

基于视觉的列车轨道缺陷检测综述

陈天炎^{1,2}, 韩泽明¹, 黄允浒³, 石金进¹, 陈德旺¹

(1. 福建理工大学交通运输学院, 福建 福州 350118;
2. 福建船政交通职业学院轨道交通学院, 福建 福州 350007;
3. 闽江学院计算机与大数据学院, 福建 福州 350108)

摘要: 列车轨道缺陷检测对轨道交通安全具有重要意义, 但当前人工检测已不能满足复杂繁重的轨道巡检要求。深度学习方法极大地扩展了缺陷检测的手段, 为了提高表面缺陷检测的效率与质量, 结合轨道缺陷的类型与相关属性, 系统分析了当前视觉检测方法的变化趋势。详细阐述了轨面及扣件缺陷视觉检测方法, 以及与之相关的深度学习方法的基本原理、技术、方法与应用现状, 讨论了轨面及扣件缺陷检测方法的原理、应用和意义。最后, 对当前研究的轨道缺陷检测领域发展趋势进行分析和总结, 首次提出了全自动轨道检修系统的概念, 致力于为未来相关研究提供有益的支撑和借鉴。

关键词: 轨道交通安全; 轨道缺陷; 图像识别; 深度学习

中图分类号: TP391.4

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202427

Survey on vision-based railway track defect detection

CHEN Tianyan^{1,2}, HAN Zeming¹, HUANG Yunhu³, SHI Jinjin¹, CHEN Dewang¹

1. School of Transportation, Fujian University of Technology, Fuzhou 350118, China
2. School of Rail Transit, Fujian Chuanzheng Communications College, Fuzhou 350007, China
3. School of Computer and Big Data, Minjiang University, Fuzhou 350108, China

Abstract: The detection of train track defects is of great significance to the safety of rail transportation, but current manual inspection can no longer meet the complex and heavy track inspection requirements. Deep learning methods have greatly expanded the means and detection capabilities of defect detection, and in order to improve the efficiency and quality of surface defect detection, the current trends of visual detection methods in conjunction with the types and related attributes of track defects was systematically analyzed. The basic principles, technologies, methods, and current application status of visual detection methods for track and fastening defects, as well as the concepts, applications, and significance of these detection methods were elaborated. Finally, the current trends in the field of track defect detection are analyzed and summarized, and for the first time proposes the concept of a fully automatic track maintenance system, which aims to provide useful support and reference for future related research.

Key words: rail transportation safety, rail detect, image recognition, deep learning

收稿日期: 2024-03-05; 修回日期: 2024-06-15

通信作者: 陈德旺, dwchen@fjut.edu.cn

基金项目: 福建省第三批创新之星人才计划项目 (No.003002); 福建省交通运输科技项目 (No.2020030); 福建船政交通职业学院科教发展基金项目 (No.20220201)

Foundation Items: The Third Batch of Innovation Star Talent Program of Fujian Province (No.003002), Fujian Provincial Transportation Science and Technology Project (No.2020030), Science and Education Development Fund of Fujian Shipbuilding and Transportation Vocational College (No.20220201)

0 引言

随着轨道交通的快速发展, 轨道交通安全成为一个重要的问题。轨道的平顺、完好, 关系到列车行驶的安全。轨道交通中, 高速列车可以达到350 km/h, 轨道上任何微小的缺陷都会被这样的行驶速度放大。普通铁路速度较低, 由于铁路建设年龄较长, 覆盖率大, 铁路易出现擦伤、断裂、掉块、磨损、扣件丢失等缺陷, 当这些缺陷大量出现时, 列车的行驶将变得不安全。有研究^[1-2]显示, 钢轨表面缺陷将会导致滚动接触疲劳、钢轨头剥落和钢轨波纹等问题。

轨道基本构造包括钢轨、轨枕、联结零件、道床等。在实际的轨道行驶情况中, 还需要在基本的轨道构造上增加防爬设备、轨撑和道岔等, 联结零件一般包括接头联结零件和扣件。轨道总体构造与扣件的组成分别如图1和图2所示。




图1 轨道总体构造

轨道缺陷检测是一个较为复杂的概念, 涉及轨道的类型、构造和材料, 不同的缺陷有不同的形成机理, 涉及各种检测方法。同时轨道周围的工况很

复杂, 由于轨面与扣件缺陷需要定期检测和修复, 周期较短, 工程量较大, 这使得复杂工况下的作业不可避免, 如阴天作业、晴天作业、雨天作业等。

当前对轨道缺陷的研究主要集中在钢轨轨面以及扣件的缺陷检测, 按照《钢轨伤损分类》标准^[3], 依据伤损种类、伤损位置及伤损原因进行分类, 共分为9类32种伤损。《钢轨伤损分类》标准没有涉及对扣件缺陷的规范。工业界将缺陷分为两类^[4]: 纹理类缺陷和功能性缺陷, 扣件的表面伤损和钢轨的表面缺陷属于纹理类缺陷, 扣件组成构件的丢失、损坏则属于功能性缺陷。目前针对轨道缺陷有多种检测方法——目检、超声波检测^[5]、电磁检测、视觉检测^[6]。当前最普遍的仍是目检, 这需要大量的有经验的技术工人, 并且精度、效率、安全都难以得到保证, 同时在恶劣的天气条件下, 例如雨雪、冰雹等, 无法对轨道进行准确的检测维护, 效率较低。其他检测方法都有一定的局限性, 超声波检测适用于检测轨道核伤, 在表面检测的任务中表现会下降, 是一种接触式检测; 电磁检测是非接触式检测, 但是不易将伤损分类; 视觉检测可以检测轨道表面伤损, 具有高速、高自动化的优势, 同时也是一种非接触式检测。

目前, 轨道缺陷检测领域已经呈现出明显的技术和产业创新驱动的发展态势。截至2023年12月, 以万方数据知识服务平台为中文数据源、以Web of Science为英文数据源的文献检索显示, 目前篇名包含关键词“轨道缺陷检测/Rail defect detect”的有49篇中文和323篇英文期刊文献。统计了Web of Science中10年间轨道缺陷检测的研究成果, 如图3所示, 其中基于深度学习的轨道缺陷检测方法从属于基于视觉的轨道缺陷检测方法, 基于视觉的轨道缺陷检测方法从属于轨道缺陷检测大




