

深度时间序列异常检测在轨道状态检测中的应用研究

王玉欣, 张长伦*

北京建筑大学理学院, 北京

收稿日期: 2025年8月24日; 录用日期: 2025年9月14日; 发布日期: 2025年9月25日

摘要

轨道缺陷严重威胁高铁运行安全, 传统人工巡检的方法难以实现大规模快速识别, 基于振动的轨道状态监测技术因其低成本和在线监测的优势被广泛采用, 针对该类时间序列数据开发高效的检测算法至关重要。本文系统综述了基于深度学习的时间序列异常检测方法及其在轨道振动状态检测中的应用。首先, 依据模型的学习任务类型, 对基于深度学习的时间序列异常检测方法进行分类介绍, 随后综述了这些方法在轨道异常检测中的具体应用, 并深入探讨了时间序列异常检测在轨道异常检测应用中面临的问题与挑战, 最后对未来研究工作进行展望。

关键词

深度学习, 时间序列, 异常检测

Deep Time Series Anomaly Detection and Its Application in Track Anomaly Detection

Yuxin Wang, Changlun Zhang*

School of Science, Beijing University of Civil Engineering and Architecture, Beijing

Received: August 24, 2025; accepted: September 14, 2025; published: September 25, 2025

Abstract

Track defects pose a serious threat to high-speed rail operational safety. Traditional manual inspection methods struggle to achieve large-scale, rapid identification. Vibration-based track condition monitoring technology, with its low cost and real-time monitoring advantages, has been widely

*通讯作者。

文章引用: 王玉欣, 张长伦. 深度时间序列异常检测在轨道状态检测中的应用研究[J]. 图像与信号处理, 2025, 14(4): 422-428. DOI: 10.12677/jisp.2025.144039

adopted. Developing efficient detection algorithms for such time-series data is of critical importance. This paper provides a systematic review of time series anomaly detection methods based on deep learning and the application of deep learning in track vibration time series data. First, the paper categorizes and introduces time series anomaly detection methods based on deep learning according to the type of learning task of the model. Subsequently, it reviews the specific applications of these methods in track anomaly detection. The paper then delves into the challenges and issues faced in time series anomaly detection applications for track anomaly detection. Finally, it summarizes and outlooks future developments.

Keywords

Deep Learning, Time Series, Anomaly Detection

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

高铁轨道是高铁系统的重要组成部分, 对其健康状态进行智能检测和识别, 对确保高铁安全稳定运行具有重要意义。随着传感器技术的不断进步, 采集到的轨道状态监测数据为轨道异常检测提供了数据基础, 面对海量的巡检数据, 人工处理的方法不仅效率低下、成本高昂, 还易受到人为因素的影响, 导致检测精度不高, 更重要的是, 许多损伤的敏感特征难以通过人工巡检发现。

结合机器学习与深度学习算法对采集到的数据进行检测, 极大地提升了轨道异常识别的效率和准确性。其中, 基于振动信号的轨道状态监测技术凭借低成本、易实施和实时检测等优势, 近年来得到广泛应用, 针对该类时间序列数据, 传统信号处理的方法通过检查频率成分变化或频谱分析来识别异常状态, 针对该类时间序列数据, 传统信号处理的方法通过检查频率成分变化或频谱分析来识别异常状态[1] [2]。近年来, 越来越多的机器学习和深度学习方法应用于检测高铁振动信号数据, 早期方法通常结合传统信号处理和浅层机器学习[3] [4], 而深度学习技术凭借对时间序列数据的出色处理能力, 已展现出显著优势。由于采集过程中环境复杂多变, 基于振动的轨道状态监测数据往往面临噪声干扰和非平稳性等特点, 而长短期记忆网络(LSTM)、卷积神经网络(CNN)和自动编码器(AE)等深度学习模型在时间序列特征提取和异常模式识别方面具有出色的能力, 可以识别传统方法难以检测到的异常模式[5], 因此在面对高铁轨道振动数据时展现出卓越的性能与应用价值。此外, 现有方法还可根据是否有标记的数据进行系统性分类, 从而更好地理解和研究其技术特点与应用场景。

