

驶向智能未来:深度学习在轨道交通革新中的应用

孙宇墨, 李昕航, 赵文杰, 朱力, 梁雅楠

引用本文

孙宇墨, 李昕航, 赵文杰, 朱力, 梁雅楠. 驶向智能未来:深度学习在轨道交通革新中的应用[J]. 计算机科学, 2024, 51(8): 1-10.

SUN Yumo, LI Xinhang, ZHAO Wenjie, ZHU Li, LIANG Ya'nan. [Driving Towards Intelligent Future:The Application of Deep Learning in Rail Transit Innovation](#) [J]. Computer Science, 2024, 51(8): 1-10.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于注意力机制的CNN和BiGRU的加密流量分类](#)

Encrypted Traffic Classification of CNN and BiGRU Based on Self-attention
计算机科学, 2024, 51(8): 396-402. <https://doi.org/10.11896/jsjcx.230500032>

[时间敏感网络中的可变长整形队列调整算法](#)

Variable-length Shaping Queue Adjustment Algorithm in Time-sensitive Networks
计算机科学, 2024, 51(8): 354-363. <https://doi.org/10.11896/jsjcx.230500214>

[基于RNN信息累积的动态多目标优化算法](#)

Dynamic Multi-objective Optimization Algorithm Based on RNN Information Accumulation
计算机科学, 2024, 51(8): 333-344. <https://doi.org/10.11896/jsjcx.230500046>

[基于知识图谱与邻域感知注意力机制的推荐算法研究](#)

Study on Recommendation Algorithms Based on Knowledge Graph and Neighbor PerceptionAttention Mechanism
计算机科学, 2024, 51(8): 313-323. <https://doi.org/10.11896/jsjcx.230500143>

[传统机器学习模型的超参数优化技术评估](#)

Evaluation of Hyperparameter Optimization Techniques for Traditional Machine Learning Models
计算机科学, 2024, 51(8): 242-255. <https://doi.org/10.11896/jsjcx.230600164>

驶向智能未来:深度学习在轨道交通革新中的应用

孙宇墨 李昕航 赵文杰 朱力 梁雅楠

北京交通大学电子信息工程学院 北京 100044

(21211016@bjtu.edu.cn)

摘要 目前,轨道交通凭借其便利性、高效性等特点,在城市交通中扮演着重要角色。然而,现有轨道交通系统的运行过程也存在着复杂的问题,客流预测、列车调度等环节仍采用人工方式,效率和准确率均较低,对系统性能造成了一定影响。近年来,深度学习蓬勃发展,其强大的特征提取与图像识别能力,也为轨道交通的自动化、智能化发展提供了更多的可能性。文中首先阐述了当前轨道交通在现实生活各种应用场景中面临的挑战;其次从轨道交通感知任务、预测任务、优化任务等方面分析了深度学习赋能轨道交通领域的主要应用;最后,从高精度和高鲁棒性的安全性检测,轻量级的轨道交通模型,全自动的轨道交通智能化运行,以及借助云计算、大数据的信息处理高效化4个方面展望了未来深度学习在轨道交通中的发展方向。

关键词:深度学习;轨道交通;感知;预测;优化

中图分类号 TP181

Driving Towards Intelligent Future: The Application of Deep Learning in Rail Transit Innovation

SUN Yumo, LI Xinhang, ZHAO Wenjie, ZHU Li and LIANG Ya'nan

School of Electronic and Information Engineering, Beijing Jiaotong University, Beijing 100044, China

Abstract Nowadays, rail transit plays a crucial role in urban transportation due to its convenience and efficiency. However, the operation of existing rail transit systems faces complex challenges. Processes such as passenger flow prediction and train scheduling still rely on manual methods, leading to low efficiency and accuracy, which has a certain impact on the system's performance. In recent years, with the flourishing development of deep learning, its powerful feature extraction and image recognition capabilities provide more possibilities for the automation and intelligence of rail transit. This paper first outlines the challenges faced by current rail transit in various real-life scenarios, and then analyzes the main applications of deep learning in the rail transit field, including perception tasks, prediction tasks, optimization tasks, etc. Finally, the future development direction of deep learning in rail transit is prospected from four aspects: high-precision and robust safety detection, lightweight rail transit models, fully automated intelligent operation of rail transit, and efficient information processing through cloud computing and big data.

Keywords Deep learning, Rail transit, Perception, Prediction, Optimization

1 引言

目前,轨道交通凭借其无可替代的优点,在城市交通中扮演着重要角色。一方面,轨道交通系统能够提供庞大的客流量,具有较高的单向运输能力,为居民的出行提供了新的选择,同时缓解了城市交通拥堵问题;另一方面,轨道交通系统运行速度快,能够缩短乘客的出行时间,提高了客运效率。

然而,随着轨道交通建设速度的加快,轨道交通的不足之处也日益凸显。例如,轨道交通系统设备老化、维护不善可能造成设备损坏,从而引发列车故障,影响运行安全;此外,列车调度智能化程度不高,决策实时性不强,可能导致车辆、人力资源分配不均,影响系统运行效率;欠佳的列车行驶轨迹选择也会导致能源消耗较高。如果这些问题无法得到解决,则会造成严重的经济损失,给乘客的切身利益造成不利影响。

当今深度学习发展迅速,鉴于深度学习处理大规模复杂

数据的高效性和准确性,国内外学者已将深度学习应用于轨道交通的信息化发展。通过对近年来国内外研究人员在轨道交通方面深度学习应用的最新研究进行分析,并对这些研究所采用的深度学习技术与贡献进行归纳总结,能够对当前深度学习在轨道交通方面应用的前景有更为清晰的认识,从而明确轨道交通的未来发展方向。

本文首先概述了深度学习的主要内容;接着分析了轨道交通目前正面临的挑战,指出轨道交通潜在的改进空间;由此引出深度学习在轨道交通中的几大应用,并对几种主要的应用场景逐一进行分析;然后归纳上述应用中所暴露出的技术挑战,指出未来可能的发展方向;最后总结全文。

2 轨道交通所面临的挑战

本章概述传统的轨道交通系统在信息化时代发展所遇到的挑战,并指出传统的轨道交通中潜在的改进空间,以展示

深度学习的应用为轨道交通带来的新的活力。

2.1 现有问题与限制

本节将从感知、预测、优化 3 个方面分析传统的轨道交通系统在运作过程中遇到的问题与限制。

2.1.1 感知领域

目前,轨道交通系统的感知任务仍基于传感器、光学摄像机等传统感知设备,设备智能化程度低。传统感知设备在系统检测任务中仅发挥检测的基础功能,监控、监视等功能均需要人工检查,成本高、效率低且难以满足实时性的要求。

此外,当前已投入感知应用的深度学习技术效果仍不尽人意,感知模型仍存在定位出现误差、特征提取能力弱、建模能力弱等问题^[1-3],训练数据难以满足模型训练的需求^[2,4],导致感知能力不理想;此外,行人遮挡、恶劣天气等外部因素也会导致设备获取的图像、视频存在噪声,进而影响目标检测效果^[3,5-6]。

2.1.2 预测领域

当前轨道交通系统在预测方面的主要问题在于预测的准确性较低。轨道交通系统运行情况复杂,预测结果常受到天气、设备故障、相邻车辆等外部因素的影响。在对相应问题建立模型的过程中,外部因素的不确定性使得其对轨道交通运行情况的影响难以衡量、估计,进而降低了预测方法的准确性。以客流预测为例,城市轨道交通短时客流量的影响因素复杂,且客流本身具有随机性、非线性的特征,因此难以对短时客流量进行建模^[7-8]。