图2 扣件的组成




图3 Web of Science中10年间轨道缺陷检测的研究成果统计

类。可以发现近些年基于视觉的轨道缺陷检测方法已经成为轨道检测研究领域的热门方法，而基于深度学习的视觉缺陷检测方法在近4年逐步成为基于视觉的轨道缺陷检测方法的主要支撑部分。当前轨道的缺陷检测技术主要从无损的角度进行综述，综合论述轨道缺陷的各类检测方法，基于视觉的轨道缺陷检测方法往往作为其中一类方法，对其技术难点与细节评述不够清晰^[7-10]。本文系统性地梳理了基于视觉的轨道缺陷检测方法的基本原理、核心技术、典型应用和现存问题，以期对未来研究提供有益的启发与借鉴。

本文组织结构为：第1节阐述了轨面与扣件视觉缺陷检测技术的基础架构模型及其关键技术现状；第2节概述了轨道缺陷检测技术的现状与发展趋势，首次提出了全自动轨道检修系统的概念；第3节总结本文内容。

1 视觉检测方法

基于视觉的轨道缺陷检测实际上要逐步定位缺陷，具体来说，要从整张图片中定位到钢轨或扣件等被检主体，再从被检主体定位到缺陷，还要根据缺陷的形状、纹理等信息完成语义的分类。

1.1 轨道缺陷类别与属性判定

轨道缺陷具有外部缺陷和内部缺陷两类不同的属性，表1依据缺陷发生的位置、纹理判定了轨道

各类缺陷的属性。由表1可知，轨道的大部分缺陷属于外部缺陷，且不同缺陷的纹理差异明显，适合使用表面损伤的判别方法进行缺陷的识别。视觉检测方法是一种无损的、基于表面纹理的检测方法，适用于完成轨面与扣件的缺陷检测任务。

表1 各类缺陷属性

缺陷状态	属性	缺陷状态	属性	缺陷状态	属性
磨损	外部缺陷	断裂	外、内部缺陷	锈蚀	外部缺陷
压溃	外部缺陷	裂纹	外、内部缺陷	擦伤	外部缺陷
辗边	外部缺陷	掉块	外部缺陷	扣件表面伤损	外部缺陷
凹陷	外部缺陷	核伤	内部缺陷	扣件弹片丢失	外部缺陷

1.2 传统视觉检测方法

在轨道检测领域中，传统视觉缺陷检测技术已经趋于成熟，本节梳理了轨道检测领域近10年的各类传统视觉检测方法，其技术思路、优缺点如表2所示。

传统机器视觉的方案针对缺陷设计人工图像处理算子，提取不同的缺陷特征，通过设定不同的阈值对缺陷进行识别。阈值选取可以通过经验人为设计，也可以通过一些复杂的统计分析或机器学习方法学习到自然的分布规律。该技术对复杂环境（多变天气、轨道污染等）下的检测有一定适用性。

在轨道缺陷检测中，直接使用传统数字图像处

表2 各类传统视觉检测方法

方法类别	技术思路	优点	缺点
传统数字图像处理算子	针对某类缺陷调试并设计特征图像增强与缺陷定位	针对性强，鲁棒性较强，适用于不同场景	通用性不强，受到不规则点的严重影响，易产生误检
分层定位	背景、目标物、缺陷三级分割定位	逐步定位，鲁棒性较好；可应用于遮挡、复杂纹理等复杂场景	算法复杂度较高
概率统计	稀疏表示、支持向量机等	精度高，有数学保证	抗噪声能力较弱，鲁棒性较差

理算子检测缺陷往往可以解决特定的缺陷,如扣件的视觉检测。**Han**等^[11]使用多源视觉传感器,针对紧固件过紧或者过松的情况,采集二维和三维信息,使用动态模板匹配算法在二维图像中对固件进行定位,使用分水岭算法在三维图像中对螺母和螺栓进行分割,完成了整个紧固件松紧度的检测。**Guerrieri**等^[12]引入了一种数字图像处理技术,用于测量钢轨的横向轮廓、波纹度以及道砟等级,可以较好地应用于轨道缺陷的检测与监测。

当前,各种纹理分析技术^[13]已广泛应用于轨道表面图像的分类、检测和分割。**Li**等^[14]没有使用轨道图像的全局Gabor纹理特征,而是使用局部频率特征来保证局部或小波纹的检测性能。**Dubey**等^[15]基于最大稳定极值区域技术提取缺陷区域的几何特征(即面积、质心、填充面积和周长)进行进一步分析。此外,利用谱特征的小波变换也应用于钢轨检测中^[16]。这些方法在很大程度上依赖于提取的全局或局部空间强度模式,在均匀纹理轨道表面图像上表现良好。然而,由于复杂的轨道条件和摄像机质量造成的较大随机噪声,它们无法检测到外观极其多样、背景动态的缺陷。

遮挡、复杂纹理的问题在视觉检测的场景中经常出现,会影响视觉模型对图片纹理的理解能力,为解决此问题,**Gan**等^[17]与**Min**等^[18]构造了一种分层检测的框架对缺陷实现了分割和定位。**Gan**等^[17]设计的分层检查框架包括粗提取器和精细提取器,粗提取器提取背景信息,精细提取器提取上下文信息并定位缺陷,取得了良好的效果;**Min**等^[18]设计了完整的视觉系统,基于形态学过程对钢轨表面缺陷进行优化,并通过跟踪方向链码获得缺陷特征,完成了缺陷检测系统的构建。粗提取器通过探索铁路背景的特征来检测缺陷,而精细提取器则通过整合纵向的上下文信息和横向先验信息来减少噪声点的影响。

Guo等^[19]提出一种区域自适应加权和范数最小化的方法,对车载系统采集的图像进行噪声建模和去噪,体现了在图像去噪领域的优越性;**Li**等^[20]提出了一种实时离散缺陷检测方法。首先,该系统利用局部图像增强缺陷与背景的对比度,该方法是非线性且与光照无关的。随后,提出了基于投影轮廓的缺陷定位(defect localization based on projection profile, DLBP)算法来识别可能存在的缺陷,该系统可以检测到93.10%的Type-II缺陷和80.41%

的Type-I缺陷,且有较高实时性。**He**等^[21]提出了一种新的Perona-Malik扩散模型用于图像增强,使用自适应阈值二值化方法可以很容易地找到所需的缺陷。虽然这些尝试都是为了提高检测性能,但它们受到不规则点(噪声点)的严重影响,易产生误检。

