

基于 LSTM 预测误差的轨道交通弓网 接触力异常识别算法*

杨劲松 邵 奇 刘金朝 陶 凯 郭剑峰 彭 楠

(中国铁道科学研究院集团有限公司基础设施检测研究所, 100081, 北京)

摘 要 [目的]接触力是轨道交通弓网综合检测的重要内容,也是弓网系统性能的重要评价因素,但在检测过程中常受到外部环境的影响而出现异常检测数据。目前针对弓网接触力异常检测数据的剔除主要依赖于人工,影响数据分析效率,因此需深入研究弓网接触力异常识别算法。[方法]梳理了弓网接触力常见的异常形式,分析了不同异常形式下接触力检测数据的特征。提出了一种基于 LSTM(长短期记忆网络)预测误差的弓网接触力异常识别算法,通过使用正常的接触力数据训练 LSTM 模型,使该模型能够对接触力变化趋势进行预测。为实现正常区段与异常点的精确划分,使用基于置信区间的异常检测数据识别方法。为降低长距离异常数据对 LSTM 模型预测效果的影响,提出了一种基于预测值置换的异常数据处理方式。通过高速综合检测列车测得的真实检测数据,分别对三种常见异常形式的弓网接触力识别效果进行验证。[结果及结论]提出的算法能够较好地实现对弓网接触力异常的识别。

关键词 轨道交通;弓网接触力异常识别算法;LSTM 预测误差

中图分类号 U225.1

DOI:10.16037/j.1007-869x.2024.08.013

Identification Algorithm of Rail Transit Pantograph-catenary Contact Force Abnormality Based on LSTM Prediction Error

YANG Jinsong, SHAO Qi, LIU Jinzhao, TAO Kai, GUO Jianfeng, PENG Nan

(Infrastructure Inspection Research Institute, China Academy of Railway Sciences Group Co., Ltd., 100081, Beijing, China)

Abstract [Objective] Contact force is a crucial aspect of comprehensive detection in the rail transit PC (pantograph-catenary) system and serves as an important evaluation factor of PC system performance. However, during the detection process, the external environment factors often lead to abnormal detection data. Currently, the elimination of abnormal PC contact force detection data mainly relies on manual methods,

which affect data analysis efficiency. Therefore, there is a need to conduct in-depth research on an identification algorithm for PC contact force abnormality in PC system. [Method] The common abnormal forms of PC contact force are categorized, and the characteristics of contact force detection data under different abnormal conditions are analyzed. An identification algorithm for PC contact force abnormality based on LSTM (long short-term memory) prediction error is proposed. Using normal contact force data to train an LSTM model enables it to predict the trend of contact force variations. To achieve precise differentiation between normal segments and abnormal points, an abnormal data detection method based on the confidence interval is used. To mitigate the impact of long-distance abnormal data on LSTM model prediction performance, a prediction value replacement method for handling abnormal data is proposed. The effectiveness of identifying three common abnormal forms of PC contact force is verified using real detection data obtained from high-speed comprehensive inspection trains. [Result & Conclusion] Research results show that the proposed algorithm can effectively identify abnormalities in the PC contact force.

Key words rail transit; identification algorithm of pantograph-catenary contact force abnormality; LSTM prediction error

无论在城市轨道交通还是高速铁路中,为保障车辆运行安全,通过及时有效的检测手段掌握接触网状态具有重要意义。在铁路接触网状态检测中,传统的人工检测逐步被专业化检测装备检测取代。弓网接触力是由受电弓和接触线接触时所产生的作用力,作为一项重要的指标综合反映弓网受流性能^[1-2]。为提高弓网受流的可靠性,需保证弓网接触力在标准范围内,进而保障行车安全。

2016 年 9 月起,接触网 CQI(运行质量指数)

* 中国国家铁路集团有限公司科技研究开发计划项目(K2020Z002)

在轨道交通全路网使用,作为接触网质量评价的重要参考。CQI 充分利用弓网检测装置的数据,能够实现对接触网质量的定量描述。在 CQI 计算过程中,弓网接触力是一项重要指标,但由于检测装备自身稳定性以及外部电磁环境复杂等原因,会造成弓网接触力检测数据出现异常,对 CQI 计算造成严重影响,导致对接触网质量评价出现偏差。

弓网接触力异常数据的产生原因较为复杂,表现形式多样,目前主要根据专家经验采用人工筛查的方法来剔除异常值,这严重影响了弓网检测数据的分析效率;同时由于对专家经验的依赖性,处理结果存在较大的主观性。因此,找到一种弓网接触力检测数据异常的自动识别、剔除方法,对于接触网检测数据分析和接触网区段质量评价具有重要意义。