2.1.3 优化领域

当前,轨道交通优化任务面临的问题在于如何综合考虑多种因素得到最优解。在轨道交通领域,优化任务所需要解决的问题主要涉及轨道交通系统运行效率,如列车调度优化、列车行驶轨迹优化,但考虑到实际应用的可行性,资源利用率、乘客体验等因素对系统运行效率的间接影响也应该在建立的模型中得以体现。然而,能够综合多个因素进行求解的模型通常结构复杂,现有技术仍难以保证模型的求解效率。

2.2 潜在的改进空间

本节将从感知、预测、优化 3 个方面对现有轨道交通系统的潜在改进空间进行分析。

2.2.1 基于深度学习的感知能力改进

基于深度学习的感知方法通过自动提取图像特征和特征分类的方法对图像进行检测与分类,这些方法使用深度学习模型,如 CNN^[2-4,9],LSTM^[9-10],YOLO^[1-2,6],使得现有方法的感知效果得以增强。深度学习感知方法可应用于故障缺陷检测、位置检测、异常检测、信息系统入侵检测等轨道交通相关领域,借助深度学习强大的感知能力,有效提高安全性检测的效率和准确性。

2.2.2 基于深度学习的预测能力改进

基于深度学习的预测方法能够基于经验和历史数据对未来可能出现的情况进行建模。部分基于深度学习的非参数方法,如 DBN(Deep Belief Network)^[7,11]和 LSTM^[12-20],能够从客流数据中提取特征或相关性,而 BPNN(Back Propagation Neural Network)^[8,21]则适用于数据处理。深度学习的预测能力可应用于客流量预测、系统故障预测等方面,准确的客流量

预测有助于调度人员及时优化调度决策,提高系统运行效率;准确的系统故障预测能够提高维护、检修过程的效率,有效保障列车运行的安全性。

2.2.3 基于深度学习的优化任务改进

轨道交通系统中的优化任务主要是通过模拟系统运行过程中的真实场景,对真实场景中的参数进行改进,实现系统性能的提升。强化学习等技术为基于深度学习的轨道交通系统赋能,使系统的决策能力得到提升,以便系统获得解决问题的最佳策略。

3 深度学习在轨道交通中的应用

本章将结合最新的研究,从轨道交通系统的感知任务、预测任务、优化任务 3 方面对深度学习在轨道交通中的几项重要的应用成果进行阐述。

深度学习赋能轨道交通系统的主要应用如图 1 所示。

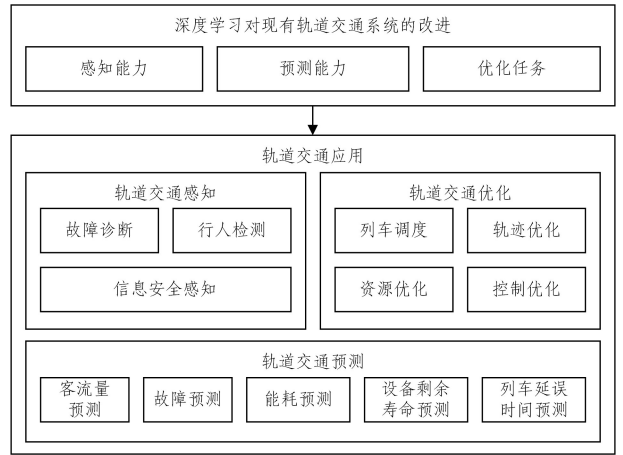


图 1 深度学习赋能轨道交通的应用

Fig. 1 Applications of rail transit empowered by deep learning

3.1 基于深度学习的感知任务

基于深度学习的感知任务主要包括故障诊断、行人检测与信息安全感知。

对于不同应用场景的感知任务,检测模型的性能指标有所不同。表 1 列出了检测模型的主要性能指标。

表 1 检测模型的主要性能指标

Table 1 Main performance indexes of detection model

性能指标	定义
准确率	被正确检测为目标样本数占总样本数的比例
召回率	被正确检测为目标样本数占总目标数的比例
收敛速度	模型训练过程中参数逼近最优解的速度
泛化能力	模型面对新数据时的预测能力
鲁棒性	模型对噪声等异常情况的处理能力

3.1.1 故障诊断

轨道交通系统基础设施的故障诊断对于整个系统运行的安全性和高效性而言至关重要。传统的轨道交通故障诊断方法,如人工巡检和视频监控等手段,对人力资源要求高,而深度学习的应用则解决了人力资源方面的问题。

CNN 和 YOLO 是主要用于图像分类和预测的深度学习模型,这两种模型对轨道故障均有良好的检测性能。

Rakshit 等^[4]采用图 2 所示的轨道故障检测系统,并对比

了 VGG, ResNet 和 InceptionV3 这 3 种 CNN 模型的检测精度。结果表明,即便是性能最差的 InceptionV3,其精度也高达 79%。