本文旨在全面探讨深度时间序列异常检测方法的核心概念及分类, 重点讨论深度学习方法在轨道振动时间序列数据中的应用, 并详细介绍其中的经典网络框架, 同时我们将探讨基于深度学习的时间序列异常检测在轨道异常检测应用中面临的问题与挑战, 并对未来发展进行总结与展望。

2. 时间序列异常检测

时间序列异常检测又名离群点检测, 是检测时间序列数据中显著偏离正常模式的时刻或区段的过程。不同于静态数据, 时间序列包含连续的时序依赖和动态变化, 异常的判断通常需要兼顾历史信息 and 未来趋势。正常模式表现为在既定的周期或趋势范围内的波动, 而异常则是那些在统计特征或结构上与大多数时段明显不同的点或片段[6]。

近年来, 深度学习在学习时间数据特征方面表现出巨大的能力, 深度时间序列异常检测是指利用神经网络自动学习序列特征, 并通过表示学习或异常评分机制识别偏离正常模式的异常, 无需手工设计特征[7], 从而完成异常判定的过程。在解决各类实际应用中的复杂检测问题方面, 深度时间序列异常检测表现出比传统时间序列异常检测更优的性能。另外, 依据模型在训练过程中使用标签的多少与学习任务的性质, 深度时间序列异常检测方法大致划分为四大类, 有监督、无监督、半监督和自监督。

2.1. 有监督深度时间序列异常检测

有监督深度时间序列异常检测依赖于带标签的时间序列数据, 通过网络学习正常模式与异常模式间的判别边界, 并生成一个评分机制或相应阈值, 当某时刻的数据点得分超过该阈值时, 即判定为异常[8]。在监测领域, 这类方法通常采用传统的分类模型架构, 利用卷积神经网络、循环神经网络、LSTM 及其变体以及门控循环单元(GRU)等, 通过多层非线性变换提取时间序列特征, 并在输出层进行异常分类[9], 并且为了提高模型对时间序列数据的捕捉能力, 研究者提出了多种改进的网络架构[10][11]。相较于自监督与无监督方法, 这类方法由于使用了真实标签, 通常展现出更优越的检测精度, 然而其不足也非常明显, 深度网络需大量标注数据支撑才能建立有效的特征嵌入空间, 而真实环境中异常样本稀缺, 标注成本高昂, 从而限制了其在真实场景中的应用。

2.2. 无监督深度时间序列异常检测

获取大规模标注的异常数据面临着成本高与操作难度大等挑战, 在现实场景中完全依赖标注数据来训练模型通常是不切实际的。无监督深度时间序列异常检测仅利用时序信息的内在模式与规律来识别偏离常态的片段[12]。在深度学习框架下, 常用的无监督异常检测模型包括自编码器及其变体、生成对抗网络(GAN)、变分自编码器(VAE)等, 由于这类方法不需要异常样本的标注, 无监督深度时间序列异常检测方法特别适合现实场景中正常样本丰富而异常样本稀缺的情况, 因而得到广泛应用, 自编码器是最常用的模型之一, 通过编码器将输入数据压缩为低维表示, 再通过解码器重构原始数据, 训练过程使用正常样本, 通过最小化重构误差来学习正常模式的表征, 测试时, 重构误差被用作异常分数[13]。生成对抗网络由生成器和判别器组成, 仅用正常样本训练, 生成器生成正常样本, 判别器区分真实与生成样本, 测试时, 异常样本因与正常分布差异大, 被判别器识别为异常[14][15]。LSTM、Transformer 等递归或自回归模型用于基于预测的无监督异常检测, 通过构建正常时间序列预测模型, 并将预测误差作为异常分数[16]。然而, 无监督深度时间序列异常检测也面临着固有的挑战, 在高维复杂的时序特征空间中精准提取共性特征具有较高难度, 同时, 无监督深度模型对数据噪声和失真通常较为敏感, 其检测精度在多数场景下难以超过有监督或半监督方法。

