

基于深度学习的道岔转辙机故障诊断技术研究综述

雷云鹏¹ 韩东² 涂鹏飞² 朱锁明²

(1. 郑州地铁集团有限公司运营分公司, 450008, 郑州; 2. 卡斯柯信号有限公司, 200071, 上海)

摘要 [目的]对基于深度学习的道岔转辙机故障诊断技术进行归纳总结,分析各种深度学习方法在转辙机故障诊断中的应用现状,探讨其优势与局限性,并提出未来研究方向。[方法]首先介绍了转辙机故障诊断的重要性及所面临的挑战,随后对比分析了模型驱动和数据驱动两种诊断方法的特点。接着详细阐述了基于深度神经网络、自动编码器、卷积神经网络、循环神经网络以及多深度模型混合的故障诊断方法,对比了不同方法的特点。最后讨论了当前研究的局限性,包括对大量标注数据的需求、模型复杂度与解释性等问题,并提出了几点未来研究方向。[结果及结论]基于深度学习的转辙机故障诊断技术展现出了强大的特征提取和数据处理能力,有效提升了故障诊断的准确性和效率。然而,现有的深度学习仍面临数据需求量大、模型复杂度高和解释性差等挑战。未来深度学习的研究应注重数据预处理技术、多源信息融合、不平衡小样本场景下的诊断方法、迁移故障诊断以及可解释性深度诊断模型等方面,以推动深度学习在转辙机故障诊断领域的广泛应用和智能化水平的提升。

关键词 轨道交通;道岔;转辙机;故障诊断;深度学习

中图分类号 U231.6;U213.6⁺1

DOI:10.16037/j.1007-869x.2024.12.059

A Review of Turnout Switch Machine Fault Diagnosis Technology Based on Deep Learning

LEI Yunpeng¹, HAN Dong², TU Pengfei², ZHU Suoming²

(1. Operation Branch of Zhengzhou Metro Group Co., Ltd., 450008, Zhengzhou, China; 2. CASCO Signal Co., Ltd., 200071, Shanghai, China)

Abstract [Objective] The turnout switch machine fault diagnosis techniques based on deep learning is summarized, the application status of various deep learning methods in turnout switch machine fault diagnosis is analyzed, their advantages and limitations are explored, and future research directions are proposed. [Method] The importance and challenges of turnout switch machine fault diagnosis are first introduced, followed by a comparative analysis of the characteristics of model-driven and data-driven diagnostic approaches. Then, fault di-

agnosis methods based on deep neural networks, autoencoders, convolutional neural networks, recurrent neural networks, and hybrid multi-deep models are elaborated in-depth, with comparisons of their respective performance characteristics. The limitations of current research, including the need for large amounts of labeled data, model complexity, and interpretability are discussed. Several future research directions are proposed.

[Result & Conclusion] Turnout switch machine fault diagnosis techniques based on deep learning demonstrate strong capabilities in feature extraction and data processing, significantly improving diagnostic accuracy and efficiency. However, current deep learning methods face challenges such as the requirement for large datasets, high model complexity, and limited interpretability. Future research should focus on data preprocessing techniques, multi-source information fusion, diagnosis methods for imbalanced and small sample scenarios, transfer fault diagnosis, and interpretable deep diagnostic models to enhance the wide application and intelligence level of deep learning in turnout switch machine fault diagnosis.

Key words rail transit; turnout; switch machine; fault diagnosis; deep learning

转辙机是轨道交通重要设备,受安装、环境、磨损等因素影响,可能出现运转不良或无法运行的问题,对行车安全和运营效率构成威胁。据统计,转辙机引发的故障在所有信号系统故障中占比高达30%^[1],需要专业人员进行及时的故障检测和诊断维护。

目前,转辙机故障诊断主要集中在转辙机动态特性,通过分析转辙机转动过程中的物理或电气特性参数曲线,来判断转辙机是否出现故障及故障类型。根据技术原理可将转辙机故障诊断方法分为模型驱动方法^[2-3]和数据驱动方法。由于转辙机类型多样、内部结构复杂,建立高精度、高鲁棒性和高泛化性的转辙机模型需要高昂成本^[4],因此基于模型的方法研究较少。而人工智能技术的兴起,推动了数据驱动方法的发展,尤其是基于深度学习的方法