使用概率统计的方法可以对纹理进行建模,拥有更软的边界和间隔,可以应对复杂环境下的缺陷检测与定位。**Liu**等^[22]考虑了测试样本与其邻居之间的关系,只使用最近的 K 个邻居来代表和分类测试样本,构造了堆成图像样本的稀疏表示,从而对样本进行分类,提高了缺陷识别的准确性,并减少了错误识别的问题,特别是对于部分磨损的扣件;**Feng**等^[23]使用似然概率模型开发自动视觉系统,将似然概率分为3个等级识别扣件缺陷,并验证了算法的有效性,但是对图像中石头或电线等遮挡导致的误分类的处理效果不佳,在缺失紧固件的检测上精度较低,平均分类精度仅为21.3%。传统的数字图像处理方法需要手工设计算子。2020年,**Gan**等^[24]针对轨道的特定缺陷提出了一种面向背景的缺陷检测器,通过对背景统计数据进行足够数量的随机采样,利用缺陷检测和融合程序来判别当前数据是否属于背景,取得了良好结果。**Lee**等^[25]采用基于特征描述的算法对波纹、侦察和正常表面完成了区分,提取了7个特征作为特征向量构建支持向量机,准确率达到97.11%。

总结上述图像处理方法,依据抽象视觉检测技术的本质,可以将传统视觉检测方法归纳为图4所示流程。

1.3 基于深度学习的方法

深度学习是一类优秀的人工智能方法,普遍应用于图像、自然语言处理等领域。它不需要对数据进行针对性的去噪,关注于学习图像的语义和内部构造,从而理解图像的信息,在图像处理领域产生了非常优秀的效果,基于深度学习的图像处理技术已经应用于大量的领域。轨道缺陷检测领域也开始探索一些基于深度学习的方法,并将其应用于特征提取。

总体上,轨道缺陷检测领域使用的深度学习方法如表3所示。

基于深度学习的检测方法最初采用一种有监督的方法构建模型,其模型结构如图5所示。

扣件的检测是轨道缺陷检测的重要内容。**Gib-**




图4 传统视觉检测方法流程

表3 各类深度学习方法

方法	任务类别	优点	缺点
Yolo 系列 ^[26-34]	缺陷检测	实时性高,适用于处理大规模数据,有较好的目标定位和分类能力	对小尺度目标和密集目标的检测效果较差,对于一些复杂场景,精度可能不高
U-Net 等 ^[35-41]	缺陷分割	可以进行像素级分割,提取精确的目标区域	训练和推理速度较慢,对计算资源要求较高
Vision Transformer ^[42-43]	缺陷检测	可以捕捉图像中的长距离依赖关系,适用于处理大尺度图像,模型参数较少,容易训练	对于小数据集,可能不如传统的卷积神经网络效果好,计算复杂度较高,需求数据量较大
GAN 系列 ^[28,44-47]	图像扩展	能够生成高质量样本,对抗训练过程使得生成的样本逼真	训练不稳定,需要仔细调参,可能会生成不合理的样本
PaDiM ^[48]	无监督缺陷检测	无监督学习,适用于缺乏标注数据的情况,能够检测各种类型的缺陷	对于复杂背景和多类别缺陷可能鲁棒性不强,性能高度依赖于正常样本的选择
VAE ^[49-51]	缺陷生成	能够学习数据的潜在表示,适用于无监督学习,可以生成逼真的样本	生成图像的多样性有限,训练需要仔细设计网络结构和损失函数
原型学习 ^[52]	缺陷定位	对于小样本学习具有较好的效果,可以快速适应新类别	需要大量的类别原型,对于大规模数据集,计算代价较高
强化学习与数字孪生预测 ^[53]	缺陷预防	可以根据反馈进行策略优化,数字孪生预测,可以在虚拟环境中进行大量实验,大大减少了缺陷的出现	强化学习训练不稳定,需要合适的奖励设计,数字孪生模拟可能无法完全模拟真实环境
协作学习注意网络 ^[54]	缺陷分割	跨模态信息融合	数据获取较难
联邦学习 ^[55]	缺陷检测	保护隐私,节省带宽,适用于大规模分布式数据	通信开销较大,需要解决模型融合和安全性等问题

ert 等^[26]针对缺陷图像较少的实际情况提出了一种深度多任务学习方法,并应用于轨道轨枕和扣件的缺陷检测,提高了检测的准确性; Hsieh 等^[27-28]分别在 2020 年和 2022 年基于 YOLOv3 和 YOLOv4-tiny 完成了离线与在线的轨道扣件检测系统; Feng 等^[29]将 YOLO 与特征金字塔结合,完成了高性能的检测; chandran 等^[30]提出了可以精准定位紧固件的图像处理算法,同时去除紧固件中的冗余信息,将卷积神经网络 (convolutional neural networks, CNN) 和 ResNet-50 算法用于分类目的,这两种算法在训练和验证阶段的准确率均达到 98% 以上; Aydin 等^[31]将经过增强的图像应用局部二值的方法进行处理,确定了扣件的位置,再使用支持向量机作为分

类器的改进的轻量级卷积神经网络 (improved lightweight convolutional neural network, LCNN) 对缺陷进行分类,检测准确率达到 99.7%。但是,当前的深度学习模型仍然无法通过图像理解扣件在整个轨道交通中起到的作用,进而也很难完成扣件的功能性检测。此外, YOLO 系列模型的锚框定位能力仍需要改进。

对于 YOLO 的检测范式有一些优秀的改进工作。Hu 等^[32]提出了一种加入坐标注意力机制的 YoloX-Nano 模型,可以更快地对扣件缺陷进行检测; Acikgoz 等^[33]提出了一种多尺度残差卷积网络 (multi-scale residual convolutional network, MSR-ConvNet) 模型来对不同类型的铁路轨道缺陷进行分




图5 有监督深度学习方法构建的模型的结构

类,在总体准确度、精确度、敏感性、特异性4个指标上均达到99%以上的水平;Li等^[34]不仅对YOLOv5算法加入了注意力机制和特征金字塔,同时使用K-means算法对数据集实现了重新聚类,改进锚框对缺陷的定位能力,实现了更高的检测精度和更快的检测速度。注意力机制的结构如图6所示。




