

# 团 体 标 准

T/CI 048-2023

## 地铁列车外观智能故障诊断与运 维管理技术及应用指南

Intelligent fault diagnosis and operation maintenance management  
technology and application guide for Subway train appearance

2023-4-6 发布

2023-4-6 实施

中国国际科技促进会 发布

## 目次

前言 .....	II
引言 .....	III
1 范围 .....	1
2 规范性引用文件 .....	1
3 术语和定义 .....	1
3.1 故障特征 Fault Feature .....	1
3.2 图像配准 Image Registration .....	1
3.3 目标检测 Object Detection .....	1
3.4 深度学习 Deep Learning .....	1
3.5 智能运维 Intelligent Operation and Maintenance .....	2
4 总体设计 .....	2
4.1 基本原则 .....	2
4.2 地铁列车外观的健康监测诊断与运维管理总体思路介绍 .....	2
4.3 地铁列车外观关键零部件及其故障模式 .....	4
4.3.1 地铁列车外观关键零部件及其故障模式概述 .....	4
4.3.2 常规故障模式分析 .....	4
4.3.3 磨损消耗类故障模式分析 .....	6
4.4 地铁列车外观故障检测的性能指标 .....	6
4.4.1 机器人性能与导航性能推荐指标 .....	6
4.4.2 常规典型类故障检测算法性能指标 .....	7
4.4.3 磨损消耗类故障检测算法性能指标 .....	8
4.5 地铁列车外观图像数据采集技术概述 .....	8
4.5.1 外观线阵图像采集 .....	9
4.5.2 外观面阵图像采集 .....	10
4.6 地铁列车外观图像预处理技术概述 .....	11
4.6.1 二维图像预处理算法 .....	11
4.6.2 三维点云数据预处理算法 .....	15
4.7 基于目标检测的地铁列车外观关键零部件定位技术 .....	18
4.8 地铁列车外观故障智能检测技术 .....	20
4.8.1 地铁列车外观关键零部件异常检测技术 .....	20
4.8.2 地铁列车外观关键零部件测量技术 .....	22

## 前 言

本文件按照 GB/TL 1-2020《标准化工作导则第 1 部分：标准化文件的结构和起草规则》的规定起草；

某些内容可能涉及专利，本文件的发布机构不承担识别这些专利的责任。

本文件由西南交通大学提出。

本文件由中国国际科技促进会归口。

本文件起草单位：西南交通大学、成都运达科技股份有限公司、杭州申昊科技股份有限公司、广州运达智能科技有限公司、北京交通大学、深圳市市政设计研究院有限公司、广州地铁集团有限公司、安徽大学、北京市地铁运营有限公司、陕西铁路物流集团有限公司、合肥工业大学、欧亚高科数字技术有限公司、成都轨道产业投资集团有限公司、成都卓安卓越新能源科技有限公司、四川顶峰时代智能科技有限公司、城市轨道交通系统安全与运维保障国家工程研究中心、轨道交通电气化与自动化工程技术研究中心、先进能源牵引与综合节能铁路行业重点实验室、国科联盟(北京)国际信息科学研究院。

本文件主要起草人：黄德青、马磊、秦娜、王青元、黄大荣、王洪伟、孙永奎、许水清、赵舵、靳守杰、胡远江、马珺杰、程军强、吴海腾、孙鹏飞、王长春、刘安、陈刚、刘正一、王磊、王顺、李洁、苏钊颐、蔡亮成、沈楷、陈勇、戈珊珊。

## 引言

为拓展地铁列车外观智能故障诊断与运维管理技术的应用，以及进一步深化各交叉领域的研究，同时为了各个群体更为高效的协作，本文件制定了地铁列车外观智能故障诊断与运维管理技术及应用通用指南。

本文件针对地铁列车外观故障检测，具体主要针对各种外观重要零部件的缺失类、鼓包类、异物类、松动类、裂纹类、磨损类等故障。

本文件为首次发布，今后将根据地铁列车外观智能故障诊断与运维管理技术要求及发展情况适时修订。

本文件由中国国际科技促进会标准化工作委员会负责管理。由西南交通大学负责具体技术指标的解释工作。若发现问题或有修改意见请及时联系西南交通大学，以便今后的修改与补充。联系方式：028-66367782。邮编：611756。

# 地铁列车外观智能故障诊断与运维

## 管理技术及应用指南

### 1 范围

本文件提供了在地铁列车外观智能故障诊断与运维管理技术及应用术语和定义、典型故障模式分析、性能指标、数据采集技术、图像预处理技术、零部件定位技术、外观故障智能检测技术等相关内容的指南。

本文件适用于在地铁列车外观故障检测的全生命周期健康检测与诊断研究、设计、技术路线，可作为地铁智能运维设计与研究的技术依据。

### 2 规范性引用文件

本文件没有规范性引用文件。

### 3 术语和定义

下列术语和定义适用于本文件。

#### 3.1

##### 故障特征 Fault Feature

指用检测程序对一个有故障的部件进行检测时所得到的图像特征。

#### 3.2

##### 图像配准 Image Registration

指将不同时间、不同传感器（成像设备）或不同条件下（天候、照度、摄像位置和角度等）获取的两幅或多幅图像进行匹配、叠加的过程。

#### 3.3

##### 目标检测 Object Detection

指定位图像中所有感兴趣的目标，并确定其类别。

#### 3.4

##### 深度学习 Deep Learning

指通过训练大量的样本学习数据的内在规律和表示层次，让机器能够像人一样具有分析学习能力。

### 3.5

#### 智能运维 Intelligent Operation and Maintenance

指将人工智能或其他高级分析技术应用于数据分析中，以建立关联并实时提供规范性和预测性答案，能够更快地解决问题，并帮助完全避免异常事件。

## 4 总体设计

### 4.1 基本原则

- (1) 对标国家重大需求。以国家需求为研究命题导向，以研究成果落地为研究目标。
- (2) 紧跟学科和工程前沿。以前沿科学技术驱动智能制造的发展创新。
- (3) 密切联系实际地铁列车检修场景，尤其是对地铁列车运行中会容易产生重要故障，会导致事故发生，造成人员伤亡、环境损害、经济损失等，以安全性和可靠性为设计基础。
- (4) 项目组应以设备检修过程中及时准确的发现异常、诊断故障、避免事故、确保安全为目标。

### 4.2 地铁列车外观的健康监测诊断与运维管理总体思路介绍

随着近年来我国城市轨道交通的发展建设，轨道交通相关产业也随之强大起来，当前我国城市轨道交通发展历程处在突飞猛进阶段。“十三五”时期，我国城市轨道交通的运营、建设、规划线路规模和投资实现跨越式增长，城市轨道交通行业持续保持快速发展趋势。随着轨道交通的不断发展，地铁列车在频繁运行过程中保持良好状态成为了保障整个轨道交通系统安全运行的关键。一旦地铁列车发生故障，将会导致整个城市轨道交通系统停滞，甚至引发严重的事故灾难，威胁生命安全，造成巨大的经济损失。因此做好地铁巡检工作是保证地铁正常运营的重要前提，地铁列车的故障巡检是保障城市轨道交通系统安全运行的必要方式。