法,因其强大的特征提取和数据处理能力,受到了广泛关注与研究。

1 转辙机故障诊断技术研究现状

对转辙机故障进行诊断时,通常依据微机监测系统采集的转辙机工作参数信息进行综合分析。诊断输入信息包括电流曲线、功率曲线、压力曲线、缺口变化曲线等监测数据,输出信息通常为转辙机当前的动作状态和故障类型。根据对数据的处理与应用方式不同,故障诊断技术可分为不同的类型^[5-6],如图 1 所示。

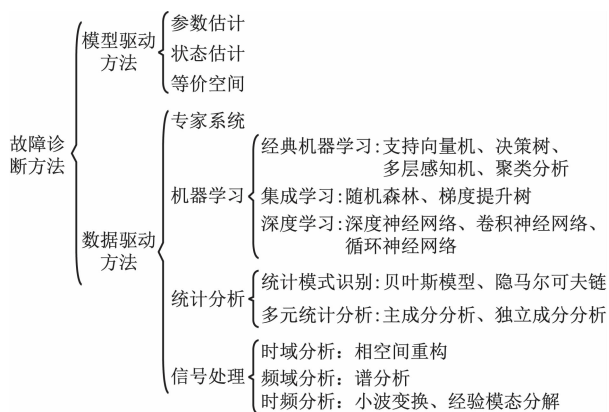


Fig. 1 Classification of fault diagnosis methods

模型驱动方法依赖于对象的解析模型^[7]。而转辙机设备的系统复杂性导致其解析模型难以建立,制约了模型驱动方法的应用^[8]。

数据驱动方法应用知识、数据和人工智能技术,通过推理和判断实现诊断功能。专家系统类方法由知识数据库和推理机制组成,需要大量专家经验难以适应复杂的实际运行环境。信号处理类方法利用统计模型、时频域等技术,从采集信号中提取能够反映设备运行状态的特征量,并根据特征量的变化分析设备的运行状态和故障。机器学习与统计分析类方法则是利用信号处理提取的故障状态特征数据训练模型,以自主完成诊断任务。然而,机器学习方法在特征工程方面过于依赖专家经验,导致研发成本居高不下。随着数据的积累与算力的提升,深度学习技术引起了学者们的关注,其克服了传统方法的缺陷,研究取得了大量成果。

2 基于深度学习的转辙机故障诊断方法

深度学习是一种基于多层网络结构的自动特

征学习方法,具有强大的自动特征提取和迁移能力,相比传统机器学习,摆脱了耗时的特征工程,且对非线性数据拟合能力更强。在转辙机故障诊断中,深度学习通过训练从海量数据中自动学习特征,并结合基本物理特征形成更抽象的特征,实现复杂功能的拟合。基于深度学习的故障诊断流程如图 2 所示。




图 2 基于深度学习的故障诊断流程

Fig. 2 Fault diagnosis process based on deep learnin

2.1 基于深度神经网络的方法

DNN(深度神经网络)是一种早期深度学习方方法,具有强大的非线性拟合能力,但其多层全连接层的结构导致模型参数过多、计算量庞大,严重降低训练效率。为解决此问题,文献[9]提出了逐层贪婪预训练受限玻尔兹曼机方法,即 DBN(深度信念网络)。

文献[10]基于转辙机音频信号,利用 DNN 实现故障分类,同时运用了 Xavier 权重初始化、ReLU(修正线性单元)激活函数和 Dropout(暂退法)等方法进一步提升模型精度。文献[11]利用 DBN 提取道岔功率原始数据特征,之后通过 ELM(极限学习机)进行故障分类,以提高诊断速度。随着新型深度学习模型的发展,这类方法的研究逐渐变少。