图6 注意力机制的结构

轨道缺陷的检测中,分割任务实际上就是对缺陷的定位和检测。它的难点在于分割边缘的细粒度以及检出效果,模型需要达到像素级的理解能力并完成辨别与分类。Lu等^[35]提出了一种SCueU-Net模型,结合了U-Net分割网络和缺陷定位方法,应用于高铁钢轨缺陷检测任务,该方法具有99.76%的检测精度;Kim等^[36]使用改进的全卷积神经网络开发了分割模型,自动检测与分割轨道表面的缺陷;Jin等^[37]使用马尔可夫随机场和快速区域建议卷积神经网络(faster region proposal convolutional neural network, Faster RCNN)构建了深度多模型,对钢轨表面缺陷完成了快速准确的边缘分割,这种方法具有良好的鲁棒性,能够抵御各种噪声和光照条件;现有的方法不仅存在缺陷样本稀缺的问题,而且由于相似类别之间的细微差异,其细粒度识别能力较低,Tu等^[38]针对这些问题,提出一种基于

实例分割的轨道缺陷实时检测方法,首先使用一种改进的轻量级实例分割网络,用于扣件和钢轨的分割和定位,其次提出了一种通过分析紧固件掩模的几何特征来检测紧固件缺陷的方法,上述方案可以克服紧固件缺陷的稀缺性,提高钢轨缺陷检测的精度;也有一些工作将两阶段的检测模型的思路与图像分割进行融合完成检测,Guo等^[39]使用微调的经典实例分割模型基于区域的掩膜卷积神经网络(mask region-based convolutional neural network, Mask RCNN)在定制数据集上完成了钢轨表面的缺陷检测,验证了有效性;Guo等^[40]在轻量级主干中加入了注意力机制构造分割模型,完成了轨道缺陷检测任务;Li等^[41]提出了一种快速渲染的分割架构,达到了更快的分割速度和更好的分割效果。

上述模型多数基于CNN,近期,视觉转换器(vision transformer, ViT)显著改善了异常检测的研究,Wan等^[42]指出现有的显著性检测网络存在定位不准确、轮廓不良和检测不完整问题,针对性地引入了滑动窗口变压器来对全局信息进行建模,对于轮廓不清晰的问题通过轮廓对齐模块加深模型对前景和背景深度差异的理解,实验结果十分显著;Hoshi等^[43]在ViT模型中引入一种高性能模块,在东京铁路公司的数据集上进行实验,性能表现良好,但其检测目标是轨道系统的接地信号线,改进模型在轨道缺陷数据集上的表现仍未经过测试。此外,由于此架构需要大量的数据,目前在轨道缺陷检测领域尚无太多应用。

当前钢轨缺陷检测面临的挑战是数据收集困难,特别是难以获取严重损坏组件的图像数据,Hsieh等^[28]在2022年的文献中也指出了这个问题。

深度学习方法需要大量数据才能得到优良的效果,但是在实际运营中,由于缺陷修复的紧迫性以

及缺陷的稀缺性，往往很难收集到足量的数据完成对模型的训练，这也导致数据集很难在多种多样的真实物理环境中保证良好的泛化能力。针对这一特定问题，Cheng等^[44]使用了一种混合生成对抗网络对原始数据集进行处理，使用改进数据集的YOLOv4在3项指标上均比原始数据集表现优异；针对数据样本不足的问题，Su等^[45]提出了一种紧固件样本生成的新方法，主动将样本生成分为两部分，根据几何约束和条件生成前景和背景，分别进行图像修复；Xia等^[46]提出了RailGAN模型，RailGAN模型生成的人工图像与铁轨上的真实裂缝非常相似，适合训练基于神经网络的缺陷识别算法。有些工作将对抗生成网络（generative adversarial networks, GAN）用在缺陷检测中，通过对抗样本加深模型对缺陷的理解。Niu等^[47]提出了一种加入自适应金字塔图和变异残差的GAN，增强了对弱纹理异常缺陷的检测，同时也提高了对异常样本的识别能力，总体上提高了检测异常的鲁棒性。GAN的基本原理如图7所示，该文还设计了自适应焦点门损失和正则化对数似然损失来克服不同背景信息下训练样本的

不平衡问题，试验取得了良好的效果。

生成数据的方法也存在各种缺陷，如GAN的训练十分脆弱，不易收敛，在轨道缺陷检测领域开始有了一些新的探索，使模型可以学习到更好的分布与特征。一种无监督、用于异常检测和定位的补丁分布建模（patch distribution modeling, PaDiM）框架，通过学习正样本的真实分布与图像纹理的正常结构关系，在缺陷检测任务上表现良好，Kim等^[48]对PaDiM模型加入了残余注意力引导机制，完成了对轨道缺陷区域的分割。PaDiM模型的原理如图8所示。

Min等^[49]针对缺陷样本不足、正负样本不平衡等问题，提出先使用轻量级网络提取轨道表面，再使用变分自编码器（variational auto-encoder, VAE）完成铁路表面的重建，从而实现对缺陷的分割，该方法精度较高，也是工业界近年来热门的方法；Ferdousi等^[50]提出了一种基于VAE的综合图像生成技术，并通过一种改进的正则化策略，将权重衰减与重建损失结合，实现了0.021的最小重建损失，使用该合成数据集进行微调的ViT在分类5种铁路




图7 GAN的基本原理




图8 PaDiM模型的原理

缺陷类别方面取得了98%的准确率；Yuan等^[51]利用一种卷积变分自编码器（convolutional variational auto-encoder, CVAE）以无监督的方式提取特征，使用椭圆包络法进行检测，实现了较好的检测效果。

Min等^[52]采用原型学习的技术，在对模型预训练后，使用无监督学习的方法构建原型库，克服了有监督范式对大量数据样本的依赖，对缺陷完成了高精度的检测和定位。

Sresakoolchai等^[53]采用了预测性维护的思路，将强化学习和数字孪生结合，这种方法既减少了大量的维护活动，也大幅减少了接下来将要出现的缺陷；Wang等^[54]提出了一种协作学习注意力网络（collaborative learning attention network, CLANet），用于无服务铁路表面缺陷检查，可以检查钢轨表面的缺陷对象并分割出该缺陷的精确区域，该方法有跨模态信息融合特点；任中伟等^[55]提出了一种轻量级的联邦学习方法，应对传统集中式训练方法要求共享参与方的私有数据，导致的隐私泄露、流量通信压力等问题，有效建立全局模型，取得了有效进展。

