选区域中，R-CNN 采用了选择性搜索的方法，具体步骤如图 4.2 所示^[59]，先是采用了基于图的图像分割方法获取初始区域，再计算初始区域中每两个相邻区域的相似度，每次合并相似度最高的两个区域并重新计算新区域和剩余区域的相邻区域相似度，直至整张图像已合并为一个区域，输出所有区域的位置框。




图 4.2 选择性搜索算法流程

选择性搜索算法在计算相邻区域的相似度时考虑了颜色相似度、纹理相似度、大小相似度和吻合相似度。在颜色相似度计算部分，先是获取每个区域 r_i 每个颜色通道的 25bins 直方图，得到一个 75 维的向量 $C_i = \{C_i^1, \dots, C_i^{75}\}$ ，采用 L1 范数

对其进行标准化后，按照以下公式计算区域 r_i 和 r_j 的颜色相似度 $S_{colour}(r_i, r_j)$ ：

$$S_{colour}(r_i, r_j) = \sum_{k=1}^{75} \min(c_i^k, c_j^k) \quad (4.1)$$

在纹理相似度计算部分，对每个区域每个颜色通道的 8 个不同方向使用方差为 1 的高斯微分，再提取每个颜色通道每个方向的 10bins 直方图，得到一个 240 维的向量 $T_i = \{T_i^1, \dots, T_i^{240}\}$ ，采用 L1 范数对其进行标准化后，按照以下公式计算区域 r_i 和 r_j 的纹理相似度 $S_{texture}(r_i, r_j)$ ：

$$S_{texture}(r_i, r_j) = \sum_{k=1}^n \min(t_i^k, t_j^k) \quad (4.2)$$

大小相似度可以促进小区域先进行合并，其计算公式如下：

$$S_{size}(r_i, r_j) = 1 - \frac{size(r_i) + size(r_j)}{size(im)} \quad (4.3)$$

其中 $size(im)$ 为整张图像大小。

合并后区域的最小外接矩形越小，吻合度就越高，吻合相似度 $fill(r_i, r_j)$ 的表达式如下：

$$fill(r_i, r_j) = 1 - \frac{size(BB_{ij}) - size(r_i) - size(r_j)}{size(im)} \quad (4.4)$$

其中 $size(BB_{ij})$ 为合并后区域最小外接矩形的大小。

四种相似度的线性组合如下：

$$S(r_i, r_j) = a_1 S_{colour}(r_i, r_j) + a_2 S_{texture}(r_i, r_j) + a_3 S_{size}(r_i, r_j) + a_4 S_{fill}(r_i, r_j) \quad (4.5)$$

其中 $a_i \in \{0, 1\}$ 。

4.2.1.2 调整候选区域大小

卷积神经网络的输入层对图像的大小有要求，R-CNN 算法提出者采用的方法是在候选区域周围填充 16 像素然后再进行图像的缩放。

4.2.1.3 卷积神经网络提取特征

R-CNN 算法中的卷积神经网络采用的是预先训练好的卷积神经网络，通过迁移学习实现对候选区域特征的提取。采用预训练的网络是需要对其进行微调的，与设备分类章节类似，需要将网络最后一个全连接层的大小修改为 $N+1$ ，其中 N 为类别，加上的 1 代表为背景。

选择性搜索产生了约 2000 个候选区域，但是这些区域中，有些是存在目标

物体的，有些是不存在目标物体的。因此，在对卷积神经网络进行训练前对候选区域进行了筛选。具体方法是计算候选区域与人工标注的物体真实区域的重叠度 IoU (Intersection over Union)，即两区域交集与两区域并集的面积比值，IoU 大于 0.5 的样本被认为是正样本，反之被认为是负样本。人工标注的物体真实区域也属于正样本。

4.2.1.4 SVM 分类器

在针对每个类别训练 SVM 分类器时，为了实现物体的精准定位，训练的正样本为事先人为标定好的物体真实区域，负样本为与真实物体区域的 IoU 值小于 0.3 的样本。

SVM 分类器的输入为 AlexNet 第二个全连接层输出的特征，维度为 2000×4096 ，输出是对 2000 个候选区域的打分，最后通过非极大值抑制法去除相交的多余的区域。非极大值抑制法，就是保留局部得分最高的区域，去除其他得分较低并且与之重叠度较高的区域。

4.2.1.5 精修候选框

为了提高候选框定位的准确性，使其接近于人为标定的真实物体边界框，R-CNN 算法采用了线性回归器对候选框进行调整。假设预测的候选框为 $P = (P_x, P_y, P_w, P_h)$ ，其中 P_x 和 P_y 为中心点位置， P_w 和 P_h 分别为候选框的宽度和高度，相应的真实物体边界框为 $g = (g_x, g_y, g_w, g_h)$ 。预测候选框中心点的平移和宽高度方向的缩放可以使其不断接近于真实物体边界框，假设变形后的候选框为 $\hat{g} = (\hat{g}_x, \hat{g}_y, \hat{g}_w, \hat{g}_h)$ ，表达式如下：

$$\hat{g}_x = p_w d_x(P) + p_x \quad (4.6)$$

$$\hat{g}_y = p_h d_y(P) + p_y \quad (4.7)$$

$$\hat{g}_w = p_w \exp(d_w(P)) \quad (4.8)$$

$$\hat{g}_h = p_h \exp(d_h(P)) \quad (4.9)$$

其中 $d_x(P)$ 为 x 方向的预测平移量， $d_y(P)$ 为 y 方向的预测平移量， $d_w(P)$ 为预测的宽度缩放量， $d_h(P)$ 为预测的高度缩放量。

而真实平移量和缩放量为：

$$t_x = \frac{g_x - P_x}{P_w} \quad (4.10)$$

$$t_y = \frac{g_y - P_y}{P_h} \quad (4.11)$$

$$t_w = \log\left(\frac{g_w}{P_w}\right) \quad (4.12)$$

$$t_h = \log\left(\frac{g_h}{P_h}\right) \quad (4.13)$$

线性回归器的输入为 AlexNet 第五个卷积层输出的特征向量 $\phi_5(P)$ ，输出值为 $d_*(P) = w_*^T \phi_5(P)$ (*表示 x, y, w, h)，训练样本为与标定区域重叠度 IoU 大于 0.6 的区域的候选框，回归器优化目标为：

$$W_* = \operatorname{argmin}_{w_*} \sum_i^N \left(t_*^i - \hat{w}_*^T \phi_5(P^i) \right)^2 + \lambda \|\hat{w}_*\|^2 \quad (4.14)$$

其中 $\lambda = 1000$ 。

4.2.2 R-CNN 检测器训练及检测结果

在进行 R-CNN 检测器训练之前，我们准备了共 927 张电机图像，并手动标注出了图像中的电机区域，其中 744 张图像为训练集，剩余的 183 张图像为测试集。在 MATLAB 环境下，我们下载了预训练 AlexNet 网络，并对 AlexNet 网络进行微调。与设备分类章节类似，我们将 AlexNet 网络最后一个全连接层大小修改为 2，分别代表电机类别和背景类别，然后进行 R-CNN 检测器的训练。

在评价检测器方面，我们选择了检测率作为评价指标，默认得分最高的区域为最终的检测结果，当输出区域与人工标注的物体真实区域的重叠度 IoU 大于 0.5 时，我们认为电机被成功检测出来了，否则，电机未被检测出来。因此，检测率的定义如下：

$$\text{检测率} = \frac{\text{检测成功的图像数}}{\text{图像总数}} \times 100\% \quad (4.15)$$

表 4.1 为 R-CNN 检测器完成训练后在测试集上的检测结果。从结果上来看，该检测器的检测率高达 95.08%，可以较为准确地识别出图像中的电机区域，保证后续图像分割的顺利进行。为了更直观地表达检测结果，图 4.3 还列举了 R-CNN 检测器在训练集上识别出的电机区域（蓝色框内的区域）。

需要注意的是，为了使 R-CNN 电机检测器能较为准确地检测出电机的位置，在进行图像采集时应保持周围良好的光照环境，尽量完整地呈现电机，避免管道

部件及其他设备的遮挡。

表 4.1 电机测试集检测结果

图像总数 (张)	检测成功图像数 (张)	检测失败图像数 (张)	检测率 (%)
183	174	9	95.08




图 4.3 电机 R-CNN 检测器检测出的电机区域

4.3 电机图像分割方法

在本文中，我们采取的电机图像分割方法如图 4.4 所示，主要分为粗分割、判断电机运行状态和细分割三个部分。




图 4.4 电机图像分割流程

在粗分割中，先使用训练好的 R-CNN 检测器获取可见光图像中电机区域的边框信息，在对原始红外图像进行调整后，将边框信息应用于调整后的红外图像，获得粗定位的电机红外图像。在进行细分割之前，我们对比粗定位电机区域的温度和背景区域的温度来判定电机的运行状态，对于关机电机直接输出电机处于关机状态的结果，不进行故障诊断，对于开机电机进行下一步细分割。由于 R-CNN 检测器预测的边界框为矩形，取得的电机部分往往还包括一些背景区域，因此需要进行进一步的处理消除背景区域。细分割部分与水管的图像分割方法类似，结合了阈值处理和形态学操作的方法，具体介绍请参考下文。