2.2 基于自动编码器的方法

AE(自动编码器)^[12]是一种无监督学习模型,由编码器和解码器组成。编码器用于将原始输入数据映射到隐藏层表达式,提取高维数据的特征并实现降维。解码器用于还原隐藏层中的原始输入数据,完成数据重构。在训练过程中,通过降低数据重构误差实现参数更新。

文献[13]提出了一种由 DCAE(深度卷积自编码器)和 LR(逻辑回归)模型结合的故障诊断方法,编码器负责从原始道岔电流曲线数据中自动提取特征,逻辑回归对提取的特征进行识别。文献[14-15]分别利用堆叠 AE 和深度 AE 提取转辙机转换曲线数据特征,并根据重构误差识别故障模式。为

解决缺少故障数据的问题,文献[16]提出了一种基于掩码自编码器的小样本深度学习模型,利用掩码自编码器进行数据扩充,损失函数联合掩码重构子网络误差、故障分类子网络误差以及故障定位子网络误差,共同引导自编码器从位置结构和拟合类别分布特征角度训练优化。

2.3 基于卷积神经网络的方法

CNN(卷积神经网络)是起源于图像处理领域的一种前馈神经网络,以其具有局部连接、权值共享和池化等特点,能够以较少的参数处理大规模数据。根据卷积核的维度,CNN可分为1D-CNN(一维CNN)、2D-CNN(二维CNN)和3D-CNN(三维CNN)。

在故障诊断领域,1D-CNN通常用于处理转辙机动作电流和功率曲线数据^[17-18]。例如,文献[18]采用1D-CNN对ZD6型转辙机不同过载条件下的电动机动作电流和电压等参数进行故障分析,其性能优于机器学习算法及DNN。2D-CNN则需将一维时间序列数据转换为二维矩阵数据,如将转辙机的时域电流信号^[19-20]或转动音频信号^[21]转换为二维灰度图像,并利用2D-CNN来识别不同故障类型。

2.4 基于循环神经网络的方法

RNN(循环神经网络)是一类隐藏层间相互连接的网络模型,可将过去的信息反映到当前状态并输出预测值^[22],因此在处理时间序列数据方面具有独特优势。RNN在不同时刻保持相同的网络结构并共享参数,从而降低了网络的复杂性。LSTM(长短期记忆网络)^[23]作为经典的RNN模型,解决了长序列训练中的梯度消失和爆炸问题。

多种研究方法利用LSTM分别根据转辙机转换扭矩信号和电流曲线进行故障分类^[24-25],并构建多层RNN模型以提高模型学习能力^[26]。此外,文献[27]引入Attention(注意力机制)以缓解时序模型对电流曲线长序列记忆力不足的问题;文献[28]通过利用ResNet50模型^[29]代替Vision Transformer^[30]模型中的故障图像分块机制进行特征提取,并结合位置编码,显著提升模型精度。

2.5 基于多深度模型混合的方法

为了进一步提升模型的性能,有学者尝试将多种深度学习模型进行组合,构建更复杂的深度网络。文献[31-33]结合CNN对数据局部特征提取和RNN对时间序列数据处理的优势,建立CNN-

RNN转辙机故障诊断模型。文献[34]使用DCDAE(深度卷积降噪自编码器)提取转辙机功率信号的高阶特征,再通过双向LSTM模型实现故障分类。

然而,这种多模型组合的策略并不一定能提高准确率,因为模型越复杂,所需要的训练数据量就越大。否则,更有可能导致模型过拟合。

2.6 综合对比

转辙机故障诊断方法的性能通常由精度、召回率、准确率和F1 score等指标^[35]评估。如表1所示,本综述中所提方法综合对比结果如下:DNN类方法作为早期深度学习模型,模型结构单一,其性能较低;AE类方法通过信号重构误差进行故障分类,适用于大量训练样本的场景;CNN类和RNN类方法分别从空间和时间角度自动提取数据深层特征,强大的特征提取能力使其在不同样本规模下均表现良好,同时通过与Attention等技术的结合,可进一步提升模型可辨别的故障类别数;多深度模型混合的方法由于模型结构复杂、容量高,在小样本规模场景下的性能相对较低,适用于样本规模大、故障类别多的复杂场景。