1 异常数据识别研究现状

异常数据自动识别的研究已有一定的进展,其中信号处理技术是异常数据识别的重要方法。文献[3]为剔除风电监测数据中的弃风数据,在风电机组的标准风数据基础上,依据正态分布的均值和标准差提出了黏滞区间的概念以及一种弃风数据剔除方法。文献[4]基于 Copula 理论提出一种利用 Copula 函数建立风速与功率间关联,结合异常数据特征完成异常数据识别的方法。文献[5]针对热工过程中监测数据,提出了一种异常数据的识别算法,即采用局部离群因子方法对各数据求取其局部异常值。文献[6]为提高现有风电场数据采集系统的准确性,采用 DBM(深层玻尔兹曼机)、EMD(经验模态分解)及 HMM(隐马尔科夫)相融合的方法,达到对异常风速值进行自适应检测的目的。文献[7]针对铁路轨道几何检测数据中存在冲击噪声的问题,利用小波分析方法将数据中冲击噪声的高频、低频成分进行分离。

近年来,基于机器学习和深度学习的方法在异常数据识别领域的应用越来越广泛^[8-9]。在工程领域,存在很大一部分传感器监测数据为时间序列类数据,时间序列类深度学习算法为处理传感器监测数据提供了新的思路。Hopfield 在 1982 年提出的 RNN(递归神经网络)是一种能够考虑时间序列中时间相关性的深度神经网络。相比于 RNN,LSTM(长短期记忆网络)克服了训练过程中存在的梯度爆炸和梯度消失等问题。根据现有技术,对异常数据进行识别主要可以分为基于信号处理的算法以

及基于机器学习和深度学习算法两个方向。针对时间序列类数据的处理,LSTM 模型应用较为广泛。由于弓网接触力异常情况多样,因此很难通过识别固定的时频特征对其实现识别。弓网接触力检测数据是一种时间序列数据,且当前弓网接触力的大小与前面一段时间范围内的检测数据存在较为明显的关联,因此,本文通过选用 LSTM 模型学习正常数据的波动规律来实现异常数据的检测。

2 弓网接触力异常形式

接触网通过接触线定位装置来调整其与受电弓碳滑板的接触点位置,使接触点往复移动保证碳滑板磨耗均匀。弓网接触力的大小与接触网和受电弓碳滑板的接触点位置有关,正常情况下接触点位置是左右连续滑动的,因此某时刻弓网接触力的大小与其前面一段时间范围内的弓网接触力测量值存在一定的相关性。正常的检测数据是在一定范围内波动变化的,而异常区段数据不存在此种变化规律。

对弓网接触力进行检测时,检测设备或电磁环境的干扰会造成弓网接触力检测数据出现异常。通过分析梳理检测数据异常情况,按照其异常的表现形式,本文将弓网接触力异常情况分为三类,分别是单点异常、拉直线异常及区段异常。其中:单点异常是指检测数据中某个数据点数值远远高于或低于其周边的检测数据,拉直线异常是指连续多个数据点为相同值,区段异常是指在一个连续区段内检测数据的波动频率和变化规律明显区别于其他区段。弓网接触力异常形式示意图如图 1 所示。

3 基于 LSTM 预测误差的弓网接触力异常识别模型

3.1 LSTM 模型

LSTM 的特点在于设计了遗忘门、输入门及输出门三个门结构,每个门结构相当于一个独立的全连接神经网络,其中:遗忘门用于舍弃和保留时间序列中的部分信息;输入门的作用在于根据遗忘门得到的状态信息将时间序列前一时刻的信息与当前输入信息相结合,从而产生新的状态信息;输出门的作用在于得到当前时刻的输出值。

从 LSTM 模型中可以看出其非常适合用于处理与时间序列高度相关的问题,与 RNN 相比,LSTM




图1 弓网接触力异常形式示意图

Fig. 1 Diagram of pantograph-catenary contact force abnormal forms


能够更好地学习时间序列中的长期依赖关系。根据正常弓网接触力检测数据的波动过程与其变化趋势存在较强依赖关系的特点,可以通过 LSTM 实现对弓网接触力变化趋势的预测。

3.2 基于 LSTM 预测误差的弓网接触力异常识别模型

目前,接触网中两条接触线固定装置间的距离通常为 50 m,弓网接触力检测数据的采集频率为每米 4 个数据点,因此选择 200 个数据点为时间序列长度进行预测。输入 LSTM 模型的时间序列长度为 200。时间序列输入方式如图 2 所示。