1.4 数据集

当前与轨道缺陷相关的数据集较为稀少，同时铁路的数据一般有保密原则，不对外开放。可以直接下载以供研究的数据集不多，其数据量较少，缺陷种类不多，由于标注年代较早，部分数据质量也不高，大大影响了轨道缺陷检测领域技术发展的进度。数据集示例如图9所示。

在表4中收集了网络上可以检索到的轨道缺陷数据集，其中质量最好的数据集是Rail-5k，经过合理设计，各类缺陷的分布与标注精度都较为合理，但是并不开源；最优的数据集是RSDDs，但是数据量较少，不能满足当下的研究需要；ARMOK是网络上相关人员标注的数据集，质量较高，但是关于轨面、扣件等数据并不开源；RTFD是开源在Kaggle上的数据集，其将异常与非异常的图片分

别存储，但是并没有对每张图片做精细的标注，采样质量较差，使用范围较窄；RDDD是北京交通大学在综合ARMOK、RTFD以及RSDDs基础上扩展提出的数据集，用来验证他们提出的联邦学习轻量化模型训练技术，其部分图像细节较RTFD更为细腻，但RTFD与RDDD两个数据集图像的前景与背景的差异过大，数据之间没有很好的平滑，适用范围较窄。轨道缺陷检测领域急需可供研究的高质量数据集。

表4 轨道缺陷数据集

名称	规模/张	缺陷类别	是否开源	标注质量
RSDDs ^[14]	195	2	是	图像级
Delft ^[56]	3 240	6	否	图像级
Rail-5k ^[57]	1 100	13	否	实例级
RTFD	384	4	是	是否异常
RDDD ^[55]	1 738	4	是	图像级
ARMOK	14 010	未知	部分开源	图像级

1.5 评价指标

缺陷检测任务需要评价指标对提出的方法的效果进行评估，参考工业界对缺陷检测方法的总结分类，使用缺陷分类和异常定位的模型评价指标进行叙述。使用预测正确与否与图像真实情况可以定义4个指标，通常称为混淆矩阵，如表5所示。

表5 混淆矩阵

对比项	真实缺陷	真实正常
预测缺陷	真阳性(TP)	假阳性(FP)
预测正常	假阴性(FN)	真阴性(TN)

(1) 缺陷分类的指标

$$\text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Recall} = \text{TPR} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{F1-measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (4)$$




图9 数据集示例

$$FPR = \frac{FP}{FP + TN} \quad (5)$$

其中, Accuracy 为准确率, 即在全部预测中, 正确预测结果占的比例。真正类率 (true positive rate, TPR) 用于刻画分类器所识别的正实例占有正实例的比例。F1-measure 为精确率 (Precision) 和召回率 (Recall) 的调和平均数, 用来衡量二分类模型在精确率和召回率之间的平衡性能。

在缺陷检测的分类任务中, 常使用两类曲线作为评估的依据。

①精确率-召回率 (precision-recall, PR) 曲线: 在不同阈值设置下, 以召回率为横坐标轴, 以精确率为纵坐标轴绘制的曲线。

②受试者工作特征 (receiver operating characteristic, ROC) 曲线: 在不同阈值设置下, 以负正类率 (false positive rate, FPR) 为横坐标轴, 以 TPR 为纵坐标轴绘制的曲线。对于 ROC 曲线来说, TPR 越高, 同时 FPR 越低, 即 ROC 曲线越陡, 模型的性能越好。

(2) 异常定位的指标

异常定位性能的评估常常使用 ROC 曲线下面积 (area under receiver operating characteristic curve, AUROC) 和逐区域重叠度 (per-region-overlap, PRO) 作为评价指标。

通常, 我们使用 AUROC 来度量相应曲线指标所描述的性能。ROC 曲线中的 TPR 值受缺陷面积的影响, 如果能够正确定位面积较大的异常区域, 将会显著提高 TPR 指标; 如果错误定位较小的缺陷区域, 则对该指标的影响不会很大。因此, AUROC 在实际应用中存在一定的局限性。

为弥补 AUROC 逐像素测量导致的不足, Bergmann 等^[58]提出了一种连通域级的指标 PRO, 它平等对待任何大小的异常区域。具体而言, 首先将定位的缺陷结果和实际的真值按连通域划分为 N 个区域。接着, 计算每个区域中预测结果 P 和真值 G 的交集, 并将交集除以 G 后, 通过 N 个区域的加权平均即可得到 PRO。同时, 预测结果 P 和真值 G 的交集即真阳性样本, 因此 PRO 也可以根据混淆矩阵进行计算。

为了避免阈值对评估结果的影响, 可以绘制 PRO 曲线来描述异常定位性能。对于 PRO 曲线, 若 FPR 过高, 则表示大面积的正常区域被定位为缺陷。在这种情况下, 由于大面积的区域被定位为

缺陷, 真正样本 TP 的值也会很大, 即 PRO 很高。显然, 在这种情况下, 高 PRO 不能很好地反映模型的定位精度。因此, 在用 ROC 曲线下面积 (area under curve, AUC) 评价 PRO 曲线时, 仅选择令 FPR 处于 0~30% 的阈值, 并将 AUC 归一化作为逐区域重叠度分数。

由于轨道缺陷领域并没有一个学者们公认的高质量公共数据集, 且大部分相关研究不公开数据集, 其数据集的类别数目也多有不同, 不同方法的结果不具备直接可比性, 本文无法给出直观有效的实验结果对比。

2 现状与发展趋势

2.1 当前轨道缺陷检测技术的总现状

轨道缺陷检测技术的发展历程如图 10 所示, 最开始的检测方法是基于机械设备, 实现了轨道缺陷检测。但是这种方法不能够检测出所有类型的缺陷, 随着电气技术的进步, 学界、工业界慢慢发展了其他的方法作为补充^[2]。视觉检测方法最开始应用于轨道检测中的是基于传统数字图像处理, 随着深度学习的不断发展, 部分学者将深度学习方法引入轨道缺陷检测领域, 取得了较好的效果。早期的技术方法有限, 综述文章倾向于对轨道缺陷的历史及所有检测方式进行评述^[2], 此时视觉方法仅作为一种补充手段完成缺陷检测任务。2008 年, 随着数字图像处理技术的发展, Liu 等^[22]对基于计算机视觉的缺陷检测方法做了全面综述, 指出了这些视觉方案总体上是基于纹理的缺陷检测方法, 但仍然是基于传统的数字数字图像处理方法进行评述。2012 年, Alexnet 的提出成功将深度学习应用在计算机视觉领域, 大量的学者开展了相关研究, 轨道缺陷检测领域也随之跟进了该技术方案, 并取得了大量成果。对于传统视觉检测方法, 手工算子可以通过检测扣件的完整松紧实现扣件功能性的检测, 通过去噪等图像预处理完成对轨面突起、剥落、裂纹等表面缺陷的检测。