3 研究展望

3.1 当前研究局限性

基于深度学习的转辙机故障诊断方法不仅可以自适应地提取复杂多变的故障特征,而且克服了传统方法对诊断知识和工程经验的依赖,在精确识别常见故障现象方面取得了巨大成功,使已建立的智能故障诊断模型更加自动化和高效。然而,此类方法仍存在如下局限性:

1) 模型训练需要大量标注数据与硬件算力,训练成本较高。在实践中很难获得足够的故障样本,限制了模型的泛化性能。

2) 合理的网络结构设计需要花费大量时间,并且难以解释其工作原理。

3.2 未来发展路线

3.2.1 数据预处理技术

尽管深度学习可直接提取原始数据中的特征信息,但预处理技术能够降低模型的学习难度,减小算力需求,提高推理效率。因此,针对不同深度学习模型,开发适合的数据预处理方法以提升输入数据的质量是非常有意义的。

表 1 不同故障诊断方法综合对比结果

Tab. 1 Comprehensive comparison results of different fault diagnosis methods

文献	基本技术方案	转辙机类型	输入数据源	故障类型数量/个	数据集规模/个			性能评价	
					正常样本	故障样本	无标签样本	指标	结果
[10]	时频域特征提取 & DNN		音频曲线	3	150	140/140/150	0	准确率	93.10%
[11]	DBN-ELM	S700K	功率曲线	8	50	8 × 25	0	准确率	96.00%
[13]	DCAE-LR	S700K	电流曲线	8	20 000	7 × 500	0	准确率	99.52%
[14]	堆叠 AE		电流曲线	1	21 368	1 007	0	漏报率/误报率	0/0
[15]	深度 AE	S700K	电流曲线	3	350	150	19 104	漏报率/误报率	0/2.06%
[16]	掩码 AE	ZYJ7	电流曲线	6	7 905	40	0	准确率	98.70%
[17]	1D-CNN	HW1000	电流曲线	1	1 161	200	0	准确率/ 精确率/召回率	95.67%/95.73%/ 99.00%
[18]	小波变换-1D-CNN	ZD6	电流/电压/ 压力曲线	3	20	3 × 20	0	准确率	100.00%
[19]	2D-CNN		电流曲线	6	290	6 × 285	0	准确率	99.80%
[20]	2D-CNN		电流曲线	8	1 000	8 × 1 000	0	准确率	99.78%
[21]	2D-CNN	NSAM	音频曲线	3	150	142/141/155	0	F1 score	98.80%
[24]	LSTM		扭矩曲线	8				准确率	91.83%
[25]	LSTM		电流曲线					准确率	99.70%
[26]	双层 GRU	ZD6	电流曲线	7	150	7 × 150	0	准确率	98.00%
[27]	多层双向 LSTM-Attention	ZYJ7	电流曲线	11	800	11 × 200	0	准确率/漏报率/ 误报率	97.60%/0/2.60%
[28]	ResNet50-Vision Transformer	ZYJ7	电流曲线	6	1 152	117/186/114/ 209/229/237	0	准确率	99.77%
[31]	小波变换-CNN-GRU	S700K	电流/功率 曲线	7	20	7 × 20	0	准确率	95.00%
[32]	1DCNN-双向 LSTM	S700K	功率曲线	8	70	8 × 70	0	精确率/召回率/ F1 score/准确率	98.99%/98.89%/ 98.89%/97.88%
[33]	经验模态分解-1D-CNN-LSTM	S700K	功率曲线	5	1 500	5 × 1 500	0	准确率	99.28%
[34]	DCDAE-双向 LSTM	S700K	功率曲线	5	800	5 × 800	0	准确率/误报率/ 漏报率	98.82%/1.15%/ 1.17%

3.2.2 多源信息融合诊断

目前多数研究主要关注单一物理源信息与单一故障的诊断准确性。面对具有耦合性和并发性特征的转辙机故障时,多源信息能全面反映设备状态,因此需要进一步探索多源信息融合的方法,提高复杂故障的识别能力。