4.3.1 粗分割

粗分割结合使用了红外图像和可见光图像，可见光图像提供电机的具体位置，红外图像提供电机的温度信息，下面将结合每一步骤处理结果（如图 4.5）进行详细说明。




图 4.5 电机粗分割处理结果 (a) 电机可见光图像 (b) R-CNN 检测电机结果 (c) 原始红外图像 (d) 边界填充后红外图像 (e) 粗定位电机红外图像

首先，使用已经训练好的 R-CNN 电机检测器检测出可见光图像中得分最高的电机区域，得到电机区域边界框 $P(x, y, w, h)$ ，其中 x 和 y 为边界框左上角坐标， w 和 h 分别为边界框的宽度和高度，然后将其应用于红外图像中获取红外图像中的电机区域。但观察图 4.5 (a)、(c) 可以看出，红外热像仪拍摄得到的可见光图像与红外图像并非一一对应关系，且可见光图像大小为 480×640 ，红外图像大小为 240×320 。因此，在这之前，需对红外图像进行调整，本文采用的方法是

缩放和边界填充。先将红外图像大小缩放为 370×480 ，然后再进行边界填充，填充方法为复制边界像素，上下左右四个方向填充的像素分别为 90、20、100 和 60，处理结果如图 4.5 (d) 所示。最后，将边界框放入调整后的红外图像，裁剪得到粗定位电机红外图像，需要在此说明的是，如果边界框落在了红外图像的填充区域，则缩小其范围，使其只包含原始红外图像区域。

4.3.2 判别电机运行状态

机房内的电机不一直都是处于开机状态的，在对其进行故障诊断之前，判断电机的运行状态是很有必要的。粗分割将红外图像分为电机区域和背景区域，通过比较电机区域和背景区域平均温度的大小，可以得知电机是否处于运行状态。在本文中，如果电机区域平均温度高于背景区域平均温度 2°C 以上，认为电机处于开机状态，否则，认为电机处于关机状态。

图 4.6 举例说明了电机未开机的情况，上方分别为电机原始红外图像和粗定位电机红外图像，下方为除去电机区域的背景红外图像和裁剪后的背景红外图像。将原始红外图像中的电机区域设置为黑色即可得到背景红外图像，对其进行裁剪的目的是清除图像左下角的 logo 区域和右侧的温度标尺区域。




图 4.6 未开机电机红外图像 (a) 未开机电机原始红外图像 (b) 粗定位电机红外图像
(c) 未开机电机背景红外图像 (d) 裁剪后未开机电机背景红外图像

电机区域平均温度 T_{mm} 和背景区域平均温度 T_{mb} 的定义分别为:

$$T_{mm} = \frac{T_{zd}}{n_{zd}} \quad (4.16)$$

其中 T_{zd} 为粗定位电机红外图像温度值大于零的像素点温度总和, $^{\circ}\text{C}$; n_{zd} 为粗定位电机红外图像温度值大于零的像素点总数。

$$T_{mb} = \frac{T_{zb}}{n_{zb}} \quad (4.17)$$

其中 T_{zb} 为裁剪后电机背景红外图像中温度值大于零的像素点温度总和, $^{\circ}\text{C}$; n_{zb} 为裁剪后电机背景红外图像中温度值大于零的像素点总数。

使用上式对图 4.6 的计算结果为: 电机区域平均温度为 11.89°C , 背景区域平均温度为 13.16°C 。因此, 该电机处于关机状态。

对于处于关机状态的电机, 直接输出其运行状态, 不进行故障诊断; 对于处于运行状态的电机, 进行下一步细分割得出精定位电机红外图像, 再进行故障诊断。

4.3.3 细分割

粗分割得到的电机红外图像中还包含了部分背景区域, 细分割的目的是消除粗定位电机红外图像的背景区域, 下面结合每一步骤的图像处理结果(如图 4.7)进行详细说明。




图 4.7 细分割图像处理结果 (a) 粗定位电机红外图像 (b) (a) 的红色分量图像 (c) 阈值分割结果 (d) 形态学处理结果 (e) 精定位电机红外图像

和水管图像分割方法相似, 由于电机运行时温度会明显高于环境温度, 因此, 在进行阈值分割前, 先提取红外图像红色分量图像作为阈值处理目标, 处理结果如图 4.7 (b) 所示。阈值分割采用的方法跟水管部分一样, 将右峰灰度值作为阈值进行图像分割, 处理结果如图 4.7 (c)。阈值处理结果已经较为初步地提取

到了电机区域，但还存在一些细小隙缝和边缘的毛刺，因此，先采用闭操作填充隙缝，再采用开操作去除毛刺，相应的图像处理结果为图 4.7 (d)，即电机区域的二值图像。采用乘法运算，保留红外图像中电机区域的颜色不变，其他区域的颜色设置为黑色，处理结果为图 4.7 (e)，即最终的电机红外图像。

为了验证图像分割方法的有效性，图 4.8 还列举了一些在实际机房拍摄得到的电机图像分割结果。从分割结果可以看出，该算法具有较好的鲁棒性，能较为准确地提取出红外图像中的电机区域，便于后续的分析。




图 4.8 实际机房电机图像分割结果

4.4 电机通风不良故障分析

我们采用在电机风扇罩外侧粘纸的方式来模拟电机通风不良引起的故障(如图 4.9 所示)，在实验条件下采集了正常电机和通风故障电机的红外图像，并对采集到的图像进行了动态分析和静态分析。实验使用的红外热像仪为 FLIR E6，

具体参数见第三章的表 3.2。为了避免电机温度过高而引起其他的故障，在实验过程中我们将电机表面最高温度控制到了 45℃ 以内。




图 4.9 通风口正常电机（左）和通风口全封电机（右）

4.4.1 动态分析

我们监测了无故障电机和通风口被完全挡住的具有通风障碍的电机开机过后温度逐渐上升的过程，以 30s 为时间步长拍摄红外图像，并计算电机区域的最高温度，得到了最高温度随时间变化的曲线，如图 4.10 所示。在计算电机区域最高温度的时候，我们采用的是粗定位电机红外图像，且最高温度取的是前 10% 最高温度的平均值。

观察曲线可以发现，在开机后前 4.5min 中，正常电机和有通风障碍电机的最高温度几乎没有差别，在 4.5min 后，故障电机最高温度曲线逐渐高于且远离正常电机最高温度曲线。在到达 18.5min 的时候，正常电机的温度已经趋于稳定，而通风故障电机的温度还在继续上升。

尽管观测电机最高温度动态变化可有效检测出电机的通风故障，但在实际条件下对单台电机进行长时间的监测是不经济的，因此，我们还提出了静态分析来判断电机是否存在通风故障。




图 4.10 正常和通风故障电机开机后最高温度变化曲线

4.4.2 静态分析

图 4.11 列出了三种类型的电机红外图像，分别为正常电机红外图像，通风口半封电机红外图像以及通风口全封电机红外图像。其中正常电机和通风口半封电机已达到热稳定状态，通风口全封电机还未达到热稳定状态。对比三张图像可以发现，存在通风故障电机的温度高于正常电机的温度，且故障程度越大温度越高。此外，观察三个电机的红色区域和白色区域可以发现，具有通风故障电机的高温区域面积也较大。因此，可以通过分析电机区域温度特性以及高温区域面积来判断其是否存在通风故障。




图 4.11 三种电机红外图像 (a) 无故障电机红外图像 (b) 通风口半堵住的电机红外图像 (c) 通风口全堵住的电机红外图像

4.4.2.1 温度分析

温度分析包括电机区域最高温度、平均温度、温度标准差以及风扇区域温度的分析，其中电机区域最高温度取的是前 1%最高温度的平均值，风扇区域温度为风扇区域的平均温度，最高温度、平均温度和温度标准差是从精定位电机红外图像中提取的，风扇温度是通过风扇红外图像获得。

我们选取了每种电机的三张图像进行最高温度、平均温度和标准差分析，得到了如图 4.12 的结果。其中蓝色圆圈代表的电机类型为无故障电机，橙色矩形代表的电机类型为通风口被半封的故障电机，绿色六角形代表的电机类型是通风口被全封的故障电机，无故障电机和通风口半封电机已达到热稳定状态，通风口全封电机未达到热稳定状态。

从图 4.12 可以看出，从无故障电机到通风口全封电机，最高温度、平均温度和标准差是依次递增的。在相同环境条件下，无故障电机达到热稳定状态时，最高温度、平均温度和标准差分别在 33°C、28°C 和 1.8°C 左右；通风口半封电机达到稳定时，最高温度、平均温度和标准差分别在 38°C、33°C 和 2.2°C 左右；而通

风口全封电机的电机在最高温度和平均温度达到 43°C 和 37°C 时，温度还在持续上升，相应地，其温度标准差也明显高于其它两类电机。




图 4.12 三种类型电机的最高温度、平均温度和标准差

除了对比电机区域的最高温度、平均温度和温度标准差，我们还对电机的风扇区域进行了分析。前面的电机图像分割方法得到的精定位电机红外图像中是不包括风扇部分的，因此，在进行风扇部分的温度分析之前，我们要先获取这部分的红外图像，具体的图像分割方法如图 4.13 所示。