2.3. 自监督深度时间序列异常检测

自监督方法核心在于借助未标注的数据构建辅助任务, 从而学习到特征表示[17], 自监督的时间序列异常检测通过对原始时间序列数据实施部分操作, 为原始样本构造“伪标签”并据此优化模型参数, 再通过设计辅助任务来强化特征学习, 如生成式方法通过构造预测或重建任务, 引导模型学习潜在表示[18][19]。基于对比学习的自监督时间序列异常检测, 通过正负样本的对比来学习表示, 与重建或生成式方法不同, 它并不重构输入, 而是构建正样本与负样本对齐或分离任务[20]。基于对抗的自监督方法借助生成对抗网络(GAN)构建代理任务, 通过对抗训练提升生成质量并保留时序动态特征, 如 USAD 中两个自动编码器相互对抗放大重构误差[21], Anomaly Transformer 使用对抗策略来放大异常的异常评分[22]。基于上述方法构造代理任务, 模型在完成这些代理任务的过程中, 自动提取对正常模式敏感且高度泛化的表

征, 从而在遇到未知异常时展现出更强的识别能力。

2.4. 半监督深度时间序列异常检测

获取标注的正常数据以及少量标注的异常数据并非难事, 研究建议应尽可能利用这些相对易得的标注信息[7]。针对此需求, 半监督方法应运而生, 当数据集仅包含正常样本而无异常标注时, 半监督异常检测方法可通过构建正常时序数据的分布模型实现异常识别。其核心是先利用无标注的正常数据训练模型, 再用有限异常样本微调模型以区分异常, 使其学习并拟合时间序列的固有分布特征, 继而将显著偏离该分布的样本判定为异常点[17]。

3. 深度学习在轨道振动时间序列数据中的应用

随着深度学习在时间序列异常检测领域发展, 其在高铁振动数据异常检测、伤损识别等领域得到广泛应用。有监督学习通过伤损标签信息指导模型训练, 在轨道异常检测领域已得到广泛应用和验证。无监督或自监督策略通过对正常数据建模、评估重构误差或采用对比学习等机制, 弥补了监督学习的不足。

3.1. 监督模式

有监督学习利用有限的标注样本借助深度神经网络自动学习数据的时序特征与判别边界, 将原始高铁振动数据映射到特定的故障类别, 从而实现对已知异常模式的精确识别。

2021年, 陈梅等人[23]提出了一种有监督学习的全卷积网络(FCN), 通过全卷积网络从轴箱加速度序列中自动提取特征, 实现不可见扣件损伤识别, 研究中设计了三类损伤和五级损伤程度仿真实验, 生成含损伤和轨道不平顺激励的轴箱加速度时序数据, 所提 FCN 检测器将加速度序列、轨道不平顺度和车速信息共同输入, 实现损伤的监测。

2022年, 谢青林等人[24]提出一种融合深度学习与数据驱动算法的钢轨波磨检测方法, 提出通过“空间域”切割法处理轴箱加速度序列并建立样本集, 通过构建一维卷积神经网络(1DCNN)对波磨状态及波长进行有监督检测。

2023年, 谢青林等人[25]提出一种有监督的 RCNet 卷积回归模型, 该模型以轴箱加速度时间序列作为输入, 经 Z-scores 归一化和滑动窗口处理后, 通过一维卷积层提取时序特征, 结合全局最大池化构建回归预测层, 实现端到端的高铁轨道波磨异常的检测。

2024年, 彭佳宁等人[26]提出一种有基于监督学习的轮轨状态识别方法, 利用轴箱垂向振动加速度构建时频融合特征, 通过变维卷积神经网络实现轮轨不良状态的准确诊断, 该方法首先利用一维卷积神经网络对振动时间序列和频谱序列降维, 融合后升维形成时频特征图, 再由二维卷积神经网络完成特征提取, 实现状态分类检测。

3.2. 无监督模式

有监督学习异常检测中依赖大量已标注的训练数据, 但由于实际场景中伤损较少, 很难收集覆盖所有轨道损伤的数据, 相比之下, 无监督策略依托正常数据或信号内部结构特征, 能够在无需或仅少量标注条件下挖掘潜在异常模式。

2021年, 徐文龙等人[27]针对轨道振动数据中多样化且分布不确定的异常, 提出了一种基于图注意力和对抗自编码器的无监督深度时序异常检测框架, 先利用图注意力网络从里程配准后的多维时序中挖掘通道与邻域节点间的依赖, 接着, 采用对抗训练的自编码器重构输入序列, 并以重构误差量化偏离程度, 最后通过设置阈值判定异常。