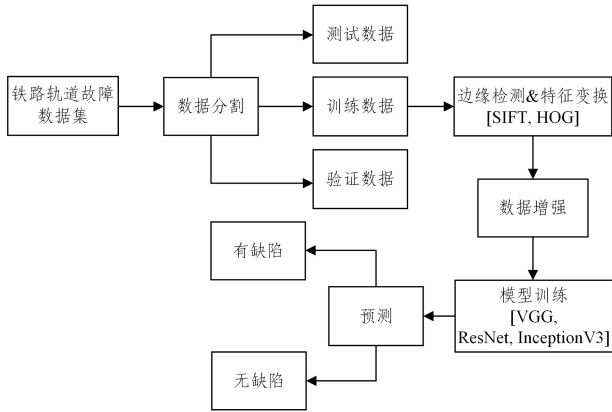


图 2 基于 CNN 模型的轨道故障检测系统结构

Fig. 2 Railway fault detection system architecture based on CNN model

YOLO 凭借更高的效率,逐渐成为受欢迎的一类 CNN 模型。YOLO 算法的设计理念为 You Only Look Once,该算

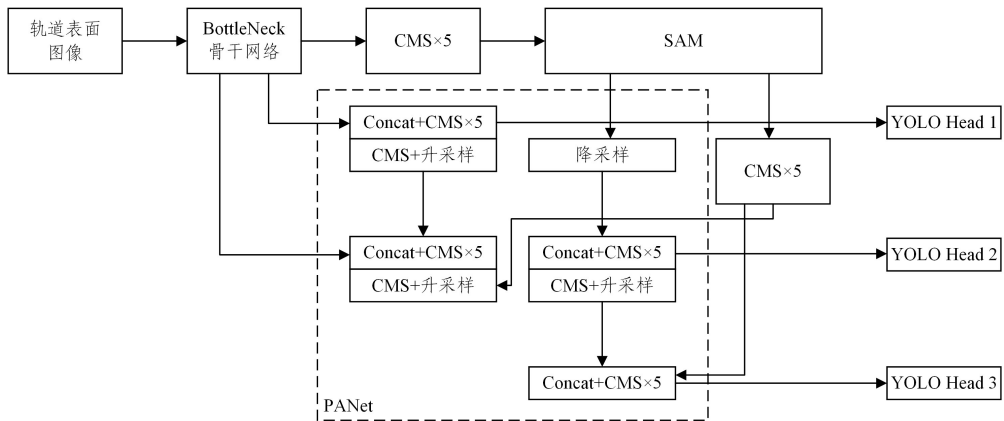


图 3 基于 YOLOv4 的轨道表面缺陷检测算法

Fig. 3 Defects detection algorithm of rail surfaces based on YOLOv4

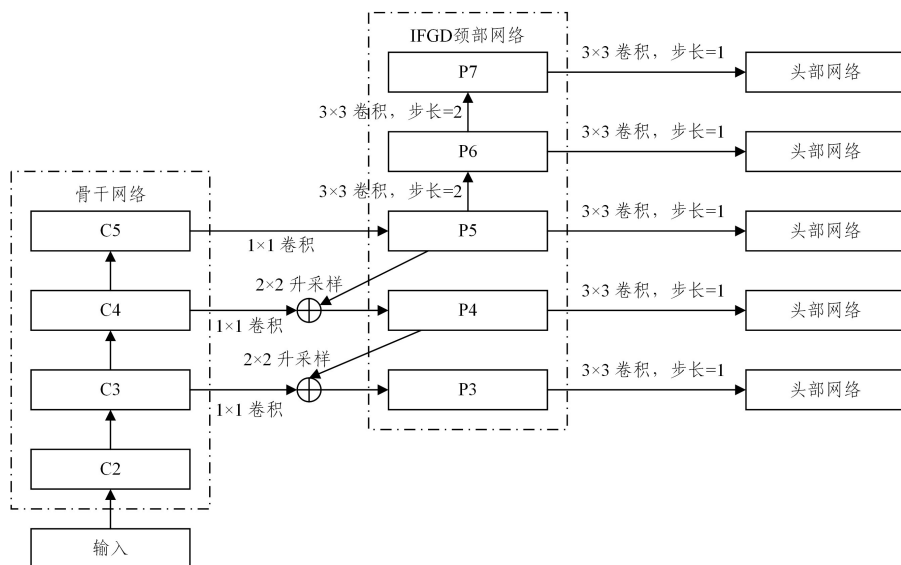


图 4 RFA-Net 结构

Fig. 4 Structure of RFA-Net

法采用单一的前向传递,即只对数据进行一次分类和回归,相较于其他检测算法的检测时间更短。基于这一特点, Lin 等采用 YOLOv3 模型对铁轨紧固件进行故障检测,结果表明该模型对包括缺陷紧固件在内的紧固件检测准确率和召回率分别高达 89% 和 95%^[1]。

针对 DCNN 缺陷检测中所存在的性能受限问题^[22], Anwar 等^[2]基于 YOLOv4 重新构建了检测系统,如图 3 所示。他们使用聚焦于逐点注意力机制的空间注意模块 (Spatial Attention Module, SAM) 作为模型附加模块,提升了模型的准确率和效率。

然而 YOLO 在实际应用中也存在问题。Ding 等^[6]基于 YOLOv5 的铁路异物入侵检测算法进行性能验证,发现该方法对于小尺寸异物和遮挡异物的检出率较低。

针对小尺寸物体检出率低的问题, Anwar 等将^[2]YOLOv4 的骨干模型结构替换为经 BottleNeck 修改的 CSP-Darknet-53,并使用 SELU 解决了梯度消失和爆炸问题,从而增强了模型对于小物体的学习能力。

Qin 等基于 RetinaNet^[23]提出了一种基于卷积神经网络的高鲁棒性检测算法 RFA-Net,该网络结构如图 4 所示。

该算法采用局部和全局知识蒸馏的方法,将鲁棒性较强的教师网络 ResNeXt-101 学习得到的特征信息传递给鲁棒性较弱的学生网络 ResNet-50。使用稳定的局部蒸馏,将图像的前景和背景分开处理,从而迫使学生网络关注关键的局部特征。研究表明,该方法提高了对小障碍物的检测精度,增强了模型对多尺度障碍物的感知能力,从而提高了检测模型的鲁棒性^[3]。

对于轨道交通系统整体异常检测,需要考虑设备数量多所导致的数据分布多样化问题。Wang 等^[10]提出基于 LSTM RNN 的时间序列异常检测。该方法将 LSTM 的遗忘门和输入门耦合成新模型的输入门,并增强了原 LSTM 模型中部分参数的影响,使模型获得了更好的学习和检测性能。通过非参数无监督学习方法动态确定误差阈值,并利用剪枝算法减少假异常的数量,解决了数据分布不均的问题。

3.1.2 行人检测

轨道交通系统的行人检测为客流预测提供了重要的历史、实时数据。然而,由于图像中行人尺度往往较小,其携带的信息也较少,因此目前行人检测方法在小尺度行人检测方面准确率仍然较低。

为降低小尺度行人的漏检率,同时提高检测精度,Zhang 等^[24]提出了 YOLOv4_I-DeepSORT 算法。该算法采用四倍下采样支路对 YOLOv4 网络进行改进,通过扩大感受野提取小尺度行人的特征信息,并利用 K-means++ 算法优化锚框参数,从而获得最佳的锚框尺度。

Zhang 等^[25]则从特征融合阶段的噪声干扰着手,引入坐标注意力机制(Coordinate Attention, CA),降低了特征图中背景噪声,从而增强了小尺度行人的特征信息。还将基础网络 YOLOv5s 中的 Ciou 损失函数扩展为 α -Ciou 损失函数,使模型聚焦于 IoU 值较高的目标框样本,提高了模型的检测性能。

3.1.3 轨道交通系统信息安全感知

随着轨道交通系统智能化水平的提高,信息安全问题逐渐引起研究人员的重视。当前,轨道交通系统的网络系统、控制系统仍较为脆弱,易遭受入侵者的攻击。

基于深度学习的入侵检测算法具有检测精度高、泛化能力强的特点。针对轨道交通网络系统的攻击行为,Wang 等使用层数更多、学习能力更强的 AlexNet 进行入侵检测。他们改进了 AlexNet 模型卷积层中的功能层,改变其原本先局部归一化再池化的顺序,将交叉熵损失函数作为模型误差函数,增强了模型的泛化能力。还引入 GRU 神经网络以缩短模型的收敛时间,使模型具有更快的检测速度^[9]。

针对 CBTC 系统中可能出现的数据可靠性和篡改、删除问题,Li 等^[26]结合区块链和 LSTM 网络实现了入侵检测。该研究将系统警报的哈希值存储于区块中以便链上所有节点访问,而 LSTM 模型则通过对正常和异常数据分类进行网络攻击检测。

3.2 基于深度学习的预测任务

预测能力是深度学习为轨道交通系统赋能的一大核心能力,预测结果是轨道交通运行过程中决策和规划的重要依据。

3.2.1 轨道交通系统客流量预测

轨道交通客流预测需要对客流数据的时间相关性进行提取,而传统基于 RNN 的客流预测无法对长期依赖关系进行有效捕捉。针对长期依赖问题,当前研究多采用 LSTM 网络进行客流预测。

表 2 对比了部分客流预测相关研究对深度学习技术的运用情况。从表中可见,许多研究将 LSTM 应用于轨道交通系统的客流量预测。LSTM 是循环神经网络 RNN 的一种专用于处理序列数据的变体,其引入长短时记忆单元以有效捕捉和学习时间序列中的长期依赖关系,因此能够有效解决涉及时间序列的客流预测问题。

表 2 深度学习赋能客流预测相关研究对比

Table 2 Comparison of researches on passenger flow prediction empowered by deep learning