图 4.13 风扇区域图像分割方法

在风扇区域图像分割方法中，输入为粗定位电机红外图像和精定位电机二值图像，输出为风扇红外图像。相应地，图 4.14 使用图像详细说明了各步骤图像处理的过程。首先，我们提取了粗定位电机红外图像的蓝色分量图像，作为边缘提取的对象，如图 4.14 所示。然后，我们使用 Canny 边缘检测算法对蓝色分量图像进行边缘的提取，我们认为被边缘包裹的部分为电机加风扇的区域，所以采用闭操作对边缘图像进行填充，最终的处理结果为图 4.14(d)。为了得到风扇区域，

我们用闭操作形成的二值图像减去电机精分割部分得到的二值图像，但观察图 4.14 (f) 可以发现，相减后的图像不只为风扇区域，因此，我们采取了开操作并保留了图像中面积最大的连通域来除去非风扇区域，最终得到了风扇二值图像，如图 4.14 (h)。最后，我们结合粗定位电机红外图像和风扇二值图像，获得了风扇区域的红外图像，如图 4.14 (i)。




图 4.14 风扇区域提取过程 (a) 粗定位电机红外图像 (b) (a) 的蓝色分量图像 (c) Canny 边缘检测结果 (d) 闭操作结果 (e) 精定位电机二值图像 (f) (d) - (e) 的结果 (g) 开操作结果 (h) 保留面积最大连通域结果 (i) 风扇红外图像

与最高温度、平均温度和温度标准差的分析一样，我们采用了同样的样本来进行风扇区域平均温度的分析，得到了如图 4.15 所示的三种不同电机风扇区域的平均温度。与最高温度、平均温度、温度标准差一致，通风口被全封的电机风扇区域温度最高，其次是通风口半封的电机，温度最低的为正常电机的风扇区域。




图 4.15 三种类型电机的风扇区域平均温度对比图

4.4.2.2 高温区域分析

高温区域分析是分析电机区域的高温区域面积占比 R_{hot} 和更高温区域面积占比 R_{hotter} ，其定义为：

$$R_{hot} = \frac{S_{hot}}{S_d} \times 100\% \quad (4.18)$$

其中 S_{hot} 为电机高温区域面积，即红外图像中红色和白色部分区域， S_d 为电机区域总面积。

$$R_{hotter} = \frac{S_{hotter}}{S_d} \times 100\% \quad (4.19)$$

其中 S_{hotter} 为电机更高温区域面积，即红外图像中的白色部分。

获取 R_{hot} 和 R_{hotter} 也是通过图像处理完成的，具体是设置相应的颜色阈值完成颜色的提取，然后统计像素个数。将 R 值大于 120，G 值小于 100 且 B 值小于 100 的像素或 R 值大于 150，G 值大于 50 且 B 值大于 90 的像素当作高温点进行提取，将 R、G、B 值均大于 150 的像素当作更高温点进行提取，图 4.16 分别列举了正常电机和通风口全封电机的高温区域、更高温区域提取结果， S_{hot} 为高温点总数， S_{hotter} 为更高温点总数。观察图 4.16 可以发现，由于图像分割的影响，通风口全封电机精定位红外图像的下方包含了更多的底座信息，如果直接统计电机精定位红外图像中的像素个数，得到的比值会比真实值偏小。因此，为了消除图像分割的影响，我们将高温区域所处列值范围和行值范围内的电机像素总数作为电机区域总面积 S_d 。




图 4.16 高温区域提取结果 (a) 正常电机精定位红外图像 (b) (a) 的高温区域 (c) (a) 的更高温区域 (d) 通风口全封电机精定位红外图像 (e) (d) 的高温区域 (f) (d) 的更高温区域

同样地，使用温度分析中的样本进行高温区域分析的结果如图 4.17 所示。可以发现，高温区域占比是区别三种电机类型的有效指标，正常电机的高温区域占比在 80%以下，通风口半封电机的高温区域占比在 80%-85%之间，而通风口全封电机的高温区域占比高达 90%左右。观察三种电机的更高温区域占比可以发现，尽管通风口半封电机的更高温区域占比略高于正常电机，但两者十分接近，难以区分，而通风口全封电机的更高温区域占比明显高于其他两种电机。因此，高温区域占比可有效检测通风故障，并实现故障等级的划分，而更高温区域占比只能检测出较为严重的通风故障。




图 4.17 三种类型电机的高温区域和更高温区域面积占比

4.4.2.3 故障诊断

当电机还未达到热稳定状态，且运行温度低于正常电机热稳定状态下的运行温度时，采用温度分析来判断电机是否发生故障是不可行的。图 4.18 列举了运行温度相近的正常电机和通风口全封电机的红外图像，两个电机均未达到热稳定状态，对其进行温度分析和高温区域分析的结果如表 4.2 所示。从分析结果可以明显地看出，在此种情况下，温度分析无法实现两种电机的区分，而高温区域分析能有效检测出电机的通风故障。因此，本文将高温区域面积占比和更高温区域面积占比作为电机通风不良故障诊断模型的输入。




图 4.18 相同运行温度下的正常电机（左）和通风口全封电机（右）

表 4.2 图 4.18 电机的温度分析和高温区域分析结果

电机类型	温度分析			高温区域分析		
	最高温度 (°C)	平均温度 (°C)	标准差 (°C)	风扇区域温 度 (°C)	高温区域面积 占比 (%)	更高温区域面 积占比 (%)
正常	26.32	22.36	1.46	16.38	71.57	12.12
通风口全封	26.05	21.99	1.70	14.53	81.45	15.63

在电机通风不良故障诊断中，我们采用了 K 近邻 (KNN) 分类算法。K 近邻分类算法是一种常见的监督学习算法，其工作原理是基于某种距离度量，找出距离测试样本最近的 K 个已正确分类的样本，然后根据这 K 个最近邻居决定测试样本的类别。在本文中，我们采用欧式距离来度量样本之间的距离。在欧几里得空间中，两点 $x = (x_1, x_2, x_3, \dots, x_n)$ 和 $y = (y_1, y_2, y_3, \dots, y_n)$ 之间的欧式距离 $d(x, y)$ 表示为：

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.20)$$

当不设置邻居的权重时，测试样本的类别由邻居的“多数表决”决定，即 K 个最近邻居出现最多的类别。然而，当不同类别的样本数量差别很大时，采用这种方法容易造成误判。因此，本文采用距离的倒数来设置邻居的权重，使距离更近的邻居对于决策更重要，即第 i 个最近邻居的权重 W_i 为：

$$W_i = \frac{1}{d_i} \quad (4.21)$$

其中 d_i 为第 i 个最近邻居与待测样本的距离。

在 K 近邻算法中，K 的取值显然是十分重要的。本文在实验室条件下共采集到了 100 组电机图像数据，包括 43 组正常电机图像和 57 组通风故障电机图像，在对每组电机进行图像分割，提取相应的高温区域面积占比 R_{hot} 和更高温区域面积占比 R_{hotter} 后，得到了最终的数据集。对于不同的 K 值，本文采用十折交叉验证，将数据集平分为 10 等份，每次取其中 9 份作为训练集，剩余的 1 份作为测试集，共重复 10 次，将 10 次结果的整体准确率 P_{10} 作为评价指标，其定义为：

$$P_{10} = \frac{n_f}{N} \quad (4.22)$$

其中 n_f 为 10 次训练测试被正确分类的样本数， N 为总样本数。

图 4.19 为不同 K 值十折交叉验证结果的整体准确率 P_{10} ，可以明显地看出，当 $K=3$ 时， P_{10} 最大。因此，本文取 $K=3$ 。相应地，图 4.20 为 $K=3$ 的十折交叉验证验证结果，其中正方形为正确分类的无故障电机，三角形为正确分类的通风故障电机，叉形代表实际类型为通风故障，但被错误分类到无故障的电机。在 100 份数据中，仅有 1 份数据分类错误，可以看出，该分类器能较为准确地分类实验电机无故障状态和通风故障状态。




图 4.19 不同 K 值的整体准确率 P_{10}




图 4.20 $K=3$ 十折交叉验证结果

4.5 本章小结

本章介绍了电机常见故障和红外诊断现状，开发了基于 R-CNN 的电机图像

分割方法，并在实验室条件下提出了电机通风不良故障的诊断方法，主要得出以下结论：

(1) 电机自身故障、电源因素、负载因素和环境因素都会导致电机的过热，观察电机是否过热不仅可以进行故障诊断，还能避免电机过热造成更多的故障和损失；

(2) 尽管红外诊断技术已被应用于电机匝间故障、转子断条、通风冷却系统故障和轴承故障的检测，但目前的算法通用性较差，而且几乎不包含电机的图像分割；

(3) 本章结合电机可见光图像和红外图像，开发了基于 R-CNN 的电机图像分割方法，经实际数据证明，该方法能较为准确地提取出红外图像中的电机区域；

(4) 本章在实验室条件下采用在风扇罩外侧粘纸的方式模拟了电机的通风不良故障，并对电机红外图像进行了动态分析和静态分析。动态分析的结果表明，故障电机具有更高的温升速率。静态分析的结果表明，故障电机具有更高的温度指标和高温区域指标，且故障程度越大，指标越高。

(5) 本章结合图像分割和静态分析，将电机的高温区域面积占比和更高温区域面积占比作为输入，采用 K 近邻算法来识别电机的通风故障。在 100 组实验数据的检验下，该算法可以较为准确地分辨出实验电机的无故障状态和通风故障状态。