3.2.3 不平衡小样本场景下的故障诊断

由于实际工程中存在不平衡小样本场景,导致深度学习模型难以学习到有用的知识。尽管数据增强方法可以缓解不平衡问题,但仅靠少量样本生成的数据仍缺乏完备性。因此,将少样本或零样本

学习理论与故障诊断结合值得深入探索。

3.2.4 迁移故障诊断

由于转辙机类型不同、转辙机使用环境差异较大,同时缺乏不同场景下的标注样本,有必要提高模型对不同工况和不同类型转辙机的泛化能力,即迁移故障诊断。近年来迁移学习在多工况故障诊断方面取得了突破性进展。然而,当源域数据与目标域数据不平衡或目标域数据完全不可用时,如何设计迁移学习策略提升诊断模型的泛化性能仍是未来研究的重点。

3.2.5 可解释性的深度诊断模型

深度学习的“黑箱”效应使其在故障诊断应用中难以帮助用户理解诊断模型如何从监测数据中学习有用的故障知识。因此,研究深度学习的可解释性在工业应用场景中尤为重要。目前,可解释性方法的研究主要集中在网络计算过程、数据表征和自我解释等方面,但现有方法多针对单一模型与目标,如何将多种模型解释技术融合或设计与模型无关的解释方法仍存在巨大的探索空间。

4 结语

转辙机故障诊断技术是列车安全高效运行的重要保障。本文回顾了近年应用于转辙机故障诊断的深度学习算法,并对不同方法进行了比较与总结,最后提出了当前所面临的挑战和未来的研究方向。随着深度学习技术的不断完善和发展,终将实现可推广落地的转辙机故障智能诊断解决方案。

参考文献

- [1] 曹代刚. 道岔转辙设备维护[J]. 科技资讯, 2014, 12(4): 106.
CAO Daigang. Maintenance of turnout switch machines[J]. Science & Technology Information, 2014, 12(4): 106.
- [2] MCHUTCHON M A, STASZEWSKI W J, SCHMID F. Signal processing for remote condition monitoring of railway points[J]. Strain, 2005, 41(2): 71.
- [3] SHI Z, LIU Z, LEE J. An auto-associative residual based approach for railway point system fault detection and diagnosis[J]. Measurement, 2018, 119: 246.
- [4] HAMADACHE M, DUTTA S, OLABY O, et al. On the fault detection and diagnosis of railway switch and crossing systems: an overview[J]. Applied Sciences, 2019, 9(23): 5129.
- [5] 刘文涛, 黄子辉, 潘庆球, 等. 基于人工智能的道岔健康度评估方法与评估系统建设路径研究[J]. 城市轨道交通研究, 2020, 23(10): 149.
LIU Wentao, HUANG Zihui, PAN Qingqiu, et al. Evaluation method of turnout health and construction path of evaluation system based on artificial intelligence[J]. Urban Mass Transit, 2020, 23(10): 149.
- [6] DAI X, GAO Z. From model, signal to knowledge: a data-driven perspective of fault detection and diagnosis[J]. IEEE Transactions on Industrial Informatics, 2013, 9(4): 2226.
- [7] HAMADACHE M, DUTTA S, AMBUR R, et al. Residual-based fault detection method: application to railway switch & crossing (S&C) system[C]//2019 19th International Conference on Control, Automation and Systems (ICCAS). New York: IEEE, 2019: 1228.
- [8] CAI B, HUANG L, XIE M. Bayesian networks in fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2017, 13(5): 2227.
- [9] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527.