文献	DL 技术运用	贡献
Cluster-Based LSTM Network for Short-Term Passenger Flow Forecasting in Urban Rail Transit	LSTM, BPTT, Adam 优化器	使用可预测性评估方法提高了模型的预测精度
Two-Stage OD Flow Prediction for Emergency in Urban Rail Transit	LSTM	实现了站点流入量的实时预测,并对数据进行了降维
Short term prediction of traffic flow based on deep learning	LSTM	提高了模型的收敛速度和预测精度
Deep Learning Architecture for Short-Term Passenger Flow Forecasting in Urban Rail Transit	ResNet, GCN, LSTM	克服了 GCN 网络多层堆叠造成的不利影响
Prediction of Passenger Flow in Urban Rail Transit Based on Big Data Analysis and Deep Learning	DBN	实现在随机性强、数据量大的数据集中更好的特征提取能力,同时保证了良好的预测性能
基于深度学习算法的城市轨道交通客流短时预测	BPNN, LSTM	提高了模型的收敛速度和学习效率,解决了传统 RNN 网络的长期依赖问题
Integrated Predicting Model for Daily Passenger Volume of Rail Transit Station Based on Neural Network and Markov Chain	BPNN	消除了系统随机性引起的预测误差
基于深度学习算法的城市轨道交通短时客流量预测	LSTM	提高了对短时客流量的拟合精度

为进一步提高 LSTM 的预测精度,许多研究基于 LSTM 提出了新的客流预测方法。Zhang 等^[12]采用两步 K-Means 聚类方法将空间相关性纳入考虑范围,提出结合 K-Means 聚类和 LSTM 的短时客流预测方法。该方法使用通过时间的

反向传播(Back Propagation Through Time, BPTT)和 Adam 优化器对模型的权重参数进行优化,最终取得了优于普通 LSTM 模型的预测效果。

Zhang 等^[13]使用小波去噪法对客流数据中的高频和

低频分量进行处理,对数据进行了充分利用。此外,他们对 LSTM 的神经元结构进行改进,使用时间相关特征通道和空间相关特征通道两个通道对客流分布的时间序列进行建模,提高了模型的收敛速度和预测精度,改善了模型的预测稳定性。

OD(Origin-Destination)客流量对预测实时旅客分布至关重要^[14],但 OD 客流维数高,预测过程计算复杂度大。对此,Zhu 等^[14]提出两阶段 OD 流量预测的思路,将 LSTM 应用于 OD 客流预测,从而实现了客流数据维度的下降。该研究把前往另一站点的进站乘客比例定义为分离率,提出了 SRI-A 和 SRI-B 两种模型,其中 SRI-A 直接使用一周前相同时间的分离率,SRI-B 使用线性回归模型减少历史分离率异常值的干扰。将这两种模型与基于深度学习的单阶段(Deep Learning based One-Stage, DL0S)模型进行对比,结果表明,SRI-B 模型具有最优的性能。

Zhang 等^[15]提出结合了 ResNet、GCN 和注意力机制 LSTM(Attention LSTM)的短时客流预测方法 ResLSTM,模型结构如图 5 所示。在该方法中,ResNet 用于捕获交通站点之间的深层抽象空间相关性,GCN 用于提取城市轨道交通网络拓扑信息,注意力机制 LSTM 用于提取时间相关性。此外,该模型考虑了天气条件和空气质量的影响,通过将影响量化的方式提高预测精度。

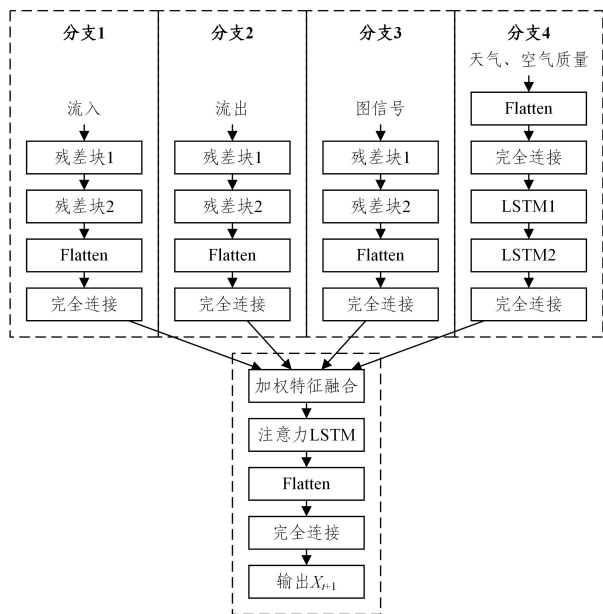


图 5 ResLSTM 模型结构

Fig. 5 Architecture of ResLSTM model

其他深度学习模型,如深度信念网络 DBN 和反向传播神经网络 BPNN,由于对系统随机性和非线性问题具有较好的处理能力,因此也被应用于客流量预测领域。

DBN 通过无监督加权和监督微调的方式训练模型权重,以保证从随机性强、数据量大的短时客流历史数据集中有效提取到特征。Zhu 等^[7]构建了下部为 DBN、上部为 SVM 的客流预测模型 DL-SVM,其中下部 DBN 的特征提取能力为上部 SVM 的预测任务提供支持。

Xiao 等^[8]则提出了基于 BPNN 和马尔可夫链的客流预测方法。BPNN 能够通过自适应和自学习特性处理非线性数据,马尔可夫链用于消除系统随机性引起的预测误差,从而对

BPNN 的预测结果进行修正,实现较高的预测精度。

3.2.2 轨道交通系统故障预测

轨道交通系统内设备故障是系统安全性的一大威胁。除感知任务中的故障诊断外,基于设备相关的物理参数或历史故障数据对未来可能发生的故障进行预测也是预防故障的重要手段。

深度学习模型,如长短时记忆网络 LSTM,为系统故障预测提供了更高效、更准确的预测方法。LSTM 克服了传统 RNN 的长期依赖问题和梯度消失、爆炸问题,对于时间序列依赖性和非线性关系具有更强的捕获能力。

然而,LSTM 对参数依赖问题较为敏感,选择的参数适当与否会直接影响其预测性能^[16]。Gao 等^[16]采用飞蛾扑火优化(Moth-Flame Optimization, MFO)算法对模型中的超参数进行如图 6 所示的优化,克服了基于经验的参数选择导致的模型低性能,提高了模型的泛化能力。

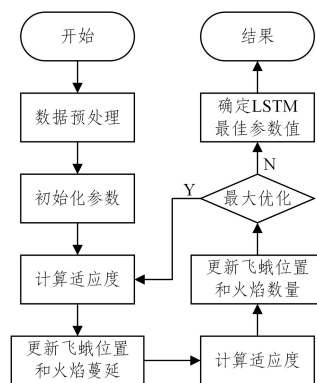


图 6 MFO-LSTM 算法流程图

Fig. 6 Flow chart of MFO-LSTM algorithm

Li 等提出牵引变压器同步多点温度预测,使用多对多映射类型的 LSTM 以同时预测三相绕组的多前步温度(Multi-forward-step Temperature),并利用 Dropout 和早停法防止参数相关性导致的模型过拟合,提高了模型的鲁棒性和泛化能力^[17]。

针对当前车载设备故障预测领域少有可靠方法的问题,Peng 等^[18]基于 LSTM 构建了具有编码器-解码器结构的 Seq2Seq 模型。该方法使用时间序列生成器从历史故障数据中捕捉未来故障发生时间的可能特征并将特征输入 Seq2Seq,Seq2Seq 模型利用编码器层和解码器层寻找特征与故障发生时间的关系,线性层则用于预测并输出结果。