第5章 方形散流器故障诊断算法的开发

风口作为室内气流组织的一部分，影响着室内温湿度的分布，如果出现故障而未及时得到维修，将直接引起室内热舒适度下降以及用户的投诉和不满。因此，风口的故障诊断具有重要意义。

本章选取了应用较为广泛的方形散流器（在本章中简称为“风口”）作为研究对象，开发了相应的图像分割算法、运行工况分类算法和送风不均匀故障诊断方法。首先，本章的第一部分介绍了风口的图像分割方法，与电机部分类似，先是采用了 R-CNN 目标检测算法进行初步的分割，然后结合边缘提取和形态学处理方法完成完整的分割。第二部分介绍了基于决策树的风口运行工况判别算法，该算法即使在风口红外图像中有灯光的情况下也能较为准确地判断风口是处于出热风，出冷风还是出常温风或未出风三种状态。最后，本章的第三部分在实验室条件下分析了风口送风不均匀故障，并根据分析结果建立了基于 SVM 的故障诊断模型来判断风口是否存在送风不均匀故障。

5.1 风口图像分割方法

考虑到风口背景的多样性和复杂性，在风口图像分割方法中，我们也采用了 R-CNN 目标检测算法，具体流程见图 5.1。




图 5.1 风口图像分割方法

风口图像分割算法的输入为可见光图像和原始红外图像，输出为精定位风口红外图像。首先，与电机图像分割方法中的粗分割一致，我们先是采用 R-CNN 检测器初步框选出红外图像和可见光图像中的电机区域，并将其裁剪出来，经过调整，裁剪后的红外图像和可见光图像是一一对应的关系。其次，我们对可见光风口区域图像进行了边缘提取和形态学操作，获得了风口区域的二值图像。由于实际风口区域为凸集，因此，为了更加接近于实际风口区域，我们选择了风口区域二值图像的凸集。最终，我们再利用粗定位风口红外图像，将得到的二值图像转换为精定位风口红外图像。

5.1.1 风口 R-CNN 检测器

风口 R-CNN 检测器的训练步骤与电机的一样，在此不再做详细的介绍。我们将现有的 448 张方形散流器图像分为训练集和测试集，其中训练集包含了 358 张图像，测试集包含了 90 张图像，在 R-CNN 检测器训练完毕后，按照与电机部分相同的规则，采用检测率来评价其在测试集上的检验结果。

风口测试集最终的检测结果见表 5.1 和图 5.2（蓝色矩形框为检测结果）所示，从结果可以看出，训练得到的 R-CNN 检测器在测试集上的检测率高达 97.78%，基本满足要求，可为后续的图像分割工作提供良好的基础。图 5.2 也清晰地显示出，对于不同吊顶形式的方形散流器，该检测器依然可以较为准确地找到图像中的风口区域。因此，该检测器具有较好的通用性和鲁棒性。

表 5.1 风口测试集检测结果

图像总数（张）	检测成功图像数（张）	检测失败图像数（张）	检测率（%）
90	88	2	97.78

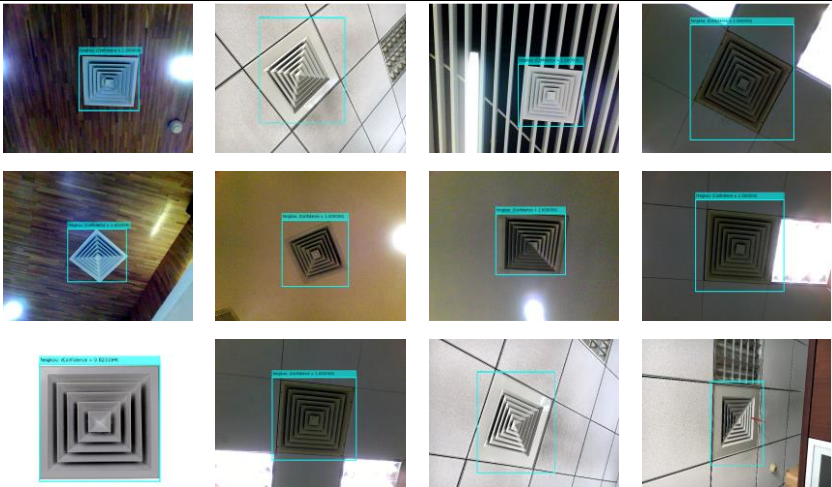


图 5.2 风口 R-CNN 检测器检测出的风口区域

5.1.2 粗分割

风口图像的粗分割与电机部分的一致，先是由 R-CNN 检测器获取风口区域边框信息，再采用与电机部分同样的方法对原始红外图像进行缩放和边界填充，目的是使调整后的红外图像除边界填充部分与可见光图像一一对应，最后，将风口区域边框信息应用于调整后的红外图像，切割出相应的部分，得到粗定位风口红外图像，见图 5.3 所示。




图 5.3 风口粗分割处理结果 (a) 风口可见光图像 (b) R-CNN 检测风口结果 (c) 原始红外图像 (d) 调整后的红外图像 (e) 粗定位风口红外图像

5.1.3 细分割

R-CNN 检测出的风口区域往往还包含有背景区域，细分割的目的就是获得更精确的风口区域，为后续分析提供更好的图像基础。图 5.4 详细展示了细分割过程图像处理的结果，接下来我们将借助图 5.4 进行每一步骤的详细说明。

由上一步的粗分割，我们获得了粗定位的风口红外图像，如图 5.4 (a)。相应地，我们裁剪出 R-CNN 检测器在可见光图像中的检测结果，如图 5.4 (b)。不难发现，图 5.4 (a) 和 5.4 (b) 具有一一对应的关系。在可见光图像中，风口区域的边缘是较为明显的，因此，后续的图像处理都是基于可见光图像的，即提取出可见光图像中的风口区域，再将其应用到一一对应的红外图像中。

首先，我们采用了 Canny 算子对可见光风口区域进行了边缘提取，处理结果见图 5.4 (c)。然后，我们采取了一系列的形态学操作来获取风口区域的二值化图像，其中包括了闭操作填充边缘区域，开操作去除图像中多余的毛刺并平滑边

界，腐蚀操作去除风口的边缘部分，处理结果分别为图 5.4 (d)、图 5.4 (e) 和图 5.4 (f)。方形散流器区域在图像中是为凸集的，因此，为了更接近于实际风口区域，我们取腐蚀结果的凸集作为最终的风口区域。因为是在 MATLAB 环境下开发的算法，图 5.4 (f) 的凸集图像 (图 5.4 (j)) 的大小为其最小外接矩形的大小，所以需要先将腐蚀操作结果的最小外接矩形边框信息应用于粗定位风口红外图像，得到最小外接矩形包围的红外图像，如图 5.4 (i)。图 5.4 (i) 和图 5.4 (j) 也是一一对应的关系，因此，我们记录凸集图像中像素值为 1 的像素坐标，使红外图像中相应坐标点的颜色保持不变，将其他点的颜色设为黑色，得到了如图 5.4 (k) 所示的最终的结果。本文在进行风口的细分割时，边缘提取 Canny 算法的上阈值为 0.1，下阈值为 0.05；闭操作使用的是 50×50 的结构元素，开操作使用的是 20×20 的结构元素，腐蚀操作使用的是 18×18 的结构元素。需要注意的是，实际应用时这些参数需根据图像大小、吊顶情况和风口大小进行调整，对于吊顶复杂的情况，建议增大开操作结构元素的大小，也可以在边缘提取后进行小面积区域的清除，减少吊顶部分的干扰。




图 5.4 风口细分割处理 (a) 粗定位风口红外图像 (b) 可见光风口区域 (c) (b) 的边缘提取结果 (d) 闭操作结果 (e) 开操作结果 (f) 腐蚀结果 (g) 红外图像上腐蚀结果的凸集 (h) 红外图像上腐蚀结果的最小外接矩形 (i) 最小外接矩形包围的红外图像区域 (j) (f) 的凸集图像 (k) 精定位风口红外图像

风口的图像分割方法未涉及到颜色信息，因此，该方法对制冷工况和制热工

况下的风口均适用，图 5.5 列举了两种工况下风口的分割结果。可以发现，对于不同吊顶和不同工况的风口图像，该图像分割算法能较为准确地找出红外图像中的风口区域，确保后续诊断的顺利进行。




图 5.5 不同工况风口分割结果

5.2 风口运行工况的分类

风口是否正常出风往往可以衡量空调系统是否正常运行，如果空调系统开启一段时间后，风口依旧未吹出冷风或热风，则可以判断空调系统出现了故障。风机损坏、风道堵塞和水系统故障等原因都会导致风口出风的异常。因此，识别风口运行工况是判断空调系统是否正常运行的有效途径。

风口的运行工况包括了出冷风、出热风、出常温风和未出风四种情况，出冷风指的是出风温度低于室内温度；出热风指的是出风温度高于室内温度；出常温风指的是出风温度约等于室内温度；未出风指的是风口风量为零。由于红外图像提供的温度信息不足以区分风口出常温风和未出风两种工况，因此，本文只将风口运行工况分为了出冷风、出热风和出常温风或未出风三种类型，采用的分类算法为决策树（Decision Tree, DT）。