2021年, 袁占东等人[28]提出了一种基于深度时间序列异常检测的轨面塌陷定位算法, 首先, 利用

卷积变分自编码器无监督地从车辆轴箱加速信号中学习多层次时序特征, 之后将重构后特征依次输入椭圆包络检测器和一类支持向量机实现对异常模式的判别, 并通过室内振动实验进一步确认其准确性。

2024年, 王思博等人[29]设计了一种无监督 GAN 异常检测框架检测高铁动检数据, 利用基于 Prob Sparse 注意力的改进 Transformer 编码器-解码器提取序列的长时依赖特征, 随后在重构网络中引入生成对抗机制, 通过判别器放大正常与异常样本在重构误差上的差异, 从而缓解样本纯度不足的问题, 最后, 采用动态时间规整度量原始序列与重构序列间的偏差, 生成异常分数并通过阈值判断是否异常。

2025年, 扬森等人[30]引入了基于注意力的深度时序异常检测网络 Anomaly Transformer, 该模型采用双分支注意力结构, 一路学习属性间的先验关联, 另一路捕捉序列内的时序依赖, 实现对轨道几何不平顺数据特征的自动提取与异常检测。

3.3. 自监督模式

自监督技术通过构造预任务, 如信号重构、预测或对比学习, 在无需或仅需少量标签的情况下, 从原始时序中自动学习判别异常的深层特征。

2023年, Antonio Origlia 等人[31]探索了三种不同的自监督异常检测方法在真实车辆获得的加速度信号中识别轨道焊接位置的性能, 包括 AE, LSTM-AD 以及 LSTM-ED, 其中, 经典自编码器通过编码映射与解码重构, 依据高重构误差判定异常。LSTM-AD 采用双层 LSTM 进行时序预测, 基于预测误差识别异常, 无需窗口长度超参数, 能捕捉长期依赖。LSTM-ED 融合前两者优势, 编解码器均为 LSTM, 借逆序重构强化短期依赖学习, 凭重构误差评估, 适应信号不确定性与复杂性。

2025年, 马超智等人[32]提出一种基于“预训练+精调”框架的钢轨波磨识别方法, 充分利用车厢内部噪声数据进行建模, 在无标签数据上, 采用降噪卷积自编码器进行预训练, 提取车内噪声时频图的通用表征。在此基础上, 利用少量带标签样本进行监督学习, 以提升模型对不同类型波磨的判别能力, 整体模型以 ResNet-18 为编码与解码骨干, 分类器为全连接层。

3.4. 半监督模式

半监督检测通过少量已标注数据与大量未标注数据的协同学习, 可在降低标注成本的同时提升模型性能。

2021年, 赵宁等人[33]针对轨道几何时间序列异常样本稀缺、特征难提取的问题, 提出一种半监督检测方法, 利用里程注意力模块与属性注意力模块提取关键特征, 并通过多层全连接网络进行融合压缩, 将压缩后的特征输入分类器实现对轨道几何异常状态的检测。

2022年, 赵原野等人[34]针对标注样本稀少的轨道状态监测振动数据检测场景, 设计了一种半监督图注意力分类方法, 利用图注意力从里程信息和传感器属性两方面提取关键特征, 随后采用 GRU 捕获序列中的长期依赖, 最后通过全连接层完成状态检测。

4. 深度时间序列异常检测在轨道异常检测应用中的问题与展望

本文依据时间序列异常检测的学习任务类型进行分类介绍, 并综述了这些方法在高铁轨道异常检测中的具体应用。然而, 将基于深度学习的时间序列异常检测的成功范式直接应用于高铁轨道异常检测仍面临以下核心挑战: 一是多重扰动源的解耦问题, 高铁轨道振动数据是车辆荷载、轨道结构特性及环境干扰的耦合产物, 导致常规模型无法区分出哪部分波动真正源于轨道病害。二是微弱早期故障信号的增强与识别问题, 早期微弱故障信号易被列车高速运行中产生的强背景噪声掩盖, 难以触发检测机制。三是模型在不同线路和车型间的迁移性问题, 现有模型多基于单一线路或单一车型的数据集进行训练, 当