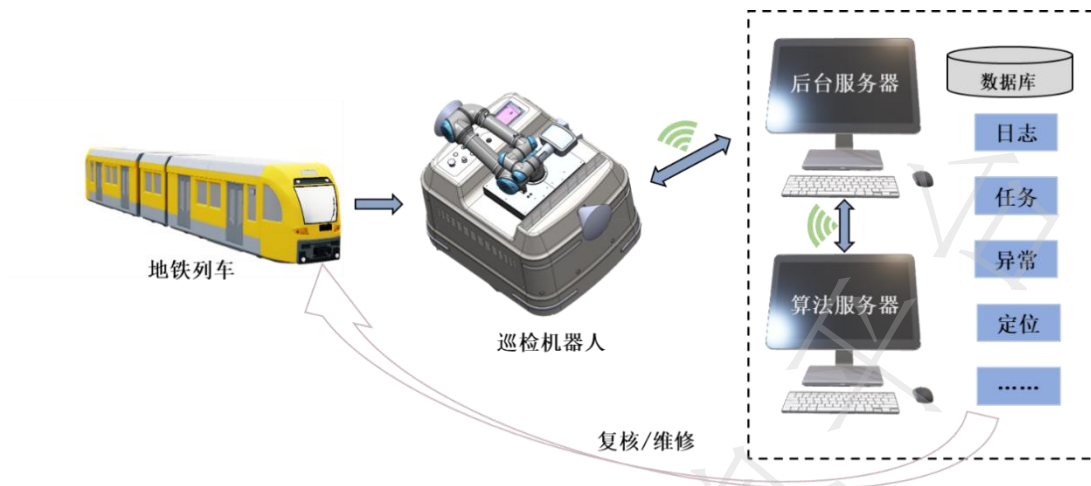


图 4-1 智能巡检机器人系统

传统的人工方式主要通过“一看、二摸、三听、四测量”对关键零部件进行外观检查及功能测试，判断列车的健康状况，及时对状态不佳的零部件进行维修或者更换等。人工巡检存在隐患多、效率低下，工作强度大，信息化程度差等问题。在一个信息化的时代的发展背景下，为了有效解决了现有人工检测所存在的问题，应用机器人、计算机视觉、人工智能等先进技术研发更高效可行的地铁巡检系统是一个必然发展趋势。所以目前地铁列车的智能检测主要依赖于巡检机器人，智能巡检机器人系统如图 4-1 所示，包含以下几个部分：1、机器人本体：机器人本体是巡检系统的核心组件，通常包括移动平台、传感器、控制系统等。移动平台使机器人能够在地铁环境中自由行走；传感器则负责检测各种维护信息，如轨道状况、供电系统、通信系统、信号系统等；机器人的控制系统负责处理来自传感器的数据，根据预设的算法和规则，对机器人的行为进行控制。2、导航与定位模块：在地铁环境中进行巡检，机器人需要能够准确地确定自身位置并规划行走路线。导航与定位模块通常利用激光雷达、惯性导航、视觉 SLAM 等技术，实现精确的自主导航和定位，完成路径规划、障碍物避让、自主充电等功能。3、地铁列车外观的健康监测诊断与运维管理技术平台：为了便于监控和管理巡检机器人对地铁外观的智能检测，需要一个集成与管理平台。该平台通过使用点阵和面阵摄像机、激光扫描仪、红外热像仪等设备，对列车外观进行全方位、多角度的检测，捕捉列车外观的变形、裂纹、腐蚀、异物等问题。针对拍摄的原始数据进行处理和分析，数据处理技术包括图像处理、信号处理、数据融合等，以提取有用信息并确定列车外观的健康状况。根据处理后的数据，运用特征比对、机器学习、深度学习等技术对列车外观状况进行诊断，诊断结果可用于预警，当发现潜在问题时及时通知运维人员进行处理。最终将以上各模块集成建立一个集成的运维管理平台，实现对列

车外观健康状况的实时监控、数据分析、故障诊断、预警处理等功能。该平台可帮助运维人员制定维修计划、调度资源、追踪维修过程，提高运维效率。地铁列车外观的健康监测诊断与运维管理技术是地铁巡检系统的重要模块，是提高城市轨道交通系统高效运行的关键途径和重点难点问题。

地铁列车外观的健康监测诊断与运维管理技术研究，应从地铁列车外观的二维图像和点云图像出发，通过图像的预处理技术、关键零部件定位技术、在线故障诊断与健康维护决策等关键技术，实现地铁列车外观的自主健康管理，在以上关键技术攻关成果的基础上，研发健康检测与诊断系统，最后，为贯彻产研相结合的理念，将该健康检测与诊断系统应用于数个城市轨道交通装备系统中，以应用实践反馈作为改进方向，形成良性循环。

值得说明的是，本文件所提供的是一种面向地铁列车外观故障的通用技术架构，所涵盖的应用对象为典型对象，包括如图 4-2 所示的典型故障或类似的对象。

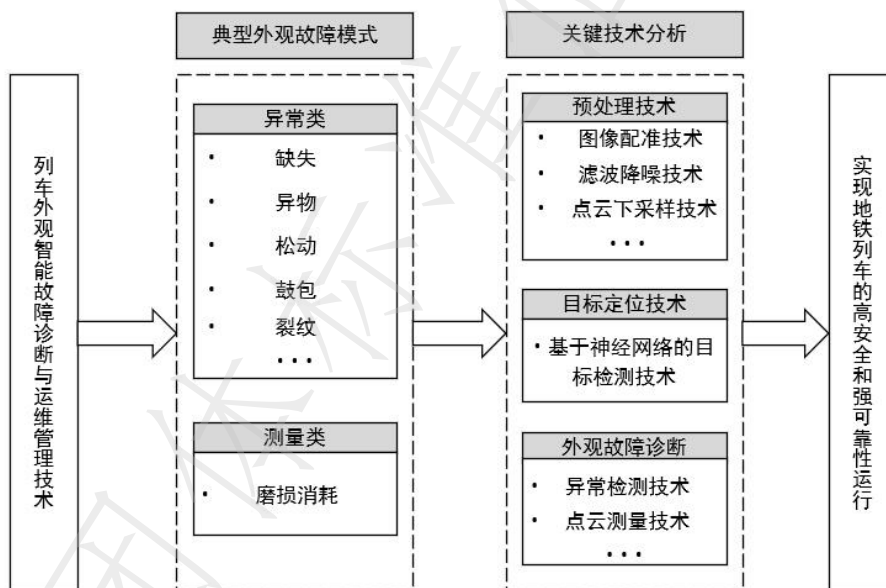


图 4-2 总体路线图

### 4.3 地铁列车外观关键零部件及其故障模式

#### 4.3.1 地铁列车外观关键零部件及其故障模式概述

根据地铁列车关键零部件智能故障诊断与运维管理所面对的部件故障模式，可以将故障种类划分为简单目视即可判断异常的常规故障模式和需要测量才能够判断是否异常的磨损消耗类故障模式。

#### 4.3.2 常规故障模式分析

常规典型故障类型主要包括缺失类（Missing Class）、鼓包类（Bulge Class）、异物类

(Foreign Class)、松动类(Losses Class)以及裂纹类(Crack Class)。在智能检修中各个项点的编码格式通常采用“所属故障类型\_项点名称\_项点编号”进行编码。下文将分别进行分析论述。

缺失类故障是大部分列车检修时需要考虑的项目，列车上的部件包含大量的小零部件如插销、螺栓以及协同装置等，这些小零部件保障着大部件的整体运行稳定性，使其能够正常发挥功能作用。然而地铁列车长期频繁制动并运行在阴暗潮湿的高污环境中，其高频振动和部件老化极易导致零部件损坏缺失。零部件的缺失容易进一步导致部件整体功能不稳定甚至失效而引发安全事故，因此如何保证准确检测此类零部件是否缺失成为列车检修中急需解决的问题。

鼓包类故障主要出现在地铁列车柔性部件上，此类部件往往作为一个调节装置保证列车运行中的稳定性与舒适性。如空气弹簧，它是工作原理是在密闭的压力气囊充入惰性气体或者油气混合物，使腔体内的压力高于大气压的几倍或者几十倍，利用活塞杆的横截面积小于活塞的横截面积而产生的压力差来实现活塞杆的运动。空气弹簧具有较理想的非线性弹性特性，加装高度调节装置后，车身高度不随载荷增减而变化，弹簧刚度可设计得较低，乘坐舒适性好。但空气弹簧悬架结构复杂，加上在列车行驶过程中需要根据运行状态频繁改变内部压强，频繁的气囊形变使得其像常见的汽车轮胎一样容易出现鼓包。一旦出现鼓包则空气弹簧随时有破裂风险，威胁着列车运行的平稳性。