5.2.1 输入数据

本文选取风口区域平均温度在温度标尺中所处的位置及风口区域和背景区域的平均温度差值作为决策树的输入。风口区域平均温度 T_{ak} 的定义为：

$$T_{ak} = \frac{T_k}{n_k} \quad (5.1)$$

其中 T_k 为风口区域温度值大于零的像素点温度总和， $^{\circ}\text{C}$ ； n_k 为风口区域温度值大于零的像素点总数。

我们用温标率 P_k 是用来描述风口区域平均温度 T_{ak} 在温度标尺中所处的位置，它的定义为：

$$P_k = \frac{T_{ak} - T_{\min}}{T_{\max} - T_{\min}} \times 100\% \quad (5.2)$$

其中 T_{\min} 为红外图像右侧温度标尺下限， $^{\circ}\text{C}$ ； T_{\max} 为红外图像右侧温度标尺上限， $^{\circ}\text{C}$ 。

观察上式可以发现， P_k 越大，风口区域平均温度越接近温度标尺上限，风口越可能处于制热状态； P_k 越小，风口区域平均温度越接近温度标尺下限，风口越可能处于制冷状态。但是，当风口旁发热的灯具被拍摄到了红外图像中， P_k 就无法正确反映风口的运行工况。更详细地说，当风口处于未出风或出常温风的状态时，如果风口旁发热的灯具被拍摄到了红外图像中，计算出的 P_k 会偏小；当风口处于出热风状态时，如果风口旁发热的灯具被拍摄到了红外图像中，且灯具温度高于风口区域温度，计算出的 P_k 也会偏小。因此，我们还需要比较风口区域和背景区域的平均温度协助进行判断。

与判断电机运行状态部分类似，在计算风口红外图像背景区域的平均温度时，本文将原始图像中左下角的 logo 部分和右侧的温度标尺部分设置为黑色，如图 5.6 所示。因此，风口红外图像背景区域的平均温度 T_{ab} 定义如下：

$$T_{ab} = \frac{T_z - T_k}{n_z - n_k} \quad (5.3)$$

其中， T_z 为处理后风口原始红外图像温度值大于零的像素点温度总和， $^{\circ}\text{C}$ ； n_z 为处理后风口原始红外图像温度值大于零的像素点总数。




图 5.6 风口原始红外图像的处理 (a) 原始红外图像 (b) 处理后的原始红外图像

那么，风口区域和背景区域的平均温度差值为：

$$\Delta T_{kb} = T_{ak} - T_{ab} \quad (5.4)$$

5.2.2 决策树算法

决策树算法是机器学习中常用的分类算法，其结构包含了一个根节点、数个内部节点和数个叶子节点。其中，每个内部节点包含了一个属性测试，每个叶子节点对应决策结果；根节点包含了样本全集，每个内部节点的集合根据属性测试的集合被划分到子节点中。在决策树的生成过程中，假设当前节点的样本均属于同一类别，则将该节点标记为这一类别的叶子节点；假设当前节点的样本在属性取值上完全相同，则标记该节点为叶子节点，其类别为样本数最多的一类；假设当前节点的样本集为空集，则标记该节点为叶子节点，其类别为父节点所含样本最多的类别。除了这三种情况的节点，则需要选择最优划分属性来划分样本，尽量使分支节点的样本集属于同一类别，即最大化分支节点样本纯度。在本文中，我们采用基尼指数来确定最优划分属性。

基尼值是表示样本集合纯度常见的一种指标^[60]，它的定义为：

$$G(D) = 1 - \sum_{k=1}^n p_k^2 \quad (5.5)$$

其中 D 为样本集合， p_k 为样本集合 D 中第 k 类样本所占比例， n 为 D 中的类别总数。

从上式可以看出，基尼值表达的是从样本集合 D 中随机抽取两个样本为不同类别的概率。因此，基尼值越大，样本集合 D 的纯度越低。

假设属性 a 将样本集合 D 分为了 D_1, D_2, \dots, D_V V 个子集合，对于第 i 个集合 D_i 可由式 (5.5) 求得基尼值。对于整个属性 a 来讲，采用基尼指数 (Gini index) 来评价它对样本集 D 的划分结果，其定义为：

$$GI(D, a) = \sum_{i=1}^V \frac{D_i}{D} G(D_i) \quad (5.6)$$

其中 $GI(D, a)$ 为属性 a 对样本集 D 进行划分后的基尼指数。

显然地，最优划分属性即为划分后基尼指数最小的属性。

5.2.3 分类模型

决策树输入数据共有 262 组，包含了 160 组制热风口数据、40 组未出风和

出常温风风口数据和 62 组制冷风口数据，它们的 P_k 和 ΔT_{kb} 值如图 5.7 所示。其中，蓝点代表的是出热风风口，橙点代表的是出常温风或未出风风口，黄点代表的是出冷风风口，横坐标为 P_k ，纵坐标为 ΔT_{kb} 。可以发现，三种类型风口在图中有较为明显的分离，选取 P_k 和 ΔT_{kb} 作为指标来区分这三种风口类型是可靠的，决策树算法也能较好地应用。为了防止决策树出现过拟合现象，本文在模型训练时采用十折交叉验证，10 次训练得到的模型在测试集上的预测结果散点图和混淆矩阵分别为图 5.8 和表 5.2。




图 5.7 262 组风口数据




图 5.8 10 次验证结果散点图

图 5.8 为 10 次预测结果的散点图，其中符号“×”表示的是预测错误的点，每个颜色代表的风口类型与图 5.7 一致。事实上，图 5.7 为 262 组数据的真实值，图 5.8 为 262 组数据的预测值，因此，从图 5.7 中我们可以得到图 5.8 预测错误的点的真实类型。表 5.2 总结了十折交叉验证结果的混淆矩阵，在 10 次验证中，共有 10 组数据被预测错误，整体准确率为 96.2%。观察表 5.2 可以发现，出热风的风口不会被判断为出冷风的风口，但两种类型的风口都有一定的可能性被判断为出常温风或未出风的风口。而对于出常温风或未出风的风口，尽管准确率高达 96.18%，但精确率和召回率较低，分别为 85%和 89.47%。

表 5.2 风口运行工况十折交叉验证结果

预测值	实际值		
	出热风	出常温风或未出风	出冷风
出热风	158	4	0
出常温风或未出风	2	34	2
出冷风	0	2	60

最终，我们选择了 10 次训练得到的最优模型作为本文的分类器，其判断规则如图 5.9 所示。




图 5.9 风口运行工况分类规则

右侧的叶子节点表示当风口的 $P_k \geq 68.89\%$ 时一定为出热风的状态。而对于 $P_k < 68.89\%$ 的风口，首先进行 ΔT_{kb} 的判断， $\Delta T_{kb} < -0.4$ 的风口具有制冷的偏向， $\Delta T_{kb} \geq -0.4$ 的风口则不可能为制冷风口，可能为出常温风或未出风风口，也可能为出热风风口。对于 $\Delta T_{kb} \geq -0.4$ 的风口，热风风口具有比常温风或未出风风口具有更大的 ΔT_{kb} ，因此当 $\Delta T_{kb} \geq 1.81$ 时，风口正在出热风；当 $\Delta T_{kb} < 1.81$ 时，风口出

常温风或未出风。对于 $\Delta T_{kb} < -0.4$ 的风口，冷风风口具有更小的 P_k ，因此以 31.4% 为界限划分冷风风口和出常温风或未出风风口。

将上述分类规则应用到 262 组数据中的分类准确率为 99.24%，分类结果混淆矩阵如表 5.3 所示。除了有两个出常温风或未出风风口被预测为了出冷风风口外，其余风口均预测准确。因此，该分类器能较为准确地将三种工况的风口进行分类。

表 5.3 最优决策树分类结果混淆矩阵

预测值	实际值		
	出热风	出常温风或未出风	出冷风
出热风	160	0	0
出常温风或未出风	0	38	0
出冷风	0	2	62

5.3 风口送风不均匀故障分析

风口送风的不均匀会导致室内温度分布的不均匀，从而影响人员的舒适度，因此，本文在实验室条件下分析了风口送风不均匀故障，建立了基于 SVM 的故障诊断模型，并将其应用于实际楼宇的方形散流器图像数据进行了检验。

5.3.1 图像采集

本文在实验室条件下采集了空调系统制热模式下正常风口和出风不均匀风口的红外图像，实验平台如图 5.10 所示。




图 5.10 风口故障实验平台示意图

实验平台空调系统的冷热源为空气源热泵，末端为风机盘管。1#室和 2#室分别有一个方形散流器，且大小完全相同，其中 1#室中的方形散流器存在故障，

2#室中的方形散流器为正常。实验过程中，我们先将空气源热泵调至制热模式，再打开空气源热泵和室内风机盘管，设定两个房间相同的送风温度，待风口出风温度明显高于室内温度时，进行红外图像的采集。实验采用的红外热像仪为 FLIR E6，详细技术参数请参见第三章表 3.2。

5.3.2 图像分析

图 5.11 列举了实验条件下采集到的送风温度相近的送风不均匀风口和正常风口的红外图像。对比两图可以发现，送风不均匀风口的低温区出现在了风口的右侧，面积较大，温差较大，且形状不规则；而正常风口的低温区出现在风口的正中心，面积较小，温差较小，且形状与中间不出风位置的形状接近。因此，送风不均匀风口具有更分散的温度分布且低温区域位置异常。