3.2.3 设备剩余寿命预测

设备剩余寿命反映轨道交通系统的安全性,在设备的检修维护过程中不可忽视。基于深度学习的剩余寿命预测方法自动分析设备自身信息并提供高准确性的预测结果。

列车车门滚动销(Rolling Pin)是车门系统的关键部件,但由于关于滚动销寿命的研究较少,因此能够用于表征其寿命的数据量少。Gan 等^[27]使用具有注意力机制的双向门控循环单元 BiGRU 替换传统 CNN 模型中最后的卷积层,使得新模型同时具备 CNN 的特征提取能力和 BiGRU 的信息保留能力,BiGRU 的注意力机制能够防止重要信息遗漏,从而提高了模型处理小样本问题的能力。

重载铁路列车车轮的工作条件复杂,导致车轮损坏模型

建立困难。Bai 等^[19]结合能够提取不同尺度特征的 MDCNN 和 MDLSTM 模型,在不同条件下提取列车车轮的多尺度特征,改善了传统 CNN 的自适应性,减少了单尺度模型在训练过程中受到的局部极小值的影响,提高了预测准确性。

3.2.4 列车延误时间预测

列车延误会对轨道交通系统的运行效率造成不利影响,因此针对延误时间的预测任务至关重要。目前已有相关研究将深度学习应用于列车延误预测中,但所提出的算法存在泛化能力弱^[28]、学习时间长、计算量大^[29]等问题。

Chen 等^[28]提出了基于多模态深度学习框架的延误预测模型 TCF-Net。该模型结合了 Transformer,3D CNN 和 FCNN 3 种模型,其中使用多头注意力机制的 Transformer 用于提取与时间序列因素相关的特征,3D CNN 通过 3D 卷积核提取与时空依赖性相关的高维特征,FCNN 则用于从 Transformer 和 3D CNN 中提取特征。结合了多个模型的 TCF-Net 同时考虑了列车运行的时空特征和时间序列特征,具有更强的泛化能力。

针对模型学习时间长、计算量大的问题,Boateng 等^[29]将多层感知器 MLP 作为元学习器,异构神经网络 ANN,CNN 和 DNN 作为提取特征的子模型构建了使用堆叠集成学习技术的列车延误预测模型。通过剪枝算法删除了重要性低的元素,保证了模型的轻量级,从而缩短了模型的学习时间。剪枝堆叠模型的工作过程如图 7 所示。

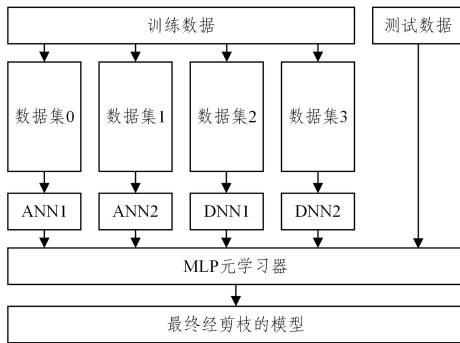


图 7 剪枝堆叠模型工作过程

Fig. 7 Procedure of pruned stacking model

3.2.5 城市轨道交通系统能耗预测

城市轨道交通系统能耗量与系统运行效率紧密相关,能耗越低获得的经济效益越高。能耗预测有助于发现并优化系统中的高能耗部分,是当前降低系统能耗的重要手段。然而,影响城市轨道交通系统能耗的因素多且不易确定^[20],从而增加了深度学习的应用难度。

Ha 等^[21]结合 BPNN 和灰度相关分析,提出了基于 BPNN 的能耗预测方法。该方法利用 BPNN 强大的非线性映射能力和自适应能力,保证了模型良好的预测性能,同时通过灰度相关分析确定系统能耗的主要影响因素,实现了模型的简化,从而降低了计算复杂度。

Tesar 等^[20]提出数据驱动的黑盒方法对能源需求进行在线计算。该黑盒方法采用微观建模和介观建模两种方式对多因素影响的轨道车辆牵引能量需求进行建模。Tesar 等分别比较了 MLN,CNN 和 LSTM 的预测性能,以及不同的采样频率和建模方式对预测结果的影响,最终发现使用 1 Hz 的

采样频率和 MLN 的架构能够实现最好的预测效果,且介观建模在计算时间方面优于微观建模。

3.3 轨道交通优化

优化任务在轨道交通系统的正常运行过程中发挥着重要作用。正常运行的轨道交通系统必须时刻保证较高的运行效率和资源利用率,从而提高服务水平,改善乘客的出行体验。而基于深度学习的轨道交通优化使用人工智能方法对列车调度、控制、决策等领域现有的不足之处进行改善,有效提高了轨道交通系统多方面的综合性能。

针对复杂的轨道交通优化问题,强化学习由于在复杂环境中具有较强的学习能力和智能体决策的高实时性受到了相关研究人员的青睐^[30]。在深度学习领域,深度神经网络的深度强化学习(Deep Reinforcement Learning,DRL)能够处理更为复杂的优化问题,因此成为解决轨道交通优化问题的关键技术。

3.3.1 列车时刻表重调度优化

列车时刻表重调度(Train Timetable Rescheduling,TTR)指轨道交通系统运行过程中列车运行组织的指挥工作,主要针对列车时刻表进行优化。准确高效的 TTR 对轨道交通系统的高效运行和安全性的改善都起着重要作用。

由于列车调度对于实时性的高要求、调度过程中扰动出现的不确定性、调度问题具有较多的局部最优解等,TTR 优化问题较为复杂。因此,当前相关研究多使用善于处理复杂优化问题的 DRL 技术,如 DQN、Actor-Critic^[31]、KL 惩罚^[31]和策略梯度方法^[30]。

减少列车延误时间是 TTR 优化的目标之一。DQN 结合了深度神经网络和 Q 学习,具有强大的搜索和学习能力。Ning 等^[32]采用 DQN 处理列车延误最小化问题。通过学习智能体调整列车的出发时间、停留时间和发车顺序,该方法明显减少了列车平均总延误时间,取得了较好的优化效果。Obara 等^[33]构建图来表达双轨铁路和主要的重调度技术,以 DQN 为一个智能体,通过确定性算法,使图逐步变形为使节点延迟最小的状态,从而在确保列车调度灵活性的同时,实现对列车延误时间的优化。Wu 等^[34]结合了 Double DQN 和 Dueling DQN 的优点,使用 Dueling Double DQN(DDDQN)作为列车延误优化模型解决了 Q 值高估的问题,从而避免了潜在冲突,减少了列车延误时间。DDDQN 的工作方法如图 8 所示。

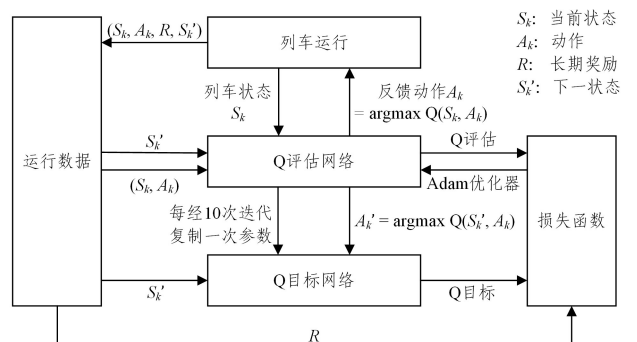


图 8 基于 Q 评估网络和 Q 目标网络的列车延误优化

Fig. 8 Train delay optimization based on Q-evaluate and Q-objective networks

Q 学习通常用于状态空间和动作空间离散的情况,而

难以处理连续高维动作空间的问题。在状态空间和动作空间连续的情况下,通常使用 Actor-Critic 算法。Yang 等^[30]将深度确定性策略梯度(Deep Deterministic Policy Gradient, DDPG)算法应用于以能源为导向的列车时刻表重调度(Energy-aimed Train Timetable Rescheduling, ETTR)问题。DDPG 属于 Actor-Critic 算法,同样具有连续的状态空间和动作空间,因此能够处理随机连续扰动并采取连续动作。DDPG 在处理 ETTR 问题时能够在保证节能效果的同时具有更高的实时性,解决了传统遗传算法计算时间过长的问題。