迁移到新场景时泛化能力受限。针对上述问题, 未来研究可从以下三个方面展开。

1) 物理信息神经网络(PINNs)融合。将车辆-轨道耦合动力学方程作为正则项引入损失函数, 借助先验物理知识约束模型学习, 提升对多重扰动源的解耦能力。

2) 多模态数据融合。结合车载摄像头采集的轨道表面图像与轨道振动数据, 通过跨模态注意力机制同步提取时序与空间特征, 以增强对早期细微损伤的敏感性。

3) 联邦学习与隐私计算。借助联邦学习框架, 各铁路运营单位可在保障数据隐私的同时, 共享模型权重与更新, 实现跨线路、跨车型的模型协同优化, 显著提升泛化能力并降低标注成本。

参考文献

- [1] 李宏锋. 地铁轨道波浪形磨耗检测系统研究[D]: [硕士学位论文]. 成都: 西南交通大学, 2014.
- [2] Hopkins, B.M. and Taheri, S. (2010) Track Health Monitoring Using Wavelets. *ASME 2010 Rail Transportation Division Fall Technical Conference*, Roanoke, 12-13 October 2010, 9-15. <https://doi.org/10.1115/rtdf2010-42004>
- [3] 周志青, 胡莺庆, 黄玉, 等. 基于支持向量机的轨道波磨检测方法研究[C]//中国振动工程学会. 第十三届全国振动理论及应用学术会议论文集. 2019: 193-197.
- [4] Li, J. and Shi, H. (2020) Rail Corrugation Diagnosis of High-Speed Railway Based on Dynamic Responses of the Vehicle. *2020 Prognostics and Health Management Conference (PHM-Besancon)*, Besancon, 4-7 May 2020, 148-152. <https://doi.org/10.1109/phm-besancon49106.2020.00031>
- [5] Pang, G., Shen, C., Cao, L. and Hengel, A.V.D. (2021) Deep Learning for Anomaly Detection. *ACM Computing Surveys*, **54**, 1-38. <https://doi.org/10.1145/3439950>
- [6] 段雪源, 付钰, 王坤. 基于VAE-WGAN的多维时间序列异常检测方法[J]. 通信学报, 2022, 43(3): 1-13.
- [7] Aggarwal, C.C. (2017) *Outlier Analysis*. Springer.
- [8] 陈红松, 刘新蕊, 陶子美, 等. 基于深度学习的时序数据异常检测研究综述[J]. 信息安全, 2025, 25(3): 364-391.
- [9] 石静雯, 侯立群. 基于一维卷积注意力门控循环网络和迁移学习的轴承故障诊断[J]. 振动与冲击, 2023, 42(3): 159-164+173.
- [10] 李雪艳, 苏博, 陈铭, 等. 基于双向LSTM自动编码器的新型无监督深度学习结构损伤识别[J/OL]. 计算力学学报, 1-8. <http://kns.cnki.net/kcms/detail/21.1373.o3.20250319.1610.004.html>, 2025-07-04.
- [11] 刘同干, 杨洪武, 陆晔, 等. 基于1D-2D-CNN-BiLSTM滚动轴承故障诊断[J]. 工业控制计算机, 2025, 38(5): 46-48.
- [12] Zamanzadeh Darban, Z., Webb, G.I., Pan, S., Aggarwal, C. and Salehi, M. (2024) Deep Learning for Time Series Anomaly Detection: A Survey. *ACM Computing Surveys*, **57**, 1-42. <https://doi.org/10.1145/3691338>
- [13] 尹春勇, 赵峰. 基于双层注意力和深度自编码器的时间序列异常检测模型[J]. 计算机工程与科学, 2024, 46(5): 826-835.
- [14] 陈世伟, 李静, 玄佳兴, 等. LSTM-GAN: 融合GAN和Bi-LSTM的无监督时间序列异常检测[J]. 小型微型计算机系统, 2024, 45(1): 123-131.
- [15] 蔡美玲, 汪家喜, 刘金平, 等. 基于Transformer GAN架构的多变量时间序列异常检测[J]. 中国科学: 信息科学, 2023, 53(5): 972-992.
- [16] Larese, D.C., Cerrada, A.B., Tomei, G.D., Guerrero-López, A., Olmos, P.M. and García, M.J.G. (2025) Transformer Vibration Forecasting for Advancing Rail Safety and Maintenance 4.0. arXiv: 2501.11730.
- [17] Gui, J., Chen, T., Zhang, J., Cao, Q., Sun, Z., Luo, H., et al. (2024) A Survey on Self-Supervised Learning: Algorithms, Applications, and Future Trends. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **46**, 9052-9071. <https://doi.org/10.1109/tpami.2024.3415112>
- [18] Shen, L., Li, Z. and Kwok, J.T. (2020) Timeseries Anomaly Detection Using Temporal Hierarchical One-Class Network. *Proceedings of the 34th International Conference on Neural Information Processing Systems (NIPS '20)*, Vancouver, 6-12 December 2020, 13016-13026.
- [19] Zerveas, G., Jayaraman, S., Patel, D., Bhamidipaty, A. and Eickhoff, C. (2021) A Transformer-Based Framework for Multivariate Time Series Representation Learning. *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, Singapore, 14-18 August 2021, 2114-2124. <https://doi.org/10.1145/3447548.3467401>