- [10] NOH B, LEE J, PARK D, et al. Anomaly classification of railway point machine using sound information and DNN[C]//Proceedings of the Korea Information Processing Society Conference. Jeju, Korea (South): Korea Information Processing Society, 2016: 611.
- [11] 司涌波, 张国瑞, 陈光武, 等. 基于深度置信网络的道岔故障智能诊断方法[J]. 重庆大学学报, 2023, 46(7): 75.
SI Yongbo, ZHANG Guorui, CHEN Guangwu, et al. An intelligent diagnosis method of switch machine based on deep belief network[J]. Journal of Chongqing University, 2023, 46(7): 75.
- [12] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533.
- [13] CHEN X, ZHANG G, DONG W, et al. A novel fault diagnosis method for high-speed railway turnout based on DCAE-logistic regression[C]//2020 3rd International Conference on Artificial Intelligence and Big Data (ICAIBD). New York: IEEE, 2020: 318.
- [14] GUO Z, YE H, DONG W, et al. A fault detection method for railway point machine operations based on stacked autoencoders[C]//2018 24th International Conference on Automation and Computing (ICAC). Newcastle Upon Tyne: IEEE, 2018: 1.
- [15] GUO Z, WAN Y, YE H. An unsupervised fault-detection method for railway turnouts[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(11): 8881.
- [16] 李刚, 徐长明, 龚翔, 等. 基于掩码自编码器的小样本深度学习道岔故障诊断模型[J]. 中国铁道科学, 2022, 43(6): 175.
LI Gang, XU Changming, GONG Xiang, et al. Few-shot deep learning on turnout fault diagnosis model based on masked autoencoder[J]. China Railway Science, 2022, 43(6): 175.
- [17] SACHAN S, DONCHAK N. Multi-segment deep convolution neural networks for classification of faults in sensors at railway point systems[C]//2019 25th International Conference on Automation and Computing (ICAC). Lancaster: IEEE, 2019: 1.
- [18] CHEN Q, NICHOLSON G, ROBERTS C, et al. Improved fault diagnosis of railway switch system using energy-based thresholding wavelets (EBTW) and neural networks[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3503312.
- [19] HUANG S, YANG L, ZHANG F, et al. Turnout fault diagnosis based on CNNs with self-generated samples[J]. Journal of Transportation Engineering, Part A: Systems, 2020, 146(9): 04020105.
- [20] ZHANG P, ZHANG G, DONG W, et al. Fault diagnosis of high-speed railway turnout based on convolutional neural network[C]//2018 24th International Conference on Automation and