然而 DDPG 在训练过程中也存在稳定性差、学习效率低的问题。Liao 等^[31]使用策略梯度方法对 Actor 网络和 Critic 网络的参数进行更新,并采用自适应 KL 惩罚进行稳定有效的模型训练。与传统的遗传算法相比,该算法能够在随机干扰下自适应地调整列车的滑行速度和停留时间,具有较好的实时性;相较于 DDPG 算法,该算法更为稳定高效,同时表现出更好的节能效果。

3.3.2 列车轨迹优化

列车轨迹优化指生成最佳行驶轨迹的过程,是列车智能自动运行的关键技术。理想的列车行驶轨迹能够避免行驶过程中不确定干扰的影响,从而减少能耗,改善乘客乘坐体验。

列车轨迹优化需要对列车行驶轨迹的综合效益进行评估,因此应该综合考虑包行车效率、节能性、乘客体验等多方面因素。

Li 等^[35]综合考虑了节能、乘坐舒适性、正点性、安全性等因素的重要性,并使用物理量描述这些因素,最终被反映为模型的奖励。此外,针对列车运行过程中的不确定扰动,Li 等采用 Supervisor-Actor-Critic 架构进行模型训练,提高了模型在不确定扰动下在线调整行程时间的适应性,从而提高列车轨迹的综合效益。

Wei 等^[36]同样使用物理量描述准时性、能耗、乘坐舒适性等评估因素,并使用这些物理量定义奖励函数。他们采用包含密集奖励的 DQN,以再生制动能量(Regenerative Braking Energy, RBE)利用率最大化为目标对列车速度轨迹进行优化。该方法选择能耗作为即时奖励从而使模型更加关注节能,并使用列车的准点性、精准停车和乘车舒适性定义智能体

的最终奖励,从而使最终得出的优化轨迹满足多重要求。

Ning 等^[37]提出了基于 DDPG 的列车轨迹优化方法。DDPG 能够学习约束和动作之间的非线性关系,因此能够满足在复杂约束下实时生成高质量解的需求。该方法还提出了分配运行时间和选择运行模式(Allocating Running Time and Selecting Operating Mode, ARTSOM)算法,通过启发式地为不同路段分配合适的运行时间,并选择适当的列车控制模式,生成可行的轨迹以加快 DDPG 的训练过程。

3.3.3 轨道交通系统计算、通信资源分配优化

针对城市轨道交通云系统资源分配数据维度过高的问题, Li 等^[38]根据实际轨道交通服务的特征对 DQN 中的状态、动作、奖励进行定义,提出了基于 DQN 的轨道交通云系统资源分配方法。该方法通过函数逼近克服维数灾难,降低了系统的整体时延,提高了城市轨道交通服务的准确性。

基于列车到列车(Train-to-Train, T2T)通信的列控系统采用 T2T 通信和列车到轨旁(Train-to-Wayside, T2W)通信共存的通信方式,这种方式存在频谱资源有限的问题,且传统的频谱复用会带来同频干扰,影响系统服务质量。为减少同频干扰的发生, Zhao 等^[39]提出了多智能体深度强化学习(Multi-Agent Deep Reinforcement Learning, MADRL)方法。在该方法中,多个智能体独立与环境交互并选择动作以实现分布式资源分配机制。为获得更多的奖励,智能体学习选择最大传输功率以提高 T2T 链路的吞吐量,同时学习减少系统中的同频干扰。

针对智能交通系统车载网络中的信道分配和功率控制问题, Yu 等^[40]提出了基于联邦多智能体深度强化学习(Federated Multi-Agent Deep Reinforcement Learning, Fed-MARL)的分布式资源分配方案。如图 9 所示,该方法将每个车与车间(Vehicle-to-Vehicle, V2V)链路都建模为 RL 智能体,并根据智能体对信道条件和干扰的观察训练本地模型。通过引入联邦学习对 DQN 和近端策略优化(Proximal Policy Optimization, PPO)进行增强,智能体能够共享本地模型参数,从而有效增加训练数据量。研究结果表明,该方法同时提高了 V2V 链路的有效负载传输率和车与基础设施(Vehicle-to-Infrastructure, V2I)间链路的总容量。

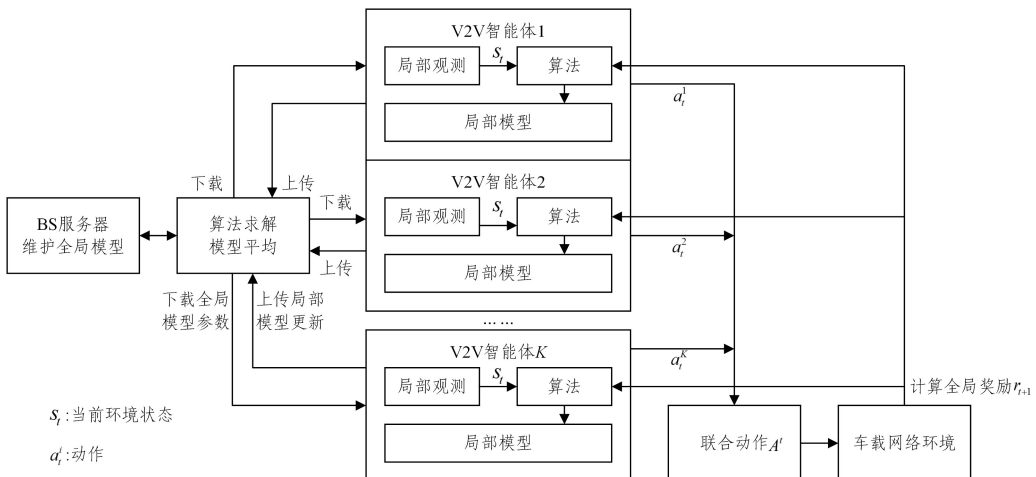


图9 Fed-MARL 结构

Fig. 9 Structure of Fed-MARL

3.3.4 控制优化

深度学习在列车控制领域也有所应用。基于 DRL, 部分相关领域研究针对当前列车控制的不足提出了优化方案。

为消除磁悬浮控制系统中系统扰动对控制性能的影响, Sun 等^[41]利用 Actor-Critic 和径向基函数(Radial Basis Function, RBF)神经网络学习无模型在线学习的优势, 提出了一种基于深度强化学习的非线性积分滑模控制器(Sliding Mode Controller, SMC)方法。在该方法中, RBF 网络一方面利用万能逼近原理对 Actor 的策略函数和 Critic 的价值函数进行逼近, 另一方面为 Actor 和 Critic 提供输入层和隐藏层的共享。与传统的 PID 控制器相比, 该方法具有更强的适应性和鲁棒性。

一些列车控制相关研究将控制过程表述为马尔可夫决策过程(Markov Decision Process, MDP), 以便 DRL 的应用。

Wang 等^[42]将 DQN 应用于节能列车控制方法的优化。该方法将节能列车控制问题表述为一个可以通过 RL 处理的 MDP, 利用 DQN 逼近最优动作值函数解决大状态空间 MDP 问题, 从而在不使用列车动力学先验知识和预先设计的速度曲线的情况下实现列车控制。