首先, 传统视觉检测方法只能针对单类缺陷进行识别, 如文献[23]只能检测轨道凸起, 多类的检测往往通过设计多个手工特征构造分类模型完成检测; 其次, 传统视觉检测方法中, 噪声的处理往往是一个重要问题, 噪声处理是决定算法工作效果的关键步骤; 最后, 传统视觉检测方法不能够适应对部分异物而非缺陷的检测, 文献[25]对阴影和污渍




图10 轨道缺陷检测技术的发展历程

的鲁棒性进行了测试，白色污渍被错误识别为缺陷。

深度学习通过大量数据对缺陷检测进行建模与迭代训练，期望模型学习到真实的图像语义，并在真实的环境中具有泛化性。深度学习具有高精度、高实时性的特点，克服了传统视觉检测方法需要手工设计算子的弱点，同时可以通过简单的数据集创建实现多类别的区分。但是大部分深度学习模型对数据量十分依赖，当前相关的数据集很少，开源的数据集只有很简单和很少量的数据样本，不能满足实际轨道缺陷检测设计的需求。通过数据增强和GAN模型生成图像可以一定程度上解决数据量的问题，但是仍不能从根本上满足真实物理环境下模型对多样性数据的要求。此外，实际的轨道缺陷检测中虽然在精度、速度以及模型的设计方面要优于传统数字图像处理的方法，但对于功能性缺陷的检测仍然是一个难点，并且传统视觉检测方法的可解释性要大幅优于基于深度学习的视觉检测方案。

当前的视觉检测系统中仍然需要传统视觉检测方法和基于深度学习的视觉检测方法相互辅助，共同完成缺陷检测的任务。

2.2 展望

轨道交通是社会经济、生活的重要支撑部分，轨道缺陷检测技术的可信、可解释性对于技术发展和应用具有重要指导意义。当前的视觉检测方法主要依赖于深度学习，人工智能领域发展的主流路径是使用大算力、大数据量，基于深度学习构建大模型，取得较高精度，本质上是一种数据驱动的方法。但是大算力、大数据量不能解决深度学习可解释性低的问题，同时可解释性低也是阻碍人工智能在社会中更广泛应用的一大原因。轨道缺陷检测在

基础技术变革的每个阶段都积累了大量对应的经验，这些经验往往在下一个阶段被更先进、更高精度的检测技术所淘汰，但这些方法往往拥有极强的实践性和可解释性。当前领域中缺陷检测模型未将这些经验与基于深度学习的视觉检测方法结合起来。为解决深度学习可解释性低的问题，可以使用一些成熟的知识驱动的方法，如模糊系统，将轨道缺陷检测领域丰富的经验提取为规则。将知识驱动的方法与数据驱动的方法结合，构建轨道缺陷检测模型，理论上该模型将具有两者的优点，拥有更好的可解释性和更高的精度^[59]。可解释性高的轨道缺陷检测模型如图11所示。




图11 可解释性高的轨道缺陷检测模型

随着时代的发展，轨道缺陷检测技术开始融合新一代人工智能技术构建高精度、实时性好的自动化检测装备。在深度视觉技术方向继续发展，与传统数字图像处理技术进行更深入结合后，对算法的要求不再只是将缺陷检出、类型判别，而是更注重算法检测细粒度。同类缺陷可以构建风险等级模型，算法和软件系统通过学习，根据伤损面积、伤损深度或细微差别的纹理信息判断缺陷的伤损等级，根据伤损等级、伤损位置、伤损类型构建缺陷修复的优先级；修复的优先级确定后，使用先进的数据传输技术，将修复任务下发给编组智能体，编

陷检测技术和轨道缺陷检测领域的发展趋势进行了预测和展望, 以期对未来研究提供有益的启发与借鉴。

参考文献:

- [1] CANNON D F, EDEL K O, GRASSIE S L, et al. Rail defects: an overview[J]. *Fatigue & Fracture of Engineering Materials & Structures*, 2003, 26(10): 865-886.
- [2] CLARK R. Rail flaw detection: overview and needs for future developments[J]. *NDT & E International*, 2004, 37(2): 111-118.
- [3] 中华人民共和国铁道部. 钢轨伤损分类: TB/T 1778—2010[S]. 2010. Ministry of Railways of the People's Republic of China. Classification of rail damages: TB/T 1778—2010[S]. 2010.
- [4] TAO X, GONG X Y, ZHANG X, et al. Deep learning for unsupervised anomaly localization in industrial images: a survey[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 5018021.
- [5] EDWARDS R S, DIXON S, JIAN X. Characterisation of defects in the railhead using ultrasonic surface waves[J]. *NDT & E International*, 2006, 39(6): 468-475.
- [6] CHEN K, BAI L B, CHEN Y F, et al. Defect automatic identification of eddy current pulsed thermography[J]. *Journal of Sensors*, 2014, 2014: 326316.
- [7] 张辉, 宋雅男, 王耀南, 等. 钢轨缺陷无损检测与评估技术综述[J]. *仪器仪表学报*, 2019, 40(2): 11-25.
ZHANG H, SONG Y N, WANG Y N, et al. Review of rail defect non-destructive testing and evaluation[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(2): 11-25.
- [8] GONG W D, AKBAR M F, JAWAD G N, et al. Nondestructive testing technologies for rail inspection: a review[J]. *Coatings*, 2022, 12(11): 1790.
- [9] KOU L. A review of research on detection and evaluation of the rail surface defects[J]. *Acta Polytechnica Hungarica*, 2022, 19(3): 167-186.
- [10] MIČIĆ M, BRAJOVIĆ L, LAZAREVIĆ L, et al. Inspection of RCF rail defects: review of NDT methods[J]. *Mechanical Systems and Signal Processing*, 2023, 182: 109568.
- [11] HAN Q, WANG S C, FANG Y, et al. A rail fastener tightness detection approach using multi-source visual sensor[J]. *Sensors*, 2020, 20(5): 1367.
- [12] GUERRIERI M, PARLA G, CELAURO C. Digital image analysis technique for measuring railway track defects and ballast gradation[J]. *Measurement*, 2018, 113: 137-147.
- [13] XIE X H. A review of recent advances in surface defect detection using texture analysis techniques[J]. *ELCVIA Electronic Letters on Computer Vision and Image Analysis*, 2008, 7(3): 1-22.
- [14] LI Q Y, TAN Y Q, ZHANG H Y, et al. A visual inspection system for rail corrugation based on local frequency features[C]//*Proceedings of the 2016 IEEE 14th Intl Conf on Dependable, Autonomic and Secure Computing, 14th Intl Conf on Pervasive Intelligence and Computing, 2nd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress*. Piscataway: IEEE Press, 2016: 18-23.
- [15] DUBEY A K, JAFFERY Z A. Maximally stable extremal region marking-based railway track surface defect sensing[J]. *IEEE Sensors Journal*, 2016, 16(24): 9047-9052.
- [16] SALVADOR P, NARANJO V, INSA R, et al. Axlebox accelerations: their acquisition and time-frequency characterisation for railway track monitoring purposes[J]. *Measurement*, 2016, 82: 301-312.
- [17] GAN J R, LI Q Y, WANG J Z, et al. A hierarchical extractor-based visual rail surface inspection system[J]. *IEEE Sensors Journal*, 2017, 17(23): 7935-7944.
- [18] MIN Y Z, XIAO B Y, DANG J W, et al. Real time detection system for rail surface defects based on machine vision[J]. *EURASIP Journal on Image and Video Processing*, 2018(1): 1-11.
- [19] GUO X, LIU F, TIAN X T. Noise modeling and denoising of images collected by on-board track inspection system[J]. *Multimedia Tools and Applications*, 2022, 81(8): 11695-11715.
- [20] LI Q Y, REN S W. A real-time visual inspection system for discrete surface defects of rail heads[J]. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(8): 2189-2199.
- [21] HE Z D, WANG Y N, YIN F, et al. Surface defect detection for high-speed rails using an inverse P-M diffusion model[J]. *Sensor Review*, 2016, 36(1): 86-97.
- [22] LIU J J, LI B L, XIONG Y, et al. Integrating the symmetry image and improved sparse representation for railway fastener classification and defect recognition[J]. *Mathematical Problems in Engineering*, 2015(1): 1-11.
- [23] FENG H, JIANG Z G, XIE F Y, et al. Automatic fastener classification and defect detection in vision-based railway inspection systems[J]. *IEEE Transactions on Instrumentation and Measurement*, 2014, 63(4): 877-888.
- [24] GAN J R, WANG J Z, YU H M, et al. Online rail surface inspection utilizing spatial consistency and continuity[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, 50(7): 2741-2751.
- [25] LEE H, HONG J, WENDIMAGEGN T W, et al. Rail corrugation detection and characterization using computer vision[J]. *Sensors*, 2021, 21(24): 8335.
- [26] GIBERT X, PATEL V M, CHELLAPPA R. Deep multitask learning for railway track inspection[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(1): 153-164.
- [27] HSIEH C C, LIN Y W, TSAI L H, et al. Offline deep-learning-based defective track fastener detection and inspection system[J]. *Sensors and Materials*, 2020, 32(10): 3429.
- [28] HSIEH C C, HSU T Y, HUANG W H. An online rail track fastener classification system based on YOLO models[J]. *Sensors*, 2022, 22(24): 9970.
- [29] FENG J H, YUAN H, HU Y Q, et al. Research on deep learning method for rail surface defect detection[J]. *IET Electrical Systems in Transportation*, 2020, 10(4): 436-442.
- [30] CHANDRAN P, ASBER J, THIERY F, et al. An investigation of railway fastener detection using image processing and augmented deep learning[J]. *Sustainability*, 2021, 13(21): 12051.
- [31] AYDIN İ, SEVİ M, SALUR M U, et al. Defect classification of railway fasteners using image preprocessing and alightweight convolutional neural network[J]. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2022, 30(3): 891-907.
- [32] HU J, QIAO P, LV H H, et al. High speed railway fastener defect detection by using improved YoLoX-Nano model[J]. *Sensors*, 2022, 22(21): 8399.
- [33] ACIKGOZ H, KORKMAZ D. MSRConvNet: classification of railway track defects using multi-scale residual convolutional neural network[J]. *Engineering Applications of Artificial Intelligence*, 2023, 121: 105965.
- [34] LI X, WANG Q, YANG X W, et al. Track fastener defect detection model based on improved YOLOv5s[J]. *Sensors*, 2023, 23(14): 6457.
- [35] LU J, LIANG B, LEI Q J, et al. SCueU-Net: efficient damage detec-