- Computing (ICAC). Newcastle Upon Tyne: IEEE, 2018: 1.
- [21] CHOI Y, ATIF O, LEE J, et al. Noise-robust sound-event classification system with texture analysis[J]. Symmetry, 2018, 10(9): 402.
- [22] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015, 61: 85.
- [23] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735.
- [24] BRYAN K J, SOLOMON M, JENSEN E, et al. Classification of rail switch data using machine learning techniques[C]//Proceedings of 2018 Joint Rail Conference. Pittsburgh: The American Society of Mechanical Engineers, 2018.
- [25] 唐维华. 基于 LSTM/NN 的道岔故障特征提取与识别研究[J]. 计算机应用与软件, 2019, 36(1): 159.
- TANG Weihua. Extraction and recognition of switch machine fault features based on LSTM/NN[J]. Computer Applications and Software, 2019, 36(1): 159.
- [26] SHI X, DAI S. Fault prediction of turnout equipment based on double-layer gated recurrent unit neural network[C]//2021 IEEE International Intelligent Transportation Systems Conference (ITSC). Indianapolis: IEEE, 2021: 2336.
- [27] 陈海欢. 基于深度学习的电液式道岔转辙机故障诊断研究[D]. 成都: 西南交通大学, 2019.
- CHEN Haihuan. Research on fault diagnosis of electro-hydraulic switch machine based on deep learning[D]. Chengdu: Southwest Jiaotong University, 2019.
- [28] 王英琪, 李刚, 胡启正, 等. 基于改进 Vision Transformer 的道岔故障智能诊断[J/OL]. (2024-02-29) [2024-06-05]. https://kns.cnki.net/kcms2/article/abstract?v=hFA5SNlyt3gnukPUqnzDShSDZV3z-zBYHUTtNWXlc5IxJ1BFFDVKutDMYPox_s3gkScuuGf_5-qVgTkX4BLAZhjdJhnlkLkBXIM1-WneNAELeVNY-tZCf9Q_6eZigxa3-bHqosj8yVsZ_ibpqhwPk7Aw-Yt2ekjoZry-WGb0A8HlchIkVgZA-pnpw4UabXFFtjl&uniplatform=NZKPT&language=CHS.
- WANG Yingqi, LI Gang, HU Qizheng, et al. Intelligent diagnosis of turnout faults based on improved Vision Transformer[J/OL]. (2024-02-29) [2024-06-05]. https://kns.cnki.net/kcms2/article/abstract?v=hFA5SNlyt3gnukPUqnzDShSDZV3z-zBYHUTtNWXlc5IxJ1BFFDVKutDMYPox_s3gkScuuGf_5-qVgTkX4BLAZhjdJhnlkLkBXIM1-WneNAELeVNY-tZCf9Q_6eZigxa3-bHqosj8yVsZ_ibpqhwPk7Aw-Yt2ekjoZry-WGb0A8HlchIkVgZA-pnpw4UabXFFtjl&uniplatform=NZKPT&language=CHS.
- [29] KOONCE B. ResNet 50[M]//Convolutional neural networks with swift for Tensorflow. Berkeley, CA: Apress, 2021: 63-72.
- [30] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words; transformers for image recognition at scale[J/OL]. ArXiv e-Prints, 2020: arXiv: 2010.11929. <https://doi.org/10.48550/arXiv.2010.11929>
- [31] 杨菊花, 于苡健, 陈光武, 等. 基于 CNN-GRU 模型的道岔故障诊断算法研究[J]. 铁道学报, 2020, 42(7): 102.
- YANG Juhua, YU Yijian, CHEN Guangwu, et al. Research on turnout fault diagnosis algorithms based on CNN-GRU model[J]. Journal of the China Railway Society, 2020, 42(7): 102.
- [32] 王瑞峰, 李扬. 基于 1DCNN-BiLSTM 组合模型的 S700K 转辙机故障诊断[J]. 电子测量与仪器学报, 2022, 36(11): 193.
- WANG Ruifeng, LI Yang. Fault diagnosis of S700K switch machine based on 1DCNN-BiLSTM hybrid model[J]. Journal OF Electronic Measurement and Instrumentation, 2022, 36(11): 193.
- [33] 付雅婷, 温世明, 杨辉, 等. 基于多通道输入和 1DCNN-LSTM 的道岔转辙机故障诊断[J]. 铁道学报, 2023, 45(11): 98.
- FU Yating, WEN Shiming, YANG Hui, et al. Fault diagnosis of switch machine based on multi-channel input and 1DCNN-LSTM[J]. Journal of the China Railway Society, 2023, 45(11): 98.
- [34] 刘可兴, 黄海于. 基于 DCDAE-BiLSTM 模型的转辙机故障诊断方法研究[J]. 铁道通信信号, 2021, 57(8): 87.
- LIU Kexing, HUANG Haiyu. Research on switch fault diagnosis based on DCDAE-BiLSTM model[J]. Railway Signalling & Communication, 2021, 57(8): 87.
- [35] THARWAT A. Classification assessment methods[J]. Applied Computing and Informatics, 2021, 17(1): 168.
- [36] CHO K, VAN MERRIENBOER B, BAHDANAU D, et al. On the properties of neural machine translation: encoder-decoder approaches[J/OL]. (2024-09-03) [2024-06-05]. https://xueshu.baidu.com/s?wd=On+the+properties+of+neural+machine+translation%3A+encoder-decoder+approaches&tn=SE_baiduxueshu_c1gjeupa&ie=utf-8&sc_hit=1.
- 收稿日期:2024-07-17 修回日期:2024-08-20 出版日期:2024-12-10
Received:2024-07-17 Revised:2024-08-20 Published:2024-12-10
• 第一作者:雷云鹏,高级工程师,leiyunpeng@zzmetro.cn
通信作者:韩东,工程师,handong@casco.com.cn
• ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

欢迎订阅《城市轨道交通研究》
服务热线 021—56830728 转 821