Liu 等^[43]将重载列车在长陡下坡上的循环空气制动策略定义为 MDP, 并根据列车运行约束和优化目标定义了问题的状态、动作、奖励。为避免 Q 值高估问题, 他们基于 DDQN 构建了以解决循环空气制动控制问题为目标的重载列车智能控制方法, 从而提升了优化模型的性能。

4 未来可能的发展方向

4.1 高精度和高鲁棒性的轨道交通感知

列车的安全行驶是当前轨道交通关注的重点。目前, 深度学习的图像检测能力已被应用于轨道交通系统的安全性检测中。然而, 目前基于深度学习的轨道交通安全性检测在复杂环境下鲁棒性较低, 从而导致图像检测的精度不高。因此, 提高深度学习模型在复杂环境下的鲁棒性是未来值得研究的方向。

4.2 轻量级的轨道交通模型

基于轨道交通情景开发的深度学习模型仍因参数大、结构复杂而面临多种限制, 如计算资源需求量大、计算速度较低、移动端应用受限。在轨道交通系统对实时性要求加强以及移动端、边缘计算等技术广泛应用的背景下, 应用于轨道交通系统的深度学习模型必然趋于轻量化。通过精简模型的结构, 深度学习能够应用于移动设备、边缘设备, 同时模型可保证在提高计算速度的同时减少计算资源需求量。

4.3 全自动的轨道交通智能化运行

随着人工智能的进步, 自动化已成为轨道交通发展的大势所趋。在人工智能技术应用越来越普遍的现在, 可以预见基于深度学习的轨道交通系统全自动运行将是未来轨道交通的发展方向。全自动运行系统(Fully Automatic Operation, FAO)是一种稳定的、价格合理的、高效的轨道交通系统^[44], 基于通信网络、数据采集、自动化等技术实现了轨道交通系统的全过程自动化^[45], 是新兴的轨道交通概念。目前, FAO

系统面临图像视频清晰度低、数据传输占用带宽大、数据处理能力低等问题。通过基于深度学习的图像增强、算法优化等技术, 研究人员能应对这些挑战, 并推动深度学习在轨道交通各领域的广泛应用。

4.4 借助云计算、大数据的信息处理高效化

轨道交通系统的运行效率决定了系统的综合效益, 它是衡量轨道交通系统实用性的重要指标。借助当前迅猛发展的云计算、大数据技术, 轨道交通系统能够将信息发送至云端进行分析, 再通过大规模机器型通信(Massive Machine Type Communication, mMTC)将信息处理结果传回系统内的设备, 从而更高效地处理交通信息。

结束语 随着轨道交通建设速度的加快, 传统轨道交通系统的不足之处凸显, 而近年来新兴的深度学习技术能够对轨道交通的信息化发展起到推动作用。

首先, 本文从感知、预测、优化 3 个方面概述了目前传统轨道交通系统所面临的挑战。其次, 分别围绕感知任务、预测任务、优化任务中存在的问题介绍深度学习在轨道交通方面应用的相关研究进展。其中, 深度学习感知任务可细化为故障诊断、行人检测、轨道交通系统信息安全感知; 预测任务可细化为客流量预测、故障预测、设备剩余寿命预测、列车延误时间预测与系统能耗预测; 优化任务可细化为列车时刻表重调度优化、列车轨迹优化、系统计算通信资源分配优化、控制优化。在感知任务方面, 研究主要采用 CNN 和 YOLO 等检测模型, 并提出了对这两种模型准确率、召回率、泛化能力等性能指标的改进方法, 实现了模型检测性能的提升; 在预测任务方面, 由于轨道交通系统预测对象多为长时间序列, 因此研究多采用能够捕捉长期依赖关系的 LSTM 模型; 在优化任务方面, DQN, Actor-Critic 等 DRL 技术由于在复杂环境中的强学习能力和智能体决策的高实时性受到相关研究的青睐。

最后, 从高精度和高鲁棒性的轨道交通感知、轻量级的轨道交通模型、全自动的轨道交通智能化运行、借助云计算和大数据的信息处理高效化 4 个方向展望了深度学习在轨道交通中未来的应用。总体来说, 本文对近年来深度学习在轨道交通领域的应用进行了综述, 总结了相关研究提出的深度学习方法以及未来可能的发展方向。

参考文献

- [1] LIN Y W, HSIEH C C, HUANG W H, et al. Railway track fasteners fault detection using deep learning[C]// 2019 IEEE Eurasia Conference on IOT, Communication and Engineering (ECICE). IEEE, 2019: 187-190.
- [2] ANWAR N, SHEN Z, WEI Q L, et al. YOLOv4 based deep learning algorithm for defects detection and classification of rail surfaces[C]// 2021 IEEE International Intelligent Transportation Systems Conference(ITSC). IEEE, 2021: 1616-1620.
- [3] QIN Y L, HE D Q, JIN Z Z, et al. An improved deep learning algorithm for obstacle detection in complex rail transit environments[J]. IEEE Sensors Journal, 2024; 24(3): 4011-4022.
- [4] RAKSHIT S, SANDEEP B S. Railway Track Fault Detection using Deep Neural Networks[C]// 2022 IEEE 6th Conference