图 5.11 风口实验图像 (a) 风口送风不均匀故障红外图像 (b) 正常风口红外图像

为了更全面的了解两种风口的不同，图 5.12 列举了 148 组实验风口图像（79 组故障、69 组正常）风口区域的温度极差 R_k 和变异系数 CV_k 。其中温度极差的定义为：

$$R_k = T_{p9} - T_{p1} \quad (5.7)$$

其中 T_{p9} 为精定位风口红外图像最高温度前 10% 的平均值， T_{p1} 为精定位风口红外图像最高温度后 10% 的平均值。

变异系数 CV_k 的定义为：

$$CV_k = \frac{\sigma_k}{T_{ak}} \quad (5.8)$$

其中 σ_k 为风口区域温度标准差， $^{\circ}\text{C}$ ； T_{ak} 为风口区域平均温度， $^{\circ}\text{C}$ 。

极差和变异系数是常见的数据离散程度评价指标，极差和变异系数越大，数据的离散程度越大。由图 5.12 可以看出，并非所有的故障风口温度离散度都大

于正常风口的温度离散度。事实上，它们还受到了送风温度和室内温度的影响。空调刚开启时，送风温度和室内温度的差值较大，风口区域温度离散程度较高；在室内温度逐渐上升后，送风温度与室内温度差值减小，风口区域温度离散程度也随之降低。为了证明这一关系，我们将原始红外图像最高温度前 10% 的平均值和后 10% 的平均值的差值作为原始红外图像的温度极差 R_0 ，并认为其与送风温度和室内温度的差值成正比。图 5.13 为不同原始红外图像温度极差下正常风口的温度极差和变异系数，可以明显地看出，原始红外图像温度极差较大的风口，其温度极差和变异系数较大，温度离散度较高。因此，在建立故障诊断模型时，我们还考虑了原始红外图像的温度极差。




图 5.12 故障和正常风口的变异系数和极差




图 5.13 不同原始红外图像温度极差下正常风口的温度极差和变异系数

5.3.3 风口送风不均匀故障诊断

根据上述分析的结果，我们认为，在相同送风温度和室内温度条件下，故障风口的温度分布更为分散。因此，我们将原始红外图像温度极差 R_o 、风口区域温度极差 R_k 、标准差 σ_k 、变异系数 CV_k 和四分位距 IQR_k 作为故障诊断模型的输入，并选择 SVM 分类器作为诊断模型，核函数采用的是三次多项式。关于 SVM 原理的详细介绍请参考文献^[61]。

在实验条件下，我们共采集了制热工况下的 309 组风口图像，其中包含了 150 组送风均匀风口图像和 159 组送风不均匀风口图像，在对每组风口图像进行图像分割后计算得到相应的特征值，形成了最终的数据集。为了验证该算法的有效性，本文将 309 组数据分为 231 组训练数据（包括 111 组正常和 120 组故障数据）和 78 组测试数据（包括 39 组正常和 39 组故障数据），在模型训练时采用十折交叉验证，得到的最终结果如表 5.4 和表 5.5 所示，最后，使用测试数据检验最优模型诊断性能。

表 5.4 风口实验训练数据诊断结果

预测值	实际值	
	正常	送风不均匀故障
正常	111	1
送风不均匀故障	0	119

表 5.5 风口实验训练数据诊断结果评价指标

类别	准确率 (%)	精确率 (%)	召回率 (%)	F1 (%)
正常	99.57	100	99.11	99.55
送风不均匀故障	99.57	99.17	100	99.58
平均值	99.57	99.59	99.56	99.57

由十折交叉验证的结果可以看出，在 231 组风口图像数据中，仅有 1 组送风不均匀故障数据被误诊为正常数据，其余数据均诊断正确。因此，该算法在训练数据上均有较高的准确率。图 5.14 为训练得到的最优模型在 78 组测试数据上的诊断结果，其中风口类型 1 代表的是故障风口，风口类型 2 代表的是正常风口，正方形代表的是风口实际值，叉形为风口诊断值。可以看出，该诊断模型在测试集上的诊断准确率为 100%。




图 5.14 送风不均匀故障实验测试数据诊断结果

5.3.4 实际数据的检验

为了进一步检验诊断模型的通用性,本次研究还采集了上海市新江湾文化中心的风口图像作为实际数据对诊断模型进行了检验。由于条件的限制,在实际楼宇中,我们并未获得存在送风不均匀故障的风口图像,因此实际数据均为风口类型 2,共计 81 组。与实验数据一样,在对实际风口图像进行图像分割后,我们提取了诊断模型所需的 5 项特征数据,获得了 81 组实际数据集。

图 5.15 为 5.3.3 节得到的诊断模型对实际数据的诊断结果,可以明显地看出,81 组数据均诊断正确。因此,该诊断模型在实际数据集上的诊断准确率为 100%,具有一定的通用性和应用价值。




图 5.15 风口实际数据诊断结果

5.4 本章小结

本章以方形散流器为研究对象,开发了基于 R-CNN 的图像分割方法,提出了采用决策树的运行工况分类算法,并在实验室条件下分析了送风不均匀故障,建立了基于 SVM 的故障诊断模型,主要得出以下结论:

(1) 本章开发的风口图像分割方法结合了 R-CNN 算法、边缘提取算法和形态学处理方法,对制热、制冷和常温风口均适用,具有较强的通用性,但在实际应用中应视具体情况微调相关参数。

(2) 本章基于红外图像, 提出了采用决策树的风口运行工况分类算法, 该算法将温标率 P_k 以及风口区域和背景区域的平均温度差值 ΔT_{kb} 作为输入, 可以较为准确地判断出风口出风状态, 具有实际应用价值。

(3) 本章在实验室条件下采集了制热工况下送风不均匀风口图像和正常风口图像, 并进行了相关分析。分析结果表明, 在相同送风温度和室内温度条件下, 故障风口的温度分布比正常风口更为分散; 对于同种风口类型, 风口区域的温度离散程度受原始红外图像温度极值的影响。因此, 本文将原始红外图像温度极差 R_o 、风口区域温度极差 R_k 、标准差 σ_k 、变异系数 CV_k 和四分位距 IQR_k 作为输入, 建立了基于 SVM 的风口送风不均匀故障诊断模型。经实验数据和实际数据的检验, 该诊断模型具有较高的准确度和一定的通用性。

第6章 总结和展望

6.1 总结

空调系统的故障诊断是延长设备使用寿命、维持室内热舒适度和降低能耗的有效途径。然而，目前的故障诊断方法大多基于空调系统运行参数，而这些数据在实际中往往难以获得。除此之外，传统的故障诊断方法需要在建筑中安装大量的传感器，实际应用时实施困难且成本昂贵。因此，本文以空调系统热水管道、电机和方形散流器作为研究对象，提出了基于图像的故障诊断方法，一方面解决了建筑空调系统故障诊断面临的数据难题；另一方面，方法所需传感器种类单一，数量较少，独立于现有自控系统，实际应用时成本较低且部署简单。

总的来说，本文的主要内容有：

(1) 对于空调系统热水管道、电机、方形散流器三种设备类型，本文提出了基于 AlexNet 卷积神经网络的设备图像分类模型，模型输入为设备可见光图像，输出为设备类型。本文使用了裁剪、旋转、翻转等数据增强方式来扩大数据集，并将图像缩放成 227×227 的大小，以满足 AlexNet 网络的输入要求，最后，采用迁移学习的方式对 AlexNet 网络结构进行微调，进行训练得到最终的分类模型。

(2) 本文针对热水管道保温层破损、脱落和漏水故障，开发了相应的故障诊断算法，算法包括了水管的图像分割、特征分析和故障诊断，并在实验数据和实际数据中得到了验证。其中，水管图像分割我们采用了阈值处理和形态学处理方法，可以较为准确地获取红外图像中的水管区域，但水管周围的灯管及其他发热体对算法的准确度有略微影响，在拍照时应尽量避免。特征分析包括了温度分析、管径分析和缺陷分析三个部分，在温度分析中，我们利用 3σ 准则判断水管区域是否存在温度异常值，如果水管区域最高温度如果高于平均值 4°C 以上，则认为较为严重的保温层脱落故障或漏水故障；在管径分析中，我们分析水管管径变化是否与保温层水管一致；在缺陷分析中，我们采用了边缘提取算法分割出水管保温层破损区域。故障诊断则是根据特征分析的结果，输出最终的管道类型。最后，在实验数据和实际楼宇数据中的检验结果表明，该算法的诊断准确率分别为 97.59% 和 92.74%，具有良好的鲁棒性。

由于缺少冷水管道的数据，本文的管道算法只针对于热水管道，但其实对于冷水管道也是适用的，只需要做出相应的调整。详细地，在图像分割中，应将“提取红色分量”改为“提取蓝色分量”；在缺陷分析时，应该将“红色分量图像”作为边缘提取目标；进行温度判断时，应判断温度是否低于某值而非是否高于某