异物类故障主要出现在列车各类通风装置中，如牵引电阻与自动电阻通风的进出口。牵引设备是地铁列车运行时的动力设备，在刹车和加速运行中会产生大量的热量，这些热量不能及时排出极易引发动力设备起火。电阻及能源设备的起火轻则导致列车停运影响整个地铁线路运营，重则引起火灾导致人员财产损失。列车运行路线长、露天高架行驶线路增加，难免有各类异物落入轨道，列车行驶过程中容易带起异物，因此需要对散热通风进出口滤网设备进行常态化检修，保证没有异物阻塞风道。

松动类故障主要指列车上的螺栓部件，一辆地铁列车上分布着超过 20000 个各类型号的螺栓，列车长时间高频振动极易使得螺栓出现松动甚至脱落。螺栓往往起着紧固件作用，螺栓的脱落极易导致其固定装置不稳甚至在运行过程中掉落，造成安全隐患。因此及时对松动螺栓进行修复，是列车日常检修中占时间最多的一项检查，也是实现地铁列车智能化检修的最大挑战。

裂纹类故障是地铁列车上刚性部件和柔性部件都会出现的故障类型，如柔性部件空气

弹簧，刚性部件夹钳弹簧、紧固件螺栓甚至箱体表面都有可能因为运行过程中受力不均匀以及老化出现裂纹。裂纹的出现预示着部件的工况转为危险状态，裂纹会随着时间不断扩大，导致空气弹簧发生破裂、弹簧断裂以及螺栓碎裂后脱落等，最终威胁列车安全行驶。

#### 4.3.3 磨损消耗类故障模式分析

磨损消耗类故障模式主要包括磨损类如制动装置闸瓦磨损检测、二系高度测量以及消耗类如齿轮箱液位检测等，下文将分别进行分析论述。

地铁列车运行中其制动、加速、过弯等运行状态的改变往往会对部分部件产生磨损，如列车闸瓦作为列车的刹车片，列车每一次进站停车都会产生巨大的磨损。闸瓦的厚度关系着列车制动效果，当闸瓦出现过度磨损时，往往会导致列车制动能力下降，轻则出现停车不准重则导致列车制动装置失效，因此闸瓦成为列车日检的必检项。除此之外，列车行驶状态改变往往需要通过空气弹簧进行调节，从而保障整体运行的平稳性。空气弹簧状态可以二系高度进行反映，二系的高度是否正常可以反映出空气弹簧充放气是否正常。二系高度过低或者过高往往预示着空气弹簧出现漏气或者充气故障。如上文所述，空气弹簧作为列车行驶的稳定性、舒适性保障部件，需要时刻关注其工况是否正常。

消耗类如齿轮箱油液、撒砂箱砂位，齿轮箱作为传动结构，长时间处于高负载工况模式。齿轮箱内油液作为润滑剂，有效地降低了齿轮间摩擦损耗，使得各个齿轮处于顺滑的工况。因此充足的油液有利于保证列车平稳运行以及延长齿轮箱寿命。机车撒砂装置可向钢轨面撒砂来增大轮轨间粘着系数，以增大粘着牵引力和防止车轮空转。在检修中注意液位以及砂位是否处于警戒值，及时提醒负责人进行油液和砂子的补充。

### 4.4 地铁列车外观故障检测的性能指标

#### 4.4.1 机器人性能与导航性能推荐指标

系统中的巡检机器人应根据每天下达的检修业务，具有自动规划路径和智能避障功能，包括以下能力：

- (1) 根据场站基础地图智能规划路径，并行驶到指定位置；
- (2) 行动过程中，巡检机器人应可以检测障碍物，并根据实际情况停止运动等待障碍物移除，或重新规划路径绕行，直到到达目标区域；
- (3) 巡检机器人应对于自身所在位置进行精确定位，满足相机成像精度及安全运行要求；
- (4) 巡检机器人应具有直行、转弯、原地转向功能，具体选择根据现有技术进行综合评定。

相应机器人性能和机器人导航性能推荐指标如下表 4-1 和 4-2 所示。

表 4-1 机器人性能推荐指标

参数	推荐指标
机器人尺寸	根据调研结果确定其最小通过空间
最大运行速度	1m/s
机器人的越障能力	障碍物高度<20mm；沟槽宽度<20mm
全列检测时间	<30min@200m
电池续航能力	≥5 小时@工作状态
充电时间	≤0.5h
防护等级	IP54
防触碰	在控制系统失效或者刹车失效的情况下，碰撞到物体，机器人停止运行。

表 4-2 机器人导航性能推荐指标

参数	推荐指标
狭窄空间通过能力	机器人宽度+2cm
停车定位精度	≤+1cm@相对特征点
机械臂重复定位精度	±0.07mm
避障保护距离	标准 2m
制动距离	≤0.5m

#### 4.4.2 常规典型类故障检测算法性能指标

常规典型故障类型主要包括缺失类（Missing Class）、鼓包类（Bulge Class）、异物类（Foreign Class）、松动类（Losses Class）以及裂纹类（Crack Class）。

此类故障检测算法性能指标包括准确率，误报率，漏报率。常用的定义术语如下：

TP（True Positive）：正确的正例，一个实例是正类并且也被判定成正类；

FN（False Negative）：错误的反例，漏报，本为正类但判定为假类；

FP（False Positive）：错误的正例，误报，本为假类但判定为正类；

TN（True Negative）：正确的反例，一个实例是假类并且也被判定成假类。

则准确率被定义为所有的预测正确（正类负类）的占总的比重。

$$\text{准确率} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4-1)$$

误报率被定义为本为假类但被判定为正类的实例占总的比重。

$$\text{误报率} = \frac{FP}{TP + TN + FP + FN} \quad (4-2)$$

漏报率被定义为本为正常类但被判定为假类的实例占总的比重。

$$\text{漏报率} = \frac{FN}{TP + TN + FP + FN} \quad (4-3)$$

表 4-3 地铁典型故障类型算法性能最低指标

典型故障类型	准确率	误报率	漏报率
缺失类	≥85%	≤10%	≤5%
鼓包类	≥80%	≤15%	≤5%
异物类	≥80%	≤15%	≤5%
松动类	≥80%	≤15%	≤5%
裂纹类	≥85%	--	≤15%

#### 4.4.3 磨损消耗类故障检测算法性能指标

磨损消耗类故障模式主要包括磨损类如制动装置闸瓦磨损检测、二系高度测量以及消耗类如齿轮箱液位检测等。

此类故障检测算法性能指标为精度。精度是表示观测值与真值的接近程度，它与误差的大小相对应，因此可用误差大小来表示精度的高低，误差小则精度高，误差大则精度低。由于列车车底磨损消耗类部件的尺寸特性，本标准采用最大误差来表征精度，如表 4-4。

表 4-4 地铁磨损消耗类故障类型算法性能最低指标

磨损消耗类故障类型	精度：±2mm
-----------	---------

#### 4.5 地铁列车外观图像数据采集技术概述

智能巡检机器人的数据采集方式主要有两种，一种是通过安装在车体上的彩色激光线阵相机对车底进行快速扫描，获取列车底部完整的线扫图像；另一种则是通过机械臂上的高精度面阵相机可采集指定列车转向架、车钩等关键部件进行图像。智能巡检机器人采集面阵图像如图 4-3 所示。