为了提高弓网接触力异常识别模型的预测效果,经试验对比在本算法中采取 3 层 LSTM 结构。不同层级 LSTM 采用的隐藏层节点数如表 1 所示。

弓网接触力异常识别模型分成训练阶段和测试识别阶段。基于 LSTM 预测偏差的弓网接触力异常识别模型算法流程,如图 3 所示。在训练阶段使用正常检测数据对 LSTM 进行训练,使网络能够



注: X 为输入序列; h 为隐含层输出序列。

图2 时间序列输入方式

Fig. 2 Data sequence input method

表1 不同层级 LSTM 采用的隐藏层节点数

Tab. 1 Number of hidden level nodes adopted by different LSTM levels

LSTM 层级	隐藏层节点数/个	时间序列	
		输入	输出
LSTM1	100	(1,200)	(100,200)
LSTM2	20	(100,200)	(20,200)
LSTM3	1	(20,200)	(1,1)

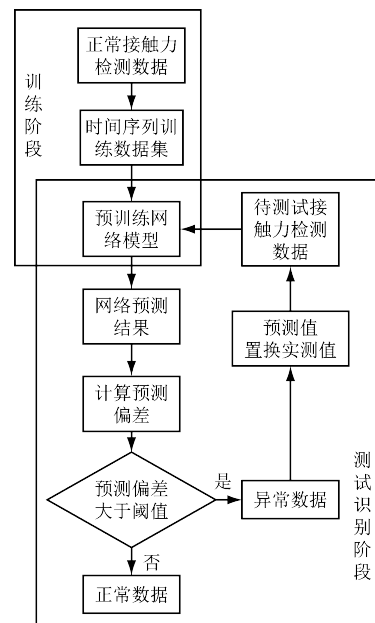


图3 基于 LSTM 预测偏差的弓网接触力异常识别模型算法流程图

Fig. 3 Algorithm flow chart of pantograph-catenary contact force abnormality identification model based on LSTM prediction deviation


学习检测数据的变化规律。测试时将待测试信号输入网络,由于异常数据不满足正常数据的变化规律,将导致较大的预测误差。异常数据可以通过网络的预测误差来判断测试数据是否正常。

若时间序列中异常数据的存在,会影响弓网接触力异常识别模型对后续时间序列的预测,为降低长距离异常数据对该模型预测效果的影响,提出了

一种基于预测值置换的异常数据处理方式。通过在异常区段使用预测值替代实测值,降低了异常数据对弓网接触力异常识别模型预测的影响,实现预

测值与实测值的融合。具体流程如下:

具体而言,将弓网接触力检测数据采用移动滑窗的方式处理为时间序列训练集,如图 4 所示。



注: T_n 为第 n 个采样点的接触力。

图 4 数据集构建流程图

Fig. 4 Flow chart of data set construction

选取 201 个检测数据作为一个窗口长度,将窗口中前 200 个检测数据作为模型输入,第 201 个数据点作为预测标签,随着窗口的移动可以得到时间序列训练数据集。

利用由正常数据组成的时间序列数据集训练 LSTM,作为预训练模型。

在测试阶段,为判断待测试弓网接触力数据中的第 m ($m \geq 200$) 个数据点 T_m 是否正常,选取第 m 个数据点前 200 个数据点 $T_{m-200} \sim T_{m-1}$ 作为模型输入, LSTM 的输出作为第 m 个数据点 T_m 的预测值 T_{pm} 。通过预训练, LSTM 模型已掌握正常弓网接触力检测数据沿时间维度的变化规律。因此,如果第 m 个数据点 T_m 为正常数据点,其与 LSTM 模型的预测值应当十分接近,但如果该数据点出现了异常, LSTM 将出现较大的预测误差。

假设 LSTM 模型的预测误差服从平均值 μ 、标准偏差 σ 的正态分布,则其整体数据平均值的 $(1 - \alpha) \times 100\%$ 置信区间为 $(\mu - Z_{\alpha/2}\sigma, \mu + Z_{\alpha/2}\sigma)$ (α 为显著性水平, $Z_{\alpha/2}$ 为相应的标准分数)。若预测误差 $T_{pm} - T_m$ 在上述置信区间内,可认为该数据点为正常值,否则为异常值。

4 LSTM 模型验证

为验证本文提出的基于 LSTM 预测误差的弓网接触力异常识别模型的准确性,本文利用综合检测列车采集到的真实弓网接触力检测数据进行了模型训练和验证。

选取一段检测中的正常数据用于 LSTM 模型训练,将检测数据划分为训练集和测试集,通过训练使 LSTM 模型能够学习到弓网接触力检测数据的变化规律。弓网接触力在 LSTM 模型下的训练与预测结果如图 5 所示。