- tion method for railway rail[J]. IEEE Access, 2020, 8: 125109-125120.
- [36] KIM H, LEE S, HAN S. Railroad surface defect segmentation using a modified fully convolutional network[J]. KSII Transactions on Internet and Information Systems, 2020: 4763-4775.
- [37] JIN X T, WANG Y N, ZHANG H, et al. DM-RIS: deep multimodal rail inspection system with improved MRF-GMM and CNN[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1051-1065.
- [38] TU Z W, WU S R, KANG G Q, et al. Real-time defect detection of track components: considering class imbalance and subtle difference between classes[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 5017712.
- [39] GUO F, QIAN Y, RIZOS D, et al. Automatic rail surface defects inspection based on mask R-CNN[J]. Transportation Research Record: Journal of the Transportation Research Board, 2021, 2675(11): 655-668.
- [40] GUO F, QIAN Y, YU H Y. Automatic rail surface defect inspection using the pixelwise semantic segmentation model[J]. IEEE Sensors Journal, 2023, 23(13): 15010-15018.
- [41] LI M X, PENG B, LIU J, et al. RBNNet: an ultrafast rendering-based architecture for railway defect segmentation[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-8.
- [42] WAN C, MA S, SONG K C. TSSTNet: a two-stream swin transformer network for salient object detection of No-service rail surface defects[J]. Coatings, 2022, 12(11): 1730.
- [43] HOSHI T, SHIBAYAMA S, JIANG X N. Employing a hybrid model based on texture-biased convolutional neural networks and edge-biased vision transformers for anomaly detection of signal bonds[J]. Journal of Electronic Imaging, 2023, 32(2): 1-10.
- [44] CHENG M Y, KHASANI R R, SETIONO K. Image quality enhancement using HybridGAN for automated railway track defect recognition[J]. Automation in Construction, 2023, 146: 104669.
- [45] SU S X, DU S L, LU X B. Geometric constraint and image inpainting-based railway track fastener sample generation for improving defect inspection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(12): 23883-23895.
- [46] XIA Y W, HAN S W, KWON H J. Image generation and recognition for railway surface defect detection[J]. Sensors, 2023, 23(10): 4793.
- [47] NIU M H, WANG Y Y, SONG K C, et al. An adaptive pyramid graph and variation residual-based anomaly detection network for rail surface defects[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 5020013.
- [48] KIM I, JEON Y, KANG J W, et al. RAG-PaDiM: residual attention guided PaDiM for defects segmentation in railway tracks[J]. Journal of Electrical Engineering & Technology, 2023, 18(2): 1429-1438.
- [49] MIN Y Z, LI Y X. Self-supervised railway surface defect detection with defect removal variational autoencoders[J]. Energies, 2022, 15(10): 3592.
- [50] FERDOUSI R, YANG C S, HOSSAIN M A, et al. Generative model-driven synthetic TrainingImage generation: an approach to cognition in railway defect detection[J]. Cognitive Computation, 2024, 16(5): 1-16.
- [51] YUAN Z D, ZHU S Y, CHANG C, et al. An unsupervised method based on convolutional variational auto-encoder and anomaly detection algorithms for light rail squat localization[J]. Construction and Building Materials, 2021, 313: 125563.
- [52] MIN Y Z, WANG Z W, LIU Y, et al. FS-RSDD: few-shot rail surface defect detection with prototype learning[J]. Sensors, 2023, 23(18): 7894.
- [53] SRESAKOOLCHAI J, KAEWUNRUEN S. Railway infrastructure maintenance efficiency improvement using deep reinforcement learning integrated with digital twin based on track geometry and component defects[J]. Scientific Reports, 2023, 13: 2439.
- [54] WANG J P, SONG K C, ZHANG D F, et al. Collaborative learning attention network based on RGB image and depth image for surface defect inspection of No-service rail[J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(6): 4874-4884.
- [55] 任中伟, 方维维, 许文元, 等. 面向轨道缺陷检测的联邦学习轻量化模型训练技术研究[J]. 铁道学报, 2023, 45(4): 77-83.
- REN Z W, FANG W W, XU W Y, et al. Research on lightweight model training technology of federated learning for railway defect detection[J]. Journal of the China Railway Society, 2023, 45(4): 77-83.
- [56] FAGHIH-ROOHI S, HAJIZADEH S, NÚÑEZ A, et al. Deep convolutional neural networks for detection of rail surface defects[C]//Proceedings of the 2016 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE Press, 2016: 2584-2589.
- [57] ZHANG Z H, YU S Z, YANG S W, et al. Rail-5k: a real-world dataset for rail surface defects detection[EB]. arXiv preprint, 2021, arXiv: 2106.14366.
- [58] BERGMANN P, FAUSER M, SATTLEGGGER D, et al. Uninformed students: student-teacher anomaly detection with discriminative latent embeddings[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2020: 4182-4191.
- [59] TAKIKAWA T, ACUNA D, JAMPANI V, et al. Gated-SCNN: gated shape CNNs for semantic segmentation[EB]. arXiv preprint, 2019, arXiv: 1907.05740.
- [60] 陈德旺, 欧纪祥. 平行模糊控制: 虚实互动、相互增强的自学习控制方法[J]. 智能科学与技术学报, 2023, 5(2): 267-273.
- CHEN D W, OU J X. Parallel fuzzy control: a self-learning control method with virtual-real interaction and mutual enhancement[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(2): 267-273.
- [61] 王飞跃. 平行控制: 数据驱动的计算控制方法[J]. 自动化学报, 2013, 39(4): 293-302.
- WANG F Y. Parallel control: a method for data-driven and computational control[J]. Acta Automatica Sinica, 2013, 39(4): 293-302.
- [62] 王飞跃, 缪青海, 张军平, 等. 探讨 AI for Science 的影响与意义: 现状与展望[J]. 智能科学与技术学报, 2023, 5(1): 1-6.
- WANG F Y, MIAO Q H, ZHANG J P, et al. The DAOs to AI for Science by DeSci: the state of the art and perspective[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(1): 1-6.
- [63] 王鹏, 陈森. 基于平行控制的信息安全管理措施仿真与优化[J]. 自动化学报, 2011, 37(11): 1351-1355.
- WANG P, CHEN S. A parallel control approach to optimization of information security management measures[J]. Acta Automatica Sinica, 2011, 37(11): 1351-1355.
- [64] 项凤涛, 罗俊仁, 谷学强, 等. 群视角下的多智能体强化学习方法综述[J]. 智能科学与技术学报, 2023, 5(3): 313-329.
- XIANG F T, LUO J R, GU X Q, et al. Survey on multi-agent reinforcement learning methods from the perspective of population[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(3): 313-329.
- [65] 杨静, 王骁, 王雨桐, 等. 平行智能与 CPSS: 三十年发展的回顾与展望[J]. 自动化学报, 2023, 49(3): 614-634.
- YANG J, WANG X, WANG Y T, et al. Parallel intelligence and CPSS in 30 years: an ACP approach[J]. Acta Automatica Sinica, 2023, 49(3): 614-634.

[作者简介]



陈天炎（1981- ），男，福建船政交通职业学院轨道交通学院教授，福建理工大学交通运输学院硕士生导师，主要研究方向为工业机器人、轨道缺陷检测。



石金进（1984- ），男，福建理工大学交通运输学院讲师、硕士生导师，主要研究方向为工业机器人、机器视觉和缺陷检测。



韩泽明（1998- ），男，福建理工大学交通运输学院硕士生，主要研究方向为机器视觉、轨道缺陷检测。



陈德旺（1976- ），男，福建理工大学交通运输学院教授，俄罗斯自然科学院外籍院士，福州大学计算机与大数据学院博士生导师，福建省“闽江学者”特聘教授，主要研究方向为人工智能算法、模糊系统和智能交通系统。



黄允许（1990- ），男，闽江学院计算机与大数据学院讲师，主要研究方向为机器学习、模糊系统及智能交通系统。