图 4-3 智能巡检机器人采集数据

#### 4.5.1 外观线阵图像采集

线扫工业相机是车体外观检测机器视觉系统必不可少的核心组件。线扫相机（Line Scan Camera）是一种专门用于运动物体的工业相机。它的工作原理与传统相机有所不同，它采用一条窄长的 CCD（Charge-Coupled Device）线阵列，通过逐行地采集物体图像来构成完整的图像。具体来说，线扫相机在工作时，将物体沿着相机的扫描方向运动，通过在不同的时间点对不同位置的物体进行成像，最终得到整个物体的图像。由于线扫相机的 CCD 阵列只有一条，因此可以使用非常高的速率进行图像采集，从而适用于高速运动物体的成像。

线扫相机的优势主要有以下几个方面：

- (1) 高速成像：线扫相机可以以非常高的速率采集图像，适用于高速运动物体的成像和检测。
- (2) 高分辨率：线扫相机的 CCD 线阵列可以非常细密地采集物体的图像，因此可以获得非常高的图像分辨率，从而更精细地检测和分析物体的细节。
- (3) 低噪声：由于线扫相机的图像采集是通过逐行地扫描物体来实现的，因此在采集图像时会降低噪声的影响，从而可以获得更清晰的图像。
- (4) 易于集成：线扫相机可以与其他系统集成，例如可以与运动控制系统、图像处理软件等配合使用，从而实现更广泛的应用场景。

综上所述，线扫相机是一种高速成像、高分辨率、低噪声且易于集成的工业相机，适

用于复杂场景的地铁列车车底图像采集。

#### 4.5.2 外观面阵图像采集

针对列车转向架、车钩等关键部件，固定在智能巡检机器人本体上的线扫相机只能采集一个方向上的图像，以及出于对闸片厚度测量、液位高度测量的需求，所以需要在车体上搭载 3D 面阵相机，采集高分辨率的面阵图像以及三位点云。提供高分辨率并带有被测物体深度信息的三维点云数据。使用这些数据可以使得常规典型故障类型包括缺失类、鼓包类、异物类、松动类故障的检出率及准确率带来显著提高，同时匹配二维图像进行联合检测可降低系统因为灰尘等因素带来的系统误报。总之，对于地铁列车外观进行三维点云数据采集成为了一个重要方向。

3D 面阵相机（3D Area Scan Camera）是一种能够获取物体三维信息的相机，它可以测量物体表面的几何形状和纹理信息，与传统的 2D 面阵相机相比，它可以同时获取物体的高度、宽度和深度等三维信息。3D 面阵相机的工作原理主要有以下几个步骤：第一步，投射结构光：3D 面阵相机通过向物体表面投射结构光，即具有一定空间结构的光条或光斑，这些光条或光斑会在物体表面形成一定的形状和纹理信息。第二步，拍摄图像：3D 面阵相机通过采集被投射光线反射、散射后的图像信息，其中结构光的形状和纹理信息可以帮助计算出物体表面的深度信息。第三步，计算深度信息：3D 面阵相机通过对采集的图像进行处理和计算，可以确定被测物体表面每一个像素的深度信息，从而构建出物体的三维模型。

因此，3D 面阵相机的主要优势有：

(1) 高精度的深度信息：3D 面阵相机可以测量物体表面每个像素的深度信息，提供了非常高精度的深度数据，能够满足高精度的测量和检测需求。

(2) 高速的测量速度：3D 面阵相机采用面阵传感器，可以同时捕捉大量像素，因此能够快速获取物体的三维信息，提高工作效率。

(3) 能够处理复杂的物体形状：3D 面阵相机可以测量不同形状、复杂纹理和非均匀表面的物体，这些物体难以通过其他传感器进行测量和检测。

综上所述，3D 面阵相机是一种高精度的深度信息、高速的测量速度、能够处理复杂的物体形状的工业相机，适用于地铁列车关键部件的高分辨率 2D 图像采集以及测量类部件的 3D 点云采集。

在采集数据过程中，3D 面阵相机随着智能巡检机器人运行到指定路点，自动操作与其相连接的机械臂，机械臂可快速运行到指定位置，然后运行面阵相机，面阵相机照亮物体，

并采集所有曝光的像素以构建数据。因此智能巡检机器人也可以获得列车关键部件的外观高清面阵图像数据以及三维点云数据。

#### 4.6 地铁列车外观图像预处理技术概述

##### 4.6.1 二维图像预处理算法

###### 4.6.1.1 SIFT 图像配准

图像配准是图像处理领域的一项重要技术，在遥感测绘、目标识别、图像及视频检索、导航制导和场景分类等多个领域应用广泛。对于工程中提供的地铁相关零部件二维图像，常常会存在拍摄时间、拍摄角度、拍摄传感器的不一致，造成同一场景下的模板图片与待测样本之间存在一定的差异。为此需要通过图像配准将同一场景的两幅或多幅图像实现几何校准过程，为后期的异常检测奠定基础。

SIFT (Scale-invariant feature transform) 算法具有较好的稳定性和不变性，能够适应旋转、尺度缩放、亮度的变化，能在一定程度上不受视角变化、仿射变换、噪声的干扰。SIFT 图像配准算法基本步骤如图 4-4 所示：1.特征点提取;2.生成特征描述子;3.特征点匹配。其中特征点提取主要包括生成高斯差分 (Difference of Gaussian, DOG) 尺度空间、寻找局部极值点、特征点筛选、确定特征点方向；特征点匹配主要包括根据描述子相似性进行匹配、匹配对比值提纯、RANSAC 方法剔除离群匹配对。

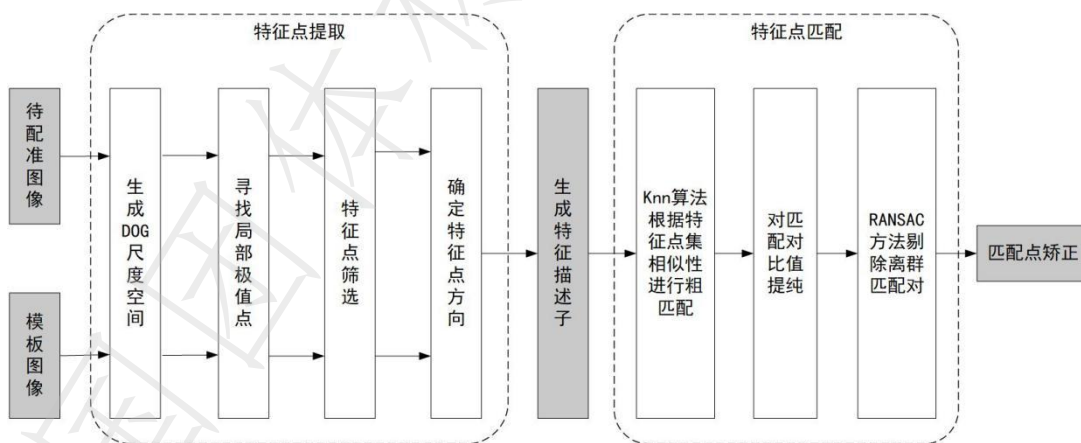


图 4-4 SIFT 图像配准算法流程图

##### (1) 生成 DOG 尺度空间

具有尺度不变性的特征检测是 SIFT 算法的核心，由于 Koendetink 证明了高斯核是实现尺度变换的唯一变换核，所以利用高斯核对图像进行卷积操作，达到尺度变换的目的，获得了不同尺度下的图像序列，再对这些图像序列进行空间特征点提取。

$$G(X, Y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (4-4)$$

$G(x, y, \sigma)$  为高斯平滑核函数，其中  $\sigma$  表示高斯函数的方差。

高斯函数与图像卷积能够得到尺度空间，则图像  $I(x, y)$  的尺度空间  $L(x, y, \sigma)$  可以表示为：

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (4-5)$$

实际计算时，DOG 是通过高斯金字塔图像中同一尺度相邻的上下两层图像相减得到的，其公式为：

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (4-6)$$

式中， $k$  视为一个常数，是两个相邻尺度图像的尺度比。

#### (2) 寻找局部极值点

为了寻找尺度空间的极值点，DoG 尺度空间中中间层的每个像素点都需要跟同一层的相邻 8 个像素点以及它上一层和下一层的 9 个相邻像素点总共 26 个相邻像素点进行比较，以确保在尺度空间和二维图像空间都检测到局部极值。