值。

(3) 在电机故障诊断算法开发部分，我们首先介绍了电机的常见故障并总结了引起电机过热的四种因素：自身因素、电源因素、负载因素和环境因素，说明了监测电机温度的重要性。其次，我们开发了基于 R-CNN 算法的电机图像分割方法，训练得到的电机 R-CNN 检测器用于识别出可见光图像中电机的具体位置，然后将该位置信息应用于一一对应的红外图像中进行分割，如果电机处于关机状态，不进行故障诊断；如果电机处于开机状态，则利用阈值分割和形态学图像处理实现红外图像电机的精确定位。最后，我们在实验条件下模拟了单相电机的通风不良故障，并对其进行了动态分析和静态分析，由于动态分析耗时长，实际应用时更建议使用静态分析。在静态分析中，我们提出了温度分析和高温区域分析方法，其中，高温区域分析可在电机未达到热稳定状态时进行故障的诊断。因此，在故障诊断时，我们将高温区域面积占比和更高温区域面积占比作为输入，采用 K 近邻算法识别电机的通风不良故障，当 K=3 时，算法在实验数据中十折交叉验证的准确率为 99%，能较为准确地判断实验电机的运行状态。

(4) 本文以方形散流器为研究目标，提出了送风不均匀故障诊断算法。对于风口的图像分割，考虑到天花板纹路的多样性，本文也采用了 R-CNN 算法实现风口的大致定位，再利用边缘提取算法和形态学处理方法完成精确的定位。由于该图像分割算法未涉及到图像的颜色信息，对于任何工况的风口都能实现较好的分割。风口的运行状态往往反映了空调系统是否正常运行，因此，本文开发了基于决策树的风口运行工况分类算法，可以实现风口出热风、出冷风和出常温风或未出风三种工况的分类，算法的输入为温标率 P_k 以及风口区域和背景区域的平均温度差值 ΔT_{kb} 。结果表明，十折交叉验证得到的最优模型可将 99.24% 的风口数据准确分类。最后，本文在实验条件下分析了制热风口送风不均匀故障，认为在相同送风温度和室内温度条件下，故障风口的温度分布比正常风口更为分散；对于同种风口类型，原始红外图像的温度极差 R_o 对风口温度的离散程度存在影响。因此，本文选取原始红外图像温度极差 R_o 、风口区域温度极差 R_k 、标准差 σ_k 、变异系数 CV_k 和四分位距 IQR_k 作为特征值，建立了基于 SVM 的送风不均匀故障诊断模型。经实验数据和实际数据的检验，该诊断模型具有较高的准确性和一定的通用性。

6.2 主要贡献

根据上述的研究结果，本文的主要贡献有：

(1) 基于 AlexNet 卷积神经网络，本文建立了空调系统水管道、电机和方

形散流器三种设备图像的分类模型。

(2) 针对热水管道保温层破损、脱落和漏水故障, 本文开发了适用于热水管道的图像分割方法, 并提出了结合温度分析、管径分析和缺陷分析的故障诊断算法。实验和实际数据的验证结果表明, 该算法具有良好的鲁棒性。

(3) 本文将 R-CNN 目标检测算法用于电机的图像分割, 并结合了阈值处理和形态学处理方法。其次, 针对单相电机通风不良故障, 本文将高温区域面积占比和更高温区域面积占比作为输入, 开发了使用 K 近邻算法的故障诊断方法。

(4) 本文以方形散流器作为研究对象, 结合 R-CNN 算法、边缘检测算法和形态学处理方法, 开发了相应的图像分割算法, 该算法对任何工况的风口均适用。其次, 本文建立了基于决策树的风口运行工况分类模型, 可实现出热风、出冷风和出常温风或未出风三种工况的判别。最后, 本文提出了基于 SVM 的风口送风不均匀故障诊断模型。

6.3 展望

尽管本文在基于图像的空调系统故障诊断算法研究中取得到了一定的进展, 但依旧存在一些不足, 还需要得到进一步的改进:

(1) 三种设备的分类模型具有一定的局限性, 这也是图像分类的局限性, 即无法同时识别出图像中存在的多种物体。例如, 水泵电机与水管道往往会出现在一张图像中, 而分类模型会将其判别为电机类型。因此, 本文开发的故障诊断算法一次只能诊断图像中的一种设备, 进一步的研究可以围绕如何分离出图像中的不同设备展开。

(2) 尽管热水管道故障诊断算法可以较为准确地识别出空调系统热水管道的保温层和漏水故障, 但还不能评估其严重程度, 进一步的研究可以对此进行展开。

(3) 本文尚未解决电机红外诊断的通用性问题, 还需要更多的研究对此进行展开。

(4) 本文在进行风口故障诊断研究时, 只考虑了方形散流器类型。在风口送风不均匀故障诊断中, 也只考虑了制热工况。为了使算法能得到更为广泛地应用, 进一步的研究可以将更多的风口类型和工况考虑进去, 完善这部分的算法。

致谢

不知不觉，我的研究生生涯就要结束了，内心有些喜悦也有些伤感。喜悦来自于自己的学术成果和即将面临的新生活，而伤感则是对这个地方和 A434 课题组大家庭的不舍。

能顺利完成这篇硕士论文，要感谢的人有很多。首先要感谢的是我的导师——许鹏教授。早在本科阶段，我就被许老师帅气的面容和儒雅的气质吸引到了，因此，在选研究生导师的时候，我毫不犹豫地选择了许老师，也特别感谢许老师接受了我。一直以来，特别感谢许老师对我的包容和指导，在我懈怠的时候给予必要的监督，在我遇到困难的时候为我出谋划策，在我没能完成任务时也温柔善待给予包容。

非常感谢 A434 课题组大家庭给予了我家人般的温暖。感谢沙华晶师姐给我做酱，给我带兔头以及生活上的很多帮助；感谢陈永保师兄带我打球，陪我过生日；感谢褚祯祯师姐的陪伴；感谢吴云涛师兄对我学术上的建议；感谢冯帆师兄对我的关爱以及送我的生日蛋糕；感谢杨经理带我上王者还不忘督促我的学习；感谢我的五年室友顾洁帆对我生活上的包容和照顾；感谢陈智博师弟帮我安装软件还每天提供笑料；感谢李泓名师弟帮我解决控制相机拍照的难题；感谢戴明坤师弟总是增加游戏趣味；感谢王鸿鑫师弟帮我处理报销事务；特别要感谢的是我的师弟兼男友吉吉，感谢他一直以来给予我的温柔，感谢他帮我做实验，在我最困难的时候陪伴在我身边，为我加油打气。

同时，我还要感谢挚友潘媛和杨光，感谢她们在学习和生活上给予我妹妹般的关爱；感谢学长段鹏飞和刘志渊带我打升级和带我吃好吃的；感谢杜博文学长带我玩王者荣耀；感谢我的本科室友孙静姝在我迷茫的时候收留我，还为我做了很多好吃的饭菜；感谢我的好朋友段段在我失恋难过时对我的安慰和支持；感谢潘老师课题组可爱的李诗尧师妹每年祝我生日快乐；感谢潘老师课题组余昭师妹的督促和陪伴；感谢曹昌盛老师在我搭建实验平台时对我的帮助；感谢鑫如意阿姨和叔叔辛苦准备的美食；感谢延华公司对我这篇论文的支持。

除此之外，由衷地感谢我的父母，感谢他们的信任和理解，感谢他们一直以我为骄傲，在背后默默地支持我并给予我无条件的包容。

最后，感谢所有在我成长路途上给予过我帮助的人，谢谢你们的温柔。

2019 年 6 月

参考文献

- [1] Energy Information Administration, International Energy Statistics, 2017.
- [2] United States Department of Energy, Building Energy Data Book 2011, 2011.
- [3] 中国建筑节能协会. 中国建筑能耗研究报告. 2017.
- [4] 清华大学建筑节能研究中心. 中国建筑节能年度发展研究报告 2010. 北京: 中国建筑工业出版社, 2010.
- [5] Wang S, Zhou Q, Xiao F. A system-level fault detection and diagnosis strategy for HVAC systems involving sensor faults. *Energy & Buildings*, 2010, 42(4):477–490.
- [6] Wu S, Sun JQ. A top-down strategy with temporal and spatial partition for fault detection and diagnosis of building HVAC systems. *Energy & Buildings*, 2011, 43(9):2134–2139.
- [7] 李曹县, 魏鸿榕. 谈 BAS 系统在我国现阶段应用中存在的一些问题. *福建工程学院学报*, 2003,1(4):45-47.
- [8] So, Albert T.P., Chan, W.L., Chow, T.T. Computer-vision-based HVAC control system (1995) *ASHRAE Transactions*, 101 (Pt 2), pp. 661-678.
- [9] Liu D, Du Y. Vision-based Indoor Occupants Detection System for Intelligent Buildings. *IEEE International Conference on Imaging Systems and Techniques*,2012:273-278
- [10] Junqi Wang, Norman Chung Fai Tse, Tin Yan Poon and John Yau Chung Chan. A Practical Multi-Sensor Cooling Demand Estimation Approach Based on Visual, Indoor and Outdoor Information Sensing. *Sensors*,2018, 18(11:3591-3615.
- [11] Shuo Liu, LeYin, Weng Khuen Ho, Keck Voon Ling, Stefano Schiavon. A tracking cooling fan using geofence and camera-based indoor localization. *Building and Environment*,2017,114:36-44.
- [12] Yongxiong Wang,JianboSu. Automated defect and contaminant inspection of HVAC duct. *Automation in Construction*,2014,41:15-24.
- [13] M.Z.M. Salleh, N.K.A.M. Rashid, Y.M. Mustafah ANFIS-based navigation for HVAC service robot with image processing *Materials Science and Engineering*, vol. 53, IOP Conference Series, IOP Publishing (2013), p. 012087.
- [14] Wooyoung Jung, Farrokh Jazizadeh. Vision-based thermal comfort quantification for HVAC control. *Building and Environment*, 2018, 142:513-523.
- [15] Farrokh Jazizadeh, Wooyoung Jung. Personalized thermal comfort inference using RGB video images for distributed HVAC control. *Applied Energy*,2018,220:829-841.
- [16] Andrei Claudiu Cosma,Rahul Simha. Thermal comfort modeling in transient conditions using real-time local body temperature extraction with a thermographic camera. *Building and Environment*,2018,143:36-47.
- [17] Da Li,Carol C.Menassa, Vineet R.Kamat. Non-intrusive interpretation of human thermal comfort through analysis of facial infrared thermography. *Energy and Buildings*,2018,176:246-261.
- [18] Youngjib Ham, Mani Golparvar-Fard. An automated vision-based method for rapid 3D energy performance modeling of existing buildings using thermal and digital imagery. *Advanced Engineering Informatics*,2013,27(3):395-409.
- [19] 央宜禾, 岳敏, 周维真. 红外系统 [M] .北京国防工业出版社, 1995.