- [20] Li, K. and Lee, J. (2024) Self-Supervised Contrastive Representation Learning for Time-Series Classification. 2024 21st International SoC Design Conference (ISOCC), Sapporo, 19-22 August 2024, 1-2. <https://doi.org/10.1109/isocc62682.2024.10762741>
- [21] Audibert, J., Michiardi, P., Guyard, F., Marti, S. and Zuluaga, M.A. (2020) USAD: UniSuper-Vised Anomaly Detection on Multivariate Time Series. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, California, 6-10 July 2020, 3395-3404. <https://doi.org/10.1145/3394486.3403392>
- [22] Xu, J., Wu, H., Wang, J. and Long, M. (2021) Anomaly Transformer: Time Series Anomaly Detection with Association Discrepancy. arXiv.2110.02642.
- [23] Chen, M., Zhai, W., Zhu, S., Xu, L. and Sun, Y. (2021) Vibration-Based Damage Detection of Rail Fastener Using Fully Convolutional Networks. *Vehicle System Dynamics*, **60**, 2191-2210. <https://doi.org/10.1080/00423114.2021.1896010>
- [24] Xie, Q., Tao, G., He, B. and Wen, Z. (2022) Rail Corrugation Detection Using One-Dimensional Convolution Neural Network and Data-Driven Method. *Measurement*, **200**, Article 111624. <https://doi.org/10.1016/j.measurement.2022.111624>
- [25] Xie, Q., Tao, G., Lo, S.M., Yang, X. and Wen, Z. (2023) A Data-Driven Convolutional Regression Scheme for On-Board and Quantitative Detection of Rail Corrugation Roughness. *Wear*, **524**, Article 204770. <https://doi.org/10.1016/j.wear.2023.204770>
- [26] 彭佳宁, 池茂儒, 梁树林, 等. 基于特征融合变维卷积神经网络的高铁轮轨不良状态识别方法[J/OL]. 铁道标准设计, 1-13. <https://doi.org/10.13238/j.issn.1004-2954.202311120001>, 2025-07-05.
- [27] 徐文龙. 高铁轨道动检数据配准及异常检测算法研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2021.
- [28] Yuan, Z., Zhu, S., Chang, C., Yuan, X., Zhang, Q. and Zhai, W. (2021) An Unsupervised Method Based on Convolutional Variational Auto-Encoder and Anomaly Detection Algorithms for Light Rail Squat Localization. *Construction and Building Materials*, **313**, Article 125563. <https://doi.org/10.1016/j.conbuildmat.2021.125563>
- [29] 王思博. 基于 Transformer 的高铁动检数据异常检测与分类算法研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2023.
- [30] 杨森, 刘金朝, 刘钰, 等. 基于 Anomaly Transformer 的轨道几何不平顺异常检测方法[J]. 铁道学报, 2025, 47(6): 122-131.
- [31] Origlia, A., Di Martino, S. and Battista, E. (2023) Rail Anomalies Detection: A Comparative Analysis of Three Self-Supervised Models on Real Data. *Computers in Industry*, **148**, Article 103909. <https://doi.org/10.1016/j.compind.2023.103909>
- [32] 马超智, 王阳, 张淑芳, 等. 基于车厢内部噪声的地铁钢轨波磨自监督快速识别方法[J]. 振动与冲击, 2025, 44(6): 282-290.
- [33] 郑宁. 基于多源数据的高速铁路轨道几何异常状态检测方法研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2021.
- [34] 赵原野. 基于生成对抗网络的高铁轨道异常状态检测与分类方法研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2022.