#### (3) 特征点筛选

由于 DoG 值对噪声边缘响应比较敏感，所以需要对上一步的检测结果进行三维二次函数拟合，用来精确定位特征点的位置和尺度，同时可以去除对比度较低的关键点和不稳定的边缘响应点。

#### (4) 确定特征点方向

特征向量除了具有该向量的坐标值（平面位置和尺度）外，还要根据特征点邻域像素的梯度方向分布特征来确定关键点的方向值，公式如下：

$$m(x, y) = \sqrt{(L(x+1, y) - L(x-1, y))^2 + (L(x, y+1) - L(x, y-1))^2} \quad (4-7)$$

$$\theta(x, y) = L(x, y+1) - L(x, y-1) / (L(x+1, y) - L(x-1, y)) \quad (4-8)$$

其中  $m(x, y)$  是高斯平滑图像  $L$  在点  $(x, y)$  处梯度的模值， $\theta(x, y)$  是高斯平滑图像  $L$  在点  $(x, y)$  处方向。

#### (5) 特征向量匹配

由于前期特征提取中提取出的特征向量是 128 维的，因此在进行特征点匹配时，匹配

的相似度采用欧式距离来衡量，特征点的寻找方式采用 K 近邻（KNN）算法查找。

在数学中，欧式距离是欧几里得空间中两点间的直线距离。点  $x = (x_1, x_2, \dots, x_n)$  与点  $y = (y_1, y_2, \dots, y_n)$  之间的欧式距离为：

$$d(x, y) = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2} \quad (4-9)$$

K 近邻算法求取在空间中距离最近的 K 个数据点，并将这些数据点归为一类，在进行特征匹配时，KNN 算法找到最近邻的两个数据点，如果最近的距离和次接近的距离比值大于设定的阈值，那就保留最接近的值，认为它和其匹配的点为 good match，通常比较的阈值为 0.75。

#### (6) RANSAC 筛选 SIFT 特征点匹配

RANSAC (Random Sample Consensus)，它是根据一组包含异常数据的样本数据集，通过迭代的方法计算出数据的数学模型参数，得到有效样本数据的非确定性的算法。

在 SIFT 特征点匹配中，同一平面上的物体在不同方向上的成像有一个透视变换的过程。透视变换的变换矩阵为一个  $3 \times 3$  的矩阵，因此需要 4 对匹配点来计算变换矩阵。不过这里需要注意的是，不同平面的物体在相机位置不同时候所拍的两张照片所对应的变换矩阵是不同的，由于 RANSAC 是按变换矩阵来筛选的，因此此算法不仅能筛选错误的匹配点，还能将一些不同平面的正确匹配点筛选。

RANSAC 算法在 SIFT 特征筛选中的主要流程为：

- 1) 从样本集中随机抽选一个 RANSAC 样本，即 4 个匹配点对；
- 2) 根据这 4 个匹配点对计算变换矩阵  $M_1$ ；
- 3) 根据样本集，变换矩阵  $M_1$ ，和误差度量函数计算满足当前变换矩阵的一致集，并返回一致集中元素个数；
- 4) 根据当前一致集中元素个数判断是否最优(最大)一致集，若是则更新当前最优一致集；
- 5) 更新当前错误概率  $P$ ，若  $P$  大于允许的最小错误概率则重复前 1-4 的步骤继续迭代，直到当前错误概率  $P$  小于最小错误概率。

#### 4.6.1.2 透视矫正

在平面图像处理中，因为镜头角度等原因，容易导致图像出现倾斜、变形等情况，为

为了方便后续处理我们常常需要进行图像透视变化矫正，将图像中的待测部分重新投射到一个新的平面，形成俯视鸟瞰图。

透视变换(Perspective Transformation)，又称投影映射(Projective Mapping)、投射变换等，是三维空间上的非线性变换，透视变换是指利用透视中心、像点、目标点三点共线的条件，按透视旋转定律使承影面(透视面)绕迹线(透视轴)旋转某一角度，破坏原有的投影光线束，仍能保持承影面上投影几何图形不变的变换。简而言之，通过一个 $3 \times 3$ 的变换矩阵 $M_2$ 将一个平面投影到一个新的视平面(Viewing Plane)，在视觉上的直观表现就是产生或消除了远近感。




图 4-5 透视变换矫正

#### 4.6.1.3 图像自适应增强

列车走行部所处环境阴暗潮湿，光照性差，在低照度环境下拍摄的图像通常能见度都很低，能见度高的图像能反映出场景中清晰的细节，这对于后期目标检测、异常检测工作有很大的影响。为此在图像预处理阶段需要对低光照的图像进行自适应增强（ACE）操作，提高低光照图片的对比度。

ACE 算法源自 retinex 算法，可以调整图像的对比度，实现人眼色彩恒常性和亮度恒常性，通过差分来计算目标点与周围像素点的相对明暗关系来校正最终像素值，有很好的增强效果。ACE 算法包括两个步骤：

假定  $x(i, j)$  是图像中某点的灰度值，低频部分采用求局部平均值的方法获得，模板大小为  $(2n+1) \times (2n+1)$ 。一般模板尺寸都比较大，经常选择  $(101 \times 101)$  模板。

$$m_x(i, j) = \frac{1}{(2n+1)^2} \sum_{k=i-n}^{i+n} \sum_{l=j-n}^{j+n} x(k, l) \quad (4-10)$$

通过式子求得模板的平均值  $m_x(i, j)$ , 则模板中的平均方差由下式求得标准差:

$$\sigma_x^2(i, j) = \sum_{k=i-n}^{i+n} \sum_{l=j-n}^{j+n} [x(k, l) - m_x(i, j)]^2 \quad (4-11)$$

对高频部分进行增强, 使用标准差做增益值, 均值  $m_x$  近似的认为是背景部分, 此时  $[x(i, j) - m_x(i, j)]$  即是高频细节部分, 对高频做增益乘积, 有:

$$f(i, j) = m_x(i, j) + \frac{D}{\sigma_x(i, j)} [x(i, j) - m_x(i, j)] \quad (4-12)$$

#### 4.6.2 三维点云数据预处理算法

点云是一个数据集, 数据集中的每个点代表一组 X、Y、Z 几何坐标和一个强度值, 这个强度值根据物体表面反射率记录返回信号的强度。当这些点组合在一起时, 就会形成一个点云, 即空间中代表 3D 形状或对象的数据点集合。

随着三维激光扫描技术的发展, 点云数据应用成为备受关注的研究热点, 已被广泛地应用于医学研究、文物数字化保护、游戏软件开发以及工程应用等领域。目前, 点云在列车外观故障领域的应用也逐渐被重视起来, 各类列车外观检测系统也在处于研发或者应用阶段。点云数据具有计算简便、测量精确度较高的特点, 并且对于干扰较小的弱光条件、没有明显的纹理及其形状改变的表层同样也可以进行精确的测量, 其发展前景和应用需求广阔。

实际的点云采集过程中, 由于物体本身材质的粗糙不一、光照不均匀、设备拍摄角度限制等原因, 3D 结构光扫描出物体点云时, 易形成离群点、噪点甚至孔洞, 点云数据的预处理是能否将点云数据用于生产应用的关键。点云数据的预处理大致包含了点云去噪、点云简化、点云配准等等步骤。