图 5 弓网接触力在 LSTM 模型下的训练与预测结果

Fig. 5 Training and prediction results of pantograph-catenary contact force under LSTM model

由图 5 可以看出: LSTM 模型能够很好地预测弓网接触力检测数据的变化规律,可将其作为预训练模型进行弓网接触力异常数据识别。

利用上述得到的预训练模型分别对单点异常、拉直线异常及区段异常等三种形式的异常数据进行识别。弓网接触力异常数据识别结果如图 6 所示。由图 6 可以看出:蓝色矩形框内的预测误差大于阈值范围,由此可见,通过预测误差能够较好地实现对异常数据区段的识别。

5 结语

1) 本文通过对弓网接触力异常形式的梳理,将弓网接触力异常划分为单点异常、拉直线异常及区段异常等三种形式,根据这三种异常形式在变化趋势上与正常检测数据存在区别的特性,提出了一种基于 LSTM 预测误差的弓网接触力异常识别模型。

2) 提出了一种基于预测值置换的异常数据处理方式。通过在弓网接触力异常区段使用预测值替代实测值,降低了长距离异常数据对 LSTM 模型预测效果的影响,实现了预测值与实测值的融合。




图6 弓网接触力异常数据识别结果

Fig.6 Identification results of pantograph-catenary contact force abnormal data

3) 通过高速综合检测列车测得的检测数据分别对三种弓网接触力异常形式的识别效果进行了验证,结果表明本文提出的方法能够较好地实现对弓网接触力异常的识别。

参考文献

- [1] 伏松平. 基于人工智能技术的电气化铁路接触网检测研究[J]. 电气应用, 2020, 39(9): 50.
FU Songping. Research on the detection of electrified railway cate-

nary based on artificial intelligence technology[J]. Electrotechnical Application, 2020, 39(9): 50.

- [2] 杨志鹏. 弓网接触力缺陷特征与诊断研究[J]. 电气化铁道, 2018, 29(1): 27.
YANG Zhipeng. Researches of characteristics and diagnosis of defects of pantograph-catenary contact force[J]. Electric Railway, 2018, 29(1): 27.
- [3] 杨茂, 江博. 风电功率弃风数据特征识别方法研究[J]. 中国电力, 2017, 50(5): 95.
YANG Mao, JIANG Bo. Recognition method of wind curtailment data characteristics[J]. Electric Power, 2017, 50(5): 95.
- [4] 王敏. 风电机组运行数据中异常值识别方法的研究[D]. 兰州: 兰州理工大学, 2019.
WANG Min. Research on identification method of outliers in operating data of wind turbine[D]. Lanzhou: Lanzhou University of Technology, 2019.
- [5] 董泽, 贾昊. 基于 EWT-LOF 的热工过程数据异常值检测方法[J]. 仪器仪表学报, 2020, 41(2): 126.
DONG Ze, JIA Hao. Outlier detection method for thermal process data based on EWT-LOF[J]. Chinese Journal of Scientific Instrument, 2020, 41(2): 126.
- [6] 林洁, 吴布托, 陈伟. 基于深层玻尔兹曼机的风电场异常风速值自适应检测预处理方法[J]. 电工技术学报, 2018, 33(增刊1): 205.
LIN Jie, WU Butuo, CHEN Wei. Adaptive detection and preprocessing method for abnormal wind speed of wind farm based on deep Boltzmann machine[J]. Transactions of China Electrotechnical Society, 2018, 33(S1): 205.
- [7] 刘金朝, 王卫东, 孙善超, 等. 铁路轨道几何数据冲击噪声小波-有序中值滤波方法[J]. 振动与冲击, 2014, 33(10): 29.
LIU Jinzhao, WANG Weidong, SUN Shanchao, et al. Removing spike noise in railway track geometric data with a wavelet-rank order mean filter[J]. Journal of Vibration and Shock, 2014, 33(10): 29.
- [8] KIM H, PARK M, KIM C W, et al. Source localization for hazardous material release in an outdoor chemical plant via a combination of LSTM-RNN and CFD simulation[J]. Computers & Chemical Engineering, 2019, 125: 476.
- [9] ZAZO R, SANKAR NIDADAVOLU P, CHEN N, et al. Age estimation in short speech utterances based on LSTM recurrent neural networks[J]. IEEE Access, 2018, 6: 22524.

· 收稿日期:2022-03-10 修回日期:2022-04-26 出版日期:2024-08-10
Received:2022-03-10 Revised:2022-04-26 Published:2024-08-10
· 第一作者:杨劲松,助理研究员, yangjinsong1994@163.com
通信作者:刘金朝,研究员, liujinzhao@rails.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