- [20] 邢素霞.红外热成像与信号处理 [M].北京国防工业出版社, 2011
- [21] 牟新刚, 周晓. 红外探测器成像与信息处理[M].重庆:重庆大学出版社,2016
- [22] Flir. Flir 红外热像仪原理及应用 [OL]. <https://wenku.baidu.com/view/c0a567761fd9ad51f01dc281e53a580216fc50f2.html?from=search>, 2016.10.11/2019.4.15.
- [23] C.A. Balaras, A.A. Argiriou. Infrared thermography for building diagnostics. *Energy & Buildings*, 2002, 34(2):171–183.
- [24] Wang Yongxiong, Su Jianbo. A hierarchical image segmentation method. *Proceeding of the 31st Chinese Control Conference(2012)*,pp. 25-27,July.2012
- [25] Chunli Fan, Fengrui Sun,Li Yang. Investigation on nondestructive evaluation of pipelines using infrared thermography. *2005 Joint 30th International Conference on Infrared and Millimeter Waves and 13th International Conference on Terahertz Electronics*,vol.2,Sept.2005,pp.339-340.
- [26] Guozhong Wu, Fenfen Song, Dong Li. Infrared Temperature Measurement and Simulation of Temperature Field on Buried Pipeline Leakage. *International Conference on Pipelines and Trenchless Technology*,2009:203-209.
- [27] Mohammedhusen H Manekiya , P. Arulmozhivarman. Leakage detection and estimation using IR thermography. *2016 International Conference on Communication and Signal Processing(ICCSP)*, pp. 6-8, April ,2016.
- [28] Bubaker Shakmak, Amin Al-Habaibeh.Detection of water leakage in buried pipes using infrared technology; A comparative study of using high and low resolution infrared cameras for evaluating distant remote detection. *2015 IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT)*,pp.1-7, Nov. 2015.
- [29] Peter M. Bach, Jayantha K. Kodikara, "Reliability of infrared thermography in detecting leaks in buried water reticulation pipes", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 9, pp. 4210-4224, Sep. 2017.
- [30] Ahmed Atef, Tarek Zayed, Alaa Hawari, Mohammad Khader, Osama Moselhi. Multi-tier method using infrared photography and GPR to detect and locate water leaks. *Automation in Construction*, 2016, 61:162-170.
- [31] 赵玉娇. 用红外热像仪检测供热直埋管道泄漏的技术研究[D].哈尔滨工业大学, 2011.
- [32] 张强, 郭桐, 张玄. 基于红外热像的供热管道内壁腐蚀诊断及预测研究[J]. *腐蚀科学与防护技术*, 2017, 29(04):462-468.
- [33] 吴晋湘, 王彦道, 赵涛等. 基于土壤温湿度的埋地供热管道泄漏检测方法[J]. *暖通空调*,2018,48 (09) ,58-62.
- [34] M.Eftekhari, M.Moallem, S.Sadri, Min-Fu Hsieh.A novel indicator of stator winding inter-turn fault in induction motor using infrared thermal imaging. *Infrared Physical& Technology*,2013,61:330-336.
- [35] Gurmeet Singh, T.Ch.Anil Kumar, V.N.A.Naikan. Induction motor inter turn fault detection using infrared thermographic analysis. *Infrared Physical& Technology*,2016,77:277-282.
- [36] Adam Glowacz, Zygryd Glowacz. Diagnostics of stator faults of the single-phase induction motor using thermal images, MoASoS and selected classifier. *Measurement*,2016,93:86-93.
- [37] Mohd Shawal Jadin, Soib Taib. Recent progress in diagnosing the reliability of electrical equipment by using infrared thermography. *Infrared Physical& Technology*,2012,55(4):236-245.
- [38] A.G. Garcia-Ramirez, L.A. Morales-Hernandez, R.A. Osornio-Rios, A. Garcia Perez,

- R.J.Romero-Troncoso. Thermographic technique as a complement for MCSA in induction motor fault detection. 2014 International Conference on Electrical Machines (ICEM) (2014), pp. 1940-1945.
- [39] Gurmeet Singh, V.N.A.Naikan. Infrared thermography based diagnosis of inter-turn fault and cooling system failure in three phase induction motor. *Infrared Physical& Technology*,2017,87:134-138.
- [40] Adam Glowacz, Zygfrzyd Glowacz. Diagnosis of the three-phase induction motor using thermal imaging. *Infrared Physical& Technology*,2017,81:7-16.
- [41] 杨宝东, 赵军. 电机表面过热故障的红外成像监测诊断[J]. 机电工程技术, 2014(1):50-52.
- [42] 倪紫峰, 袁双玲. 基于高分辨率热成像技术的定子绕组故障诊断[J]. 技术与市场, 2018, 25(5): 92-92.
- [43] 孙斌, 王艳武, 杨立. 基于红外测温的异步电机轴承故障诊断[J]. 电机与控制学报, 2012, 16(1):50-55.
- [44] 张强, 郭桐, 刘忆等. 基于红外热像技术的电机定子线圈腐蚀诊断研究[J]. 腐蚀科学与防护技术, 2017(06):94-100.
- [45] 郑小荣, 李红江, 高海林. 舰艇中频发电机组的故障诊断[J]. 船电技术, 2016, 36(8):48-51.
- [46] 韦先霜. 电机红外图像检测诊断系统的研究[D]. 华中科技大学, 2007
- [47] 王霄菲. 机电设备红外监测系统软件开发[D]. 西安科技大学, 2014.
- [48] Ying Sun, Theodore F.Smith. Air flow characteristics of a room with square cone diffusers. *Building and Environment*, 2005,40(5):589-600.
- [49] S. Svai'c, I. Boras, and N. Ferdekji. Implementation of Thermography for Determination of Air Jet Geometry in HVAC Systems. In *Proceeding international conference on Quantitative Infrared Thermography (QIRT)*, July 27-30 2010.
- [50] M. Cehlin, B. Moshfegh, M. Sandberg. Measurements of air temperatures close to a low-velocity diffuser in displacement ventilation using an infrared camera. *Energy and Buildings*, 34 (7) (2002), pp. 687-698
- [51] 刘昕.CNN 近期进展与实用技巧[EB/OL].2016-05-03/2019-03-27.
- [52] A. Krizhevsky, I. Sutskever, and G. Hinton. Imagenet classification with deep convolutional neural networks. In *NIPS*, 2012.
- [53] Rafael C. Gonzale, Richard E.woods. 数字图像处理（第三版）. 北京：电子工业出版社, 2011.
- [54] Wikimedia Commons. File: Comparison of 1D and 2D interpolation.svg [OL]. http://commons.wikimedia.org/wiki/File:Comparison_of_1D_and_2D_interpolation.svg, 2018.8.14/2019.3.31.
- [55] Peter Kovesi. MATLAB and Octave Functions for Computer Vision and Image Processing [CP/OL]. (2013-05) [2019-03-15]. <https://www.peterkovesi.com/matlabfns/index.html>
- [56] Khadim Moin Siddiqui1, Kuldeep Sahay, V.K.Giri. Health Monitoring and Fault Diagnosis in Induction Motor- A Review. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*,2014,1(3):6549-6565.
- [57] O.V. Thorsen, M. DalvaA survey of faults on induction motors in offshore oil industry, petrochemical industry, gas terminals, and oil refineries *IEEE Trans. Ind. Appl.*, 31 (5)(1995), pp.

1186-1196

[58] 杨宝东,赵军. 电机表面过热故障的红外成像监测诊断[J].机电工程技术,2014,43(01):50-52.

[59] Jasper R. R. Uijlings, Koen E. A. van de Sande, Theo Gevers, et al. Selective Search for Object Recognition. *International Journal of Computer Vision*, 2013,104(2):154-171.

[60] 周志华.机器学习[M].北京:清华大学出版社,2016.

[61] 邓乃扬, 田英杰. 支持向量机—理论、算法与拓展[M]. 北京: 科学出版社,2009.

个人简历、在读期间发表的学术论文与研究成果

个人简历:

罗为，女，1995年3月生。

2016年7月毕业于同济大学 建筑环境与设备工程专业 获学士学位。

2016年9月入同济大学读硕士研究生

待发表论文:

[1] 罗为，许鹏，李为林等. 单体建筑需求响应研究. 建筑节能（已接收）