##### (1) 点云去噪

以下几个情况都是需要点云做出滤波和优化的: 第一, 点云的空间排列非常杂乱, 而且需要柔顺。第二, 因为不可抗因素如遮挡等问题导致距原始点云较远的离群点的数据需要被去除。第三, 大量的数据都需要在群中进行次级采样。第四, 数据包含过多噪声。

通常点云数据模型中的噪声分为客观噪声和主观噪声两大类, 其中客观噪声是由物理测量所产生的误差或外部干扰引起的, 而主观噪声则是由扫描现场无关物的干扰引起的, 如相机自身的检测精度。对于不同的噪声类型, 所采用的去噪方法也不同。

客观噪声的消除通常采用去噪算法实现，如点云体素分布滤波，K-邻域搜索算法、空间栅格算法、快速双边滤波算法、KD-tree 算法以及 Laplace 算法等。

快速双边滤波（Bilateral filter）是一种非线性的滤波方法，同时考虑空域信息和灰度相似性，达到保边去噪的目的。具有简单、非迭代、局部的特点。

三维点云快速双边滤波算法如下所示：

$$D_b(x,y) = \frac{W_b D_b(x,y)}{W_b(x,y)} = \frac{\text{interpolate}(G \otimes WD, x, y, z)}{\text{interpolate}(G \otimes W, x, y, z)} \quad (4-13)$$

式中  $WD$  和  $W$  分别为：

$$WD(x,y,z) = \sum_{(u,v) \in R(x,y,z)} d_i(u,v) \quad (4-14)$$

$$W(x,y,z) = \sum_{(u,v) \in R(x,y,z)} 1 \quad (4-15)$$

式中  $d_i(u,v)$  为点  $p_i = (x,y,z)$  邻域的深度值，邻域三维空间集为  $R$ ； $D_b(x,y)$  为滤波后的点云数据， $G$  为深度相似度因子。

主观噪声通常是为了扩大被测物的扫描范围所引起的，通常表现为大片的点云，利用三维图像模型信号处理软件就能够对其进行手动地消除。一般来说，可采用 meshlab 软件进行手工去噪。

## (2) 点云简化

通常三维扫描设备获取的点云数据模型的数据量都很大，数据点较为密集，对其存储、传输和计算均不利，因此有必要对其进行简化。点云简化的基本原则为：对于点云模型中曲率较大的地方，要尽量保留较多的数据点，而对于点云模型中曲率较小的地方，可以保留较少的数据点。关于点云的简化算法有很多，如 Delaunay 三角化点云简化算法，非均匀网格方法点云简化算法；扇形网格法点云简化算法。除此之外，还有基于曲面变化度的局部离群系数(SVLOF)的 ExtendedSVLOF(ESVLOF)算法。ESVLOF 定义如下式：

$$\text{ESVLOF}(p) = \begin{cases} \frac{\sigma_{sk}^{\beta}(p)}{\sigma_{sk}^{\alpha}(p)}, & \sigma_{sk}^{\beta}(p) \geq \sigma_{sk}^{\alpha}(p) \\ \left( \frac{\sigma_{sk}^{\beta}(p)}{\sigma_{sk}^{\alpha}(p)} \right)^{\sigma}, & \sigma \leq -2, \sigma_{sk}^{\beta}(p) < \sigma_{sk}^{\alpha}(p) \end{cases} \quad (4-16)$$

其中  $\sigma$  称为曲面变化度（或称为曲面变分），它被定义为  $p$  点及其邻域点构成的协方差矩阵  $C$  的最小特征值  $\lambda_0$  与所有特征值之和的比值它表示了该点处曲面的弯曲程度。 $\sigma_{sk}^{\beta}(p)$  是定义在饱和类  $k$  邻域(即包含  $p$  点的类  $k$  邻域)上的曲面变化度,  $\sigma_{sk}^{\alpha}(p)$  是定义在欠类  $k$  邻域

(即不包含  $p$  点的类  $k$  邻域)上的曲面变化度。利用  $ESVLOF$  作为近离群点的识别参数,既能识别平滑表面上的离群点,又能识别三维实体的棱边或棱角点处的离群点,同时仍然保留  $SVLOF$  原有的足够宽泛的阈值选取空间。

不管采用哪种简化方法,其目的都是为了在精简数据的同时,有效保持点云的重要特征。

### (3) 点云配准

在采用三维激光扫描设备获取被测物的点云数据模型时,通常一次扫描很难获取整个物体的完整点云数据信息,因此需要对同一物体在不同坐标系下进行不同角度下的多次扫描,并对多次扫描的结果进行配准,从而获得整个物体的完整点云数据模型。因此,点云配准就是将同一物体在不同方位下测得的点云数据模型通过刚体变换,使其能够统一到同一坐标系的过程。3D 点云配准是计算机视觉的关键研究问题之一,在多领域工程应用中具有重要应用,如逆向工程、SLAM、图像处理和模式识别等。点云配准的目的是求解出同一坐标下不同姿态点云的变换矩阵,利用该矩阵实现多视扫描点云的精确配准,最终获取完整的 3D 数字模型、场景。

根据配准规模,点云配准分为两大类,即两片点云配准和多片点云配准,而多片点云配准可以通过两片点云的多次配准实现,因此点云配准主要研究的是两片点云的配准。点云配准分为粗配准(CoarseRegistration)和精配准(FineRegistration)两个阶段。

粗配准是指在点云相对位姿完全未知的情况下对点云进行配准,可以为精配准提供良好的初始值。当前较为普遍的点云自动粗配准算法包括基于穷举搜索的配准算法和基于特征匹配的配准算法。

基于穷举搜索的配准算法:遍历整个变换空间以选取使误差函数最小化的变换关系或者列举出使最多点对满足的变换关系。如 RANSAC 配准算法、四点一致集配准算法(4-PointCongruentSet,4PCS)、Super4PCS 算法等。

基于特征匹配的配准算法:通过被测物体本身所具备的形态特性构建点云间的匹配对应,然后采用相关算法对变换关系进行估计。如基于点 FPFH 特征的 SAC-IA、FGR 等算法、基于点 SHOT 特征的 AO 算法以及基于线特征的 ICL 算法等。

精配准的目的是在粗配准的基础上让点云之间的空间位置差别最小化。应用最为广泛的精配准算法是 ICP (IterativeClosestPoint),其通过欧式变换求解出两片点云的旋转平移矩阵及对应的配准误差,ICP 算法通过不断求解估计的变换矩阵,直到 RMSE 配准误差收

敛于局部最优解，此时认为配准误差最小。

除了 ICP 点云配准算法外，还有 ICP 的各种变种，如稳健 ICP、pointtoplaneICP、PointtolineICP、MBICP、GICP、NICP 等。

#### 4.7 基于目标检测的地铁列车外观关键零部件定位技术

地铁列车关键零部件定位技术是地铁列车关键零部件故障诊断的核心技术，对地铁列车的螺栓、闸片、夹钳、高度阀等关键零部件进行定位及分类，从而为后续的故障诊断与分析打下基础。由于地铁列车关键零部件的图像数据便于采集，容易制作大量数据集，因此相比传统图像处理的定位手段，使用深度学习中的目标检测模型进行定位能够取得更可靠的结果。本文采用 YOLO 系列的目标检测模型对地铁列车关键零部件进行定位，其中主要使用 YOLOv4-Tiny 模型进行定位，其特点有是作为 One-stage 目标检测算法，兼具精度与速度，训练简单且高效。以下是关于 YOLOv4-Tiny 目标检测模型的原理描述。

YOLOv4-Tiny 是 YOLOv4 的轻量化版本，其所需计算参数量仅 600 万左右，远小于标准版，在地铁列车关键零部件定位任务中，其在能满足精度需求的前提下，大大提升了检测速度，满足了算法的实时性要求，能够在 CPU 环境上进行实时检测。YOLOv4-Tiny 的网络结构如下图 4-6 所示。