- on Information and Communication Technology(CICT). IEEE, 2022;1-5.
- [5] GUO W P, WANG H, MAO L N, et al. Research on Deep Learning-based Deraining Method of Catenary Images [C] // 2021 IEEE 2nd China International Youth Conference on Electrical Engineering(CIYCEE). 2021;1-5.
- [6] DING X W, CAI X N, ZHANG Z Y, et al. Railway foreign object intrusion detection based on deep learning[C]//2022 International Conference on Computer Engineering and Artificial Intelligence(ICCEAI). IEEE, 2022;735-739.
- [7] ZHU K E, XUN P, LI W, et al. Prediction of passenger flow in urban rail transit based on big data analysis and deep learning [J]. IEEE Access, 2019, 7:142272-142279.
- [8] XIAO Z S, MAO B H, ZHANG T. Integrated predicting model for daily passenger volume of rail transit station based on neural network and Markov chain [C] // 2018 IEEE 3rd International Conference on Cloud Computing and Big Data Analysis(ICCCB-DA). IEEE, 2018;578-583.
- [9] WANG Z R, XIE X Z, CHEN L, et al. Intrusion detection and network information security based on deep learning algorithm in urban rail transit management system[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(2):2135-2143.
- [10] WANG Y J, DU X, LU Z H, et al. Improved LSTM-based time-series anomaly detection in rail transit operation environments [J]. IEEE Transactions on Industrial Informatics, 2022, 18(12):9027-9036.
- [11] ZHANG Y, HAN J Z, LIU J, et al. Safety prediction of rail transit system based on deep learning[C]//2017 IEEE/ACIS 16th International Conference on Computer and Information Science (ICIS). IEEE, 2017;851-856.
- [12] ZHANG J L, CHEN F, SHEN Q. Cluster-based LSTM network for short-term passenger flow forecasting in urban rail transit [J]. IEEE Access, 2019, 7:147653-147671.
- [13] ZHANG Y, WANG Q R. Short term prediction of traffic flow based on deep learning[C]//2020 International Conference on Virtual Reality and Intelligent Systems(ICVRIS). IEEE, 2020;982-985.
- [14] ZHU G Y, DING J C, WEI Y, et al. Two-stage OD flow prediction for emergency in urban rail transit[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 25(1):920-928.
- [15] ZHANG J L, CHEN F, CUI Z Y, et al. Deep learning architecture for short-term passenger flow forecasting in urban rail transit[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22(11):7004-7014.
- [16] GAO H L, SHI J Q, BAO C Q, et al. Fault prediction of track circuit compensation capacitor based on MFO-LSTM[C]//2023 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes(SAFEPROCESS). IEEE, 2023;1-5.
- [17] LI C, CHEN J, XUE C J, et al. Simultaneous Multi-Spot Temperature Prediction of Traction Transformer in Urban Rail Transit Using Long Short-Term Memory Networks[J]. IEEE Transactions on Transportation Electrification, 2023, 9(3):4552-4561.
- [18] PENG C, SHANGGUAN W, CAI B G, et al. Fault prediction method for on-board equipment of CTCS based on Seq2Seq model using LSTM[C]//2021 Global Reliability and Prognostics and Health Management(PHM-Nanjing). IEEE, 2021;1-5.
- [19] BAI Y H, LI H H, ZHAO S, et al. Remaining Useful Life Prediction of Wheel of Heavy-duty Railway Train based on Dual Channel Multi-scale Deep convolution Multi-scale Deep Long Short-Term Memory network[C]//2022 Global Reliability and Prognostics and Health Management(PHM-Yantai). IEEE, 2022;1-8.
- [20] TESAR M, MÜLLER-BROICH S, HILMER L, et al. Predicting traction energy demand of a light rail vehicle using deep learning methods[C]//2021 IEEE Vehicle Power and Propulsion Conference(VPPC). IEEE, 2021;1-5.
- [21] HA J B, ZHOU W P. Research on Energy Consumption Prediction of Urban Rail Transit Based on Data Mining[C]//7th International Conference on Information Science, Computer Technology and Transportation(ISCTT 2022). VDE, 2022;1-4.
- [22] YUAN H, CHEN H, LIU S W, et al. A deep convolutional neural network for detection of rail surface defect[C]//2019 IEEE Vehicle Power and Propulsion Conference(VPPC). IEEE, 2019;1-4.
- [23] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C] // Proceedings of the IEEE International Conference on Computer Vision. 2017;2980-2988.
- [24] ZHANG H, XU J, ZHANG X W. Pedestrian tracking and counting based on YOLOv4 and DeepSORT in Subway Stations [C] // 2023 35th Chinese Control and Decision Conference (CCDC). IEEE, 2023;732-737.
- [25] ZHANG Z H, MENG W W, LI Z, et al. A Small-Scale Pedestrian Detection Method in Railway Scene[C]//2022 IEEE 5th International Conference on Electronics and Communication Engineering(ICECE). IEEE, 2022;188-192.
- [26] LI Q C, ZHAO J Y. An Intrusion Detection Method for CBTC Systems Using Blockchain and LSTM[C]//2023 3rd Asia-Pacific Conference on Communications Technology and Computer Science(ACCTCS). IEEE, 2023;609-612.
- [27] GAN Y F, LU N Y, ZHANG B L, et al. A CNN-BiGRU Based Life Prediction Method for Rolling Pins of Rail Vehicle Door System[C]//2023 6th International Symposium on Autonomous Systems(ISAS). IEEE, 2023;1-5.
- [28] CHEN S, WU X T, ZHOU M, et al. Train delay prediction based on a multimodal deep-learning method[C]//2021 China Automation Congress(CAC). IEEE, 2021;3241-3246.
- [29] BOATENG V A, YANG B. A Global Modeling Pruning Ensemble Stacking With Deep Learning and Neural Network Meta-Learner for Passenger Train Delay Prediction[J]. IEEE Access, 2023, 11:62605-62615.
- [30] YANG G, ZHANG F, GONG C, et al. Application of a deep deterministic policy gradient algorithm for energy-aimed timetable rescheduling problem[J]. Energies, 2019, 12(18):3461.
- [31] LIAO J L, YANG G, ZHANG S W, et al. A deep reinforcement learning approach for the energy-aimed train timetable resche-

- duling problem under disturbances[J]. IEEE Transactions on Transportation Electrification, 2021, 7(4): 3096-3109.
- [32] NING L B, LI Y D, ZHOU M, et al. A deep reinforcement learning approach to high-speed train timetable rescheduling under disturbances[C] // 2019 IEEE Intelligent Transportation Systems Conference(ITSC). IEEE, 2019: 3469-3474.
- [33] OBARA M, KASHIYAMA T, SEKIMOTO Y. Deep reinforcement learning approach for train rescheduling utilizing graph theory[C] // 2018 IEEE International Conference on Big Data (Big Data). IEEE, 2018: 4525-4533.
- [34] WU W, YIN J T, PU F, et al. A deep reinforcement learning approach for the traffic management of high-speed railways[C] // 2021 IEEE International Intelligent Transportation Systems Conference(ITSC). IEEE, 2021: 2368-2373.
- [35] LI G N, OR S W, CHAN K W. Intelligent energy-efficient train trajectory optimization approach based on supervised reinforcement learning for urban rail transits[J]. IEEE Access, 2023, 11: 31508-31521.
- [36] WEI W B, WANG X M. Trajectory Optimization for Urban Rail Transit Considering Regenerative Energy Utilization: A Reinforcement Learning Approach [C] // 2022 China Automation Congress(CAC). IEEE, 2022: 300-305.
- [37] NING L B, ZHOU M, HOU Z P, et al. Deep deterministic policy gradient for high-speed train trajectory optimization[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(8): 11562-11574.
- [38] LI Z H, ZHU L, LI Y, et al. A deep reinforcement learning based resource allocation method for urban rail transit cloud systems[C] // 2021 IEEE International Intelligent Transportation Systems Conference(ITSC). IEEE, 2021: 3922-3926.
- [39] ZHAO J H, ZHANG Y, NIE Y W, et al. Intelligent resource allocation for train-to-train communication: A multi-agent deep reinforcement learning approach[J]. IEEE Access, 2020, 8: 8032-8040.
- [40] YU J M, WU S C, LIANG L, et al. Resource Allocation in Vehicular Networks Based on Federated Multi-Agent Reinforcement Learning[C] // 2023 IEEE 23rd International Conference on Communication Technology(ICCT). IEEE, 2023: 84-89.
- [41] SUN Y G, XU J Q, CHEN C, et al. A deep reinforcement learning based control approach for suspension systems of maglev trains[C] // 2020 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence(IC-SMD). IEEE, 2020: 496-501.
- [42] WANG C, LIU W T, TIAN Q H, et al. An energy-efficient train control approach based on deep Q-network methodology[C] // 2020 IEEE 23rd International Conference on Intelligent Transportation Systems(ITSC). IEEE, 2020: 1-6.
- [43] LIU W T, SU S, TANG T. An intelligent control approach for heavy haul trains using deep reinforcement learning[C] // 2021 IEEE 17th International Conference on Automation Science and Engineering(CASE). IEEE, 2021: 2262-2267.
- [44] HOU Z W, BAO F, DU Z X, et al. Research on operation control model of FAO system under compound-fault scene in urban rail transit[J]. Systems Science & Control Engineering, 2018, 6(2): 32-36.
- [45] HE C C, YAN F. Research on Fault Prediction of Fully Automatic Operation System Based on Ontology and Bayesian Network[C] // 2022 34th Chinese Control and Decision Conference (CCDC). IEEE, 2022: 1434-1439.



SUN Yumo, born in 2003, undergraduate. His main research interests include deep learning and communication engineering.



ZHU Li, born in 1984, professor, Ph.D supervisor. His main research interests include train control systems and autonomous train operation.

(责任编辑:何杨)