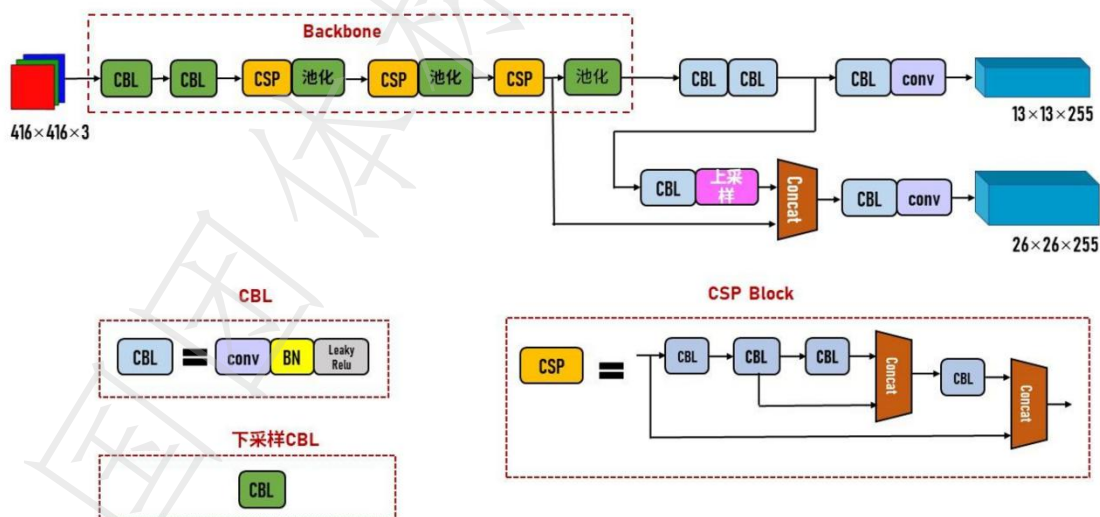


图 4-6 YOLOv4-Tiny 网络结构图

YOLOv4-Tiny 的主干网络采用 CSPDarknet53，使用 LeakyReLU 激活函数以提高运算速度。相比原来的 Darknet 网络，加入 CSP 结构之后，解决了主干网络中信息重复问题，尤其是在一些大型神经网络梯度优化过程中，这样可以很大程度减少模型的参数数量和浮点运算量，使得最终模型的推理速度有所提升。

在 CSPNet 的主干部分，CSPDarknet53 会对一次  $3 \times 3$  卷积后的特征层进行通道的划分，分成两部分，取第二部分。利用主干特征提取网络，我们可以获得两个不同尺度的有效特征层，即 CSPDarknet53 最后两个尺度的有效特征层，传入加强特征提取网络当中进行 FPN 的构建。

YOLOv4-Tiny 中使用的 FPN 结构，主要是对第一步获得的两个有效特征层进行特征融合。FPN 会将最后一个尺度的有效特征层卷积后进行上采样，然后与上一个尺度的有效特征层进行堆叠并卷积。

在 YOLOv4-Tiny 的检测头部分，YOLOv4-Tiny 提取多特征层进行目标检测，一共提取两个特征层，两个特征层的尺度分别为  $26 \times 26 \times 256$ 、 $13 \times 13 \times 512$ 。输出层的尺度分别为  $26 \times 26 \times 255$ 、 $13 \times 13 \times 255$ ，最后一个维度为 255 是因为该图是基于 COCO 数据集的，它的类别为 80 种，每个特征点预测 3 个先验框，每个框包含 4 个坐标以及 1 个置信度，因此维度为  $3 \times 85$ 。

每个检测框都由 85 维数据表示，分为 4 个坐标数据、1 个置信度、80 个类别概率，分别为  $x\_offset$ 、 $y\_offset$ 、 $h$  和  $w$ 、置信度、80 个类别概率，将每个网格点加上它对应的  $x\_offset$  和  $y\_offset$ ，加完后的结果就是预测框的中心，然后再结合  $h$ 、 $w$  计算出预测框的长和宽，这样就能得到整个预测框的位置。但由于每个特征点预测 3 个框，而最终的特征图分为  $13 \times 13$  和  $26 \times 26$  两个，因此预测框数量达 2535 个，需要通过 NMS 非极大值抑制算法去除多余的重叠的框。NMS 算法流程如下所示。

假设有 6 个候选框，按照置信度从大到小排序为 A、B、C、D、E、F。

1、从最大概率矩形框 A 开始，分别判断 B~F 与 A 的重叠度 IOU 是否大于某个设定的阈值；

2、假设 B、D 与 A 的重叠度超过阈值，那么就剔除 B、D，认为 B、D 和 A 检测的为同一目标；并标记第一个矩形框 A，是我们保留下来的。

3、从剩下的矩形框 C、E、F 中，选择概率最大的 C，然后判断 E、F 与 C 的重叠度，重叠度大于一定的阈值，那么就剔除；并标记 C 是我们保留下来的第二个矩形框。

4、重复以上过程，直到没有剩下的框。

通过 NMS 算法后留下的框则为模型的定位结果。关于 YOLOv4-Tiny 的训练过程，YOLOv4-Tiny 的损失计算由三部分组成：

定位损失如式(4-17)所示，其中  $\lambda_{\text{coord}}$  表示正样本权重系数，默认为 1； $I_{ij}^{\text{obj}}$  为非 0 即 1，

正样本时为 1，因为这部分损失只计算正样本； $(2-w_i \times h_i)$  为惩罚项，用于惩罚小框。

$$L_{loc} = \lambda_{\text{coord}} \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{obj} (2 - w_i \times h_i) (1 - CIoU) \quad (4-17)$$

置信度损失如式(4-18)所示，使用了交叉熵损失，其中  $\lambda_{\text{noobj}}$  表示负样本权重系数，一般小于 1，因为负样本数量多于正样本，可以减轻网络训练的偏置； $\hat{C}_i$  表示置信度； $I_{ij}^{noobj}$  当负样本时为 1。

$$L_{obj} = \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{obj} \left[ -\hat{C}_i \log(C_i) - (1 - \hat{C}_i) \log(1 - C_i) \right] + \lambda_{\text{noobj}} \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{noobj} \left[ -\hat{C}_i \log(C_i) - (1 - \hat{C}_i) \log(1 - C_i) \right] \quad (4-18)$$

分类损失如式(4-19)所示，其中  $I_{ij}^{obj}$  为 0 即 1，当正样本时为 1，因为分类损失也只计算正样本； $p_i(c)$  表示第 i 个框是类 c 的概率。

$$L_{cls} = \sum_{i=0}^{K \times K} \sum_{j=0}^M I_{ij}^{obj} \sum_{c \in \text{classes}} \left[ -\hat{p}_i(c) \log(p_i(c)) - (1 - \hat{p}_i(c)) \log(1 - p_i(c)) \right] \quad (4-19)$$

## 4.8 地铁列车外观故障智能检测技术

### 4.8.1 地铁列车外观关键零部件异常检测技术

异常检测技术是地铁列车关键零部件故障检测中的常用技术之一，其可应用于地铁列车的空气弹簧、滤网、闸片等关键零部件的故障检测中。通常情况下基于深度学习的故障检测技术往往需要大量数据样本作为支撑，然而实际场景下，地铁列车关键零部件出现故障是小概率偶然事件，采集到的故障样本（负样本）非常有限，正负样本数量极不均衡，普通的故障检测技术很难取得理想的效果。异常检测技术作为数据驱动的故障检测技术中一条特立独行的分支，其训练过程只需大量正样本，算法模型可根据这些数据学习到正样本的特征，而负样本特征没有得到模型的学习，因此模型在对待检测样本进行估计评分时，负样本会与正样本有着较大的差异。目前的基于深度学习的异常检测算法主要包扩：

(1) 以 Ganomaly 为代表的基于 GAN 网络的半监督式异常检测算法：图 4-7 所示为 Ganomaly 网络的整体结构图，其主要包含了两个编码器，一个解码器和一个判别网络。第一个子网络是一个自动编码器网络，作为模型的生成器部分，该生成器分别通过编码器和解码器网络学习输入数据表示并重构输入图像。第二个子网络是编码器网络 E，用于压缩生成器 G 重构的图像。第三个子网络是判别器网络 D，其目标是分辨输入 x 和输出哪个是真哪个是假，从而优化生成器网络 G。GANomaly 算法在图像编码的潜在空间下比对，即对于正常的的数据，编解码再编码得到的潜在空间和第一次编码得到的潜在空间差距不会

特别大，但是在正常样本训练下的网络用作从未见过的异常样本编码解码时，在经历两次编码过程下潜在空间往往差距比较大，当两次编码得到的潜在空间差距大于一定阈值的时候，判断样本是异常样本。

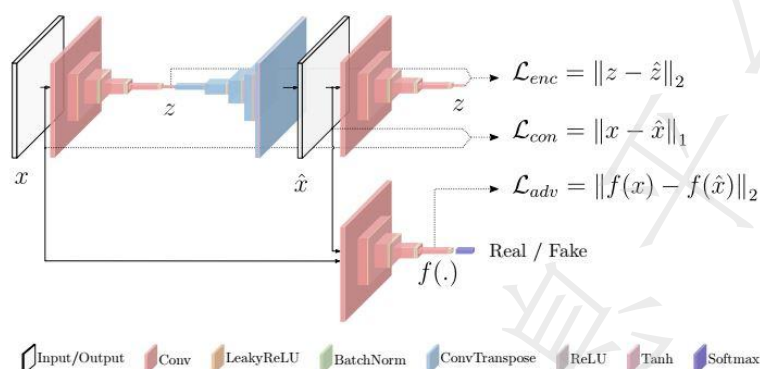


图 4-7 GANomaly 算法结构图

(2) 以 Deep SVDD 与 OC-CNN 等为代表的基于构建超球面的异常检测算法：其特点在于构建一个超球面，将超球面之外的异常点认定为负样本，而这样做的困难在于要建立效果良好的特征工程，才能寻到一个合适的超平面区分正负样本，其原理如图 4-8 所示。




图 4-8 基于超球面的异常检测可视化

OC-CNN 的检测思路首先通过特征提取器获得一定长度的特征向量，之后通过标准高斯函数生成同样大小的特征向量与特征提取器的特征向量做嵌合，再将嵌合之后的特征向量送入分类器中，给该待检测图片一个标签来区分是否属于该类。其结构可视化如图 4-9 所示。

OC-CNN 使用的损失函数为二值交叉熵，其公式定义为：

$$L_c = -\frac{1}{2k} \sum_{j=1}^{2k} (y \log(p) + (1-y) \log(1-p)) \quad (4-20)$$

其中  $y \in \{0,1\}$  意味着当  $y=0$  时该输入来自于图片，而当  $y=1$  时则该输入来组与标准高斯函

数，而  $p$  表示分类器分类中  $y=0$  的可能性。




图 4-9 OC-CNN 结构示意图

OC-CNN 整体网络由特征提取器网络和分类器网络组成，特征提取器网络本质上提取了图像特征然后将特征与伪负类向量进行嵌合，该伪负向量有标准正态分布的高斯函数生成，然后将嵌合特征向量送入具有完全连接层的分类神经网络。OC-CNN 的特征提取网络从图片中提取长度为  $D$  的特征向量，同时从标准高斯函数  $N(\bar{\mu}, \sigma^2 \cdot I)$  也声称长度为  $D$  的特征向量，将两个特征向量进行嵌合送入网络最后的分类网络做一分类。

#### 4.8.2 地铁列车外观关键零部件测量技术

地铁列车外观检测研究越来越成熟，但是主要是基于二维图像进行算法开发与研究，随着检测需求不断增加，二维图片的算法难以切入到测量类故障类型检测中，所以只利用二维数据难以满足智能运维需求。为了进一步提升地铁列车外观故障检测的智能化程度，必须重视对于三维数据的应用，例如部件的尺寸、间隙和高度等测量只能通过三维信息获取。地铁外观关键零部件需要测量某些结构参数，利用三维数据对例如闸瓦磨损，螺栓松动，二系高度测量等项点进行研究可以提高智能化检测水平，3D 技术的发展为列车故障检测提供了新的研究方向。点云数据相对二维数据有效抑制如光照、污渍等环境因素干扰，利用点云方案能够更精确表达空间信息，并且通过测量尺寸等参数建立一种可以细化故障程度的检测算法，减少在故障检测领域常见的误报率问题。因此，本标准提供一种可行性解决方案，研究设计一种 3D 故障检测技术，利用三维点云数据对闸瓦等关键零部件进行研究，以“二维图像零部件分割—三维点云参数测量模型”的算法步骤，算法融合二维数据和三维数据实现基于三维点云的零部件故障检测。如图 4-10 所示，闸瓦磨损检测的关键步骤可分为二维语义分割和参数测量。

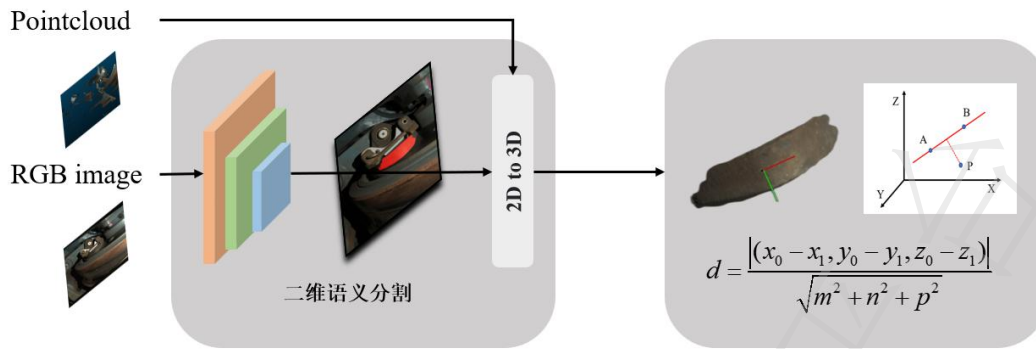


图 4-10 基于三维点云的测量检测技术

(1) 零部件分割：二维图像和三维数据有着各自的优势，二维数据在处理速度上比三维点云更具优势，所以选择使用基于深度学习的图像分割算法完成目标零部件的识别，目的是对图像中的每一个像素点进行分类，从而确定每个像素点所属的类别。比较常用的二维语义分割算法是 U-Net 和 DeeplabV3 网络等。获取到目标像素点之后，如图 4-11 所示，算法可以利用结构点云将二维数据提升到三维点云中，结构点云是被放置为类似于图像结构的 2D 点阵列。每个点均包含了 XYZ 数据以及 RGB 值，有序点云在 2D 图像（颜色和深度）中的像素与点云中的 3D 点之间具有 1:1 的相关性。分割模型获取所有属于目标像素点索引，根据索引在读取到所对应的点云信息。




图 4-11 有序点云

(2) 参数测量模型：测量模型就是利用三维信息和目标零部件的结构特点，针对不同的零部件设计独有的测量模型，实现既快速又准确的测量。常用的处理方式有点云降采样、配准、滤波、点云边缘检测、RANSAC 平面和直线检测、曲面重建等方法。以闸瓦磨损测量为例，通过直通滤波切片和检测直线的方式进行厚度的测量。