

doi: 10.3969/j.issn.1672-6073.2025.03.021

# 基于数字孪生的转辙机可视化 监控与故障诊断方法研究

张 琰<sup>1</sup>, 张振海<sup>1</sup>, 梁朝辉<sup>2</sup>, 马 章<sup>2</sup>

(1. 兰州交通大学 自动化与电气工程学院, 兰州 730070;  
2. 中国国家铁路集团有限公司 工程管理中心, 北京 100844)

**摘要:** 为提高城市轨道交通作业人员对转辙机工作时状态监测的可视化与故障诊断的智能化, 提出一种基于数字孪生的转辙机三维可视化监控与故障诊断方法, 为转辙机工作状态的实时监测、运行数据的高质量传输和设备故障的精准化报警提供有力的技术支持。相较于现有转辙机智能运维系统, 本研究利用数字孪生技术建立高保真模型, 通过数据的实时交互将现场工作的转辙机映射于信息空间, 通过 WebGL 与模型轻量化技术实现在室内对转辙机的三维可视化监控; 针对现场转辙机故障数据样本较少, 建立 CNN-Transformer 的组合模型实现转辙机的故障诊断, 在正常数据与故障数据不平衡的条件下故障诊断精确率为 98.67%。为验证所提框架及改进算法方法的可行性, 设计基于数字孪生的转辙机三维可视化监控与故障诊断平台。

**关键词:** 城市轨道交通; 数字孪生; 转辙机; 三维可视化监控; 故障诊断; CNN-Transformer  
**中图分类号:** U231.1 **文献标志码:** A **文章编号:** 1672-6073(2025)03-0153-09

## Research on 3D Visualization Monitoring and Fault Diagnosis Methods for Urban Rail Transit Switch Machines Based on Digital Twins Technology

ZHENG Yan<sup>1</sup>, ZHANG Zhenhai<sup>1</sup>, LIANG Zhaohui<sup>2</sup>, MA Zhang<sup>2</sup>

(1. College of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070;  
2. China State Railway Group Co., Ltd., Beijing 100844)

**Abstract:** To improve the visualization of switch machine status monitoring and the intelligence of fault diagnosis by urban rail transit operators, a 3D visualization monitoring and fault diagnosis method of switch machine based on digital twin is proposed, which provides a powerful technical support for the real-time monitoring of switch machine status, high-quality transmission of operation data, and the precise alarm of equipment faults. Compared with the existing intelligent operation and maintenance system of Switch Machines, this study uses digital twin technology to establish a high-fidelity model, maps the field-working Switch Machines in the information space through real-time interaction of data, and realizes three-dimensional visual monitoring of Switch Machines indoors through WebGL and model lightening technology; in view of the small number

收稿日期: 2024-09-09 修回日期: 2024-12-02

第一作者: 张琰, 男, 硕士研究生, 从事轨道交通关键信号设备智能运维的理论与技术研究, 814097667@qq.com

导师简介: 张振海, 男, 教授, 硕士生导师, 从事轨道交通信号控制与智能运维工作, 764411629@qq.com

基金项目: 甘肃省重点研发计划项目(22YF7GA141); 国家自然科学基金项目(61763025); 兰州交通大学重点研发计划(ZDYF2303)

引用格式: 张琰, 张振海, 梁朝辉, 等. 基于数字孪生的转辙机可视化监控与故障诊断方法研究[J]. 都市轨道交通, 2025, 38(3): 153-161.

ZHENG Yan, ZHANG Zhenhai, LIANG Zhaohui, et al. Research on 3D visualization monitoring and fault diagnosis methods for urban rail transit switch machines based on digital twins technology[J]. Urban rapid rail transit, 2025, 38(3): 153-161.

of samples of fault data for switch machines in the field, it establishes a combined model of CNN-Transformer to achieve fault diagnosis. To achieve the fault diagnosis of switch machines, the fault diagnosis accuracy rate is 98.67% under the condition of imbalance between normal data and fault data; In order to verify the feasibility of the proposed framework and the improved algorithmic approach, a 3D visualization monitoring and fault diagnosis platform for switch machines based on digital twins is designed.

**Keywords:** urban rail transit; digital twin; switch machine; 3D visualization and monitoring; fault diagnosis; CNN-Transformer

## 0 引言

转辙机是城市轨道交通的关键信号设备之一，其安全性和可靠性直接影响行车安全<sup>[1]</sup>。由于转辙机工作环境繁杂多样，容易遭受恶劣天气等环境因素以及人为因素的影响，在现场容易出现故障。目前城市轨道交通工作人员一般采取的运维措施为“日常修”和“故障修”<sup>[2]</sup>，通过信号集中监测设备的报警信息、人工查询设备的电流和功率曲线等方式，大致判断故障范围，容易发生养护不周或过度维修的情况。因此，如何更加高效、可靠、智能地对道岔转辙机进行实时监控与故障诊断成为当下智能化城市轨道交通发展的热点领域之一。

目前国内外学者在转辙机运维技术与故障诊断方面已取得一些成果。胡小晨等<sup>[3]</sup>提出了一种基于主成分分析和深度森林算法的故障诊断方法，在样本数据均衡的情况下有较好的诊断效果；付雅婷等<sup>[4]</sup>提出一种基于多通道输入和一维卷积神经网络与长短期记忆神经网络结合的故障诊断方法，但未考虑现场数据分布不均衡的情况；郑启明等<sup>[5]</sup>提出一种基于改进生成对抗网络数据增强的转辙机故障诊断方法，但采用自适应对齐的方式有可能导致曲线失去原有的特征；何晖等<sup>[6]</sup>提出一种基于 DCNN-SVM 的道岔故障诊断方法，但对转辙机故障样本的数据量要求过高。尽管上述论文中对于转辙机的状态检测与故障诊断等做出了一定的研究，但大部分学者未考虑到现场正常数据与故障数据的占比情况，使用的数据较为理想化，并且缺少集成化的体系、可视化的平台、实时的数据反馈及可交互的感官体验，这些情况导致转辙机的智能运维技术难以落地。

数字孪生的出现为转辙机的状态检测与运维技术的发展及应用提供了一种新的途径，作为现实世界与信息世界的深度交融体，充分利用传感器网络、通信手段、云边协同技术、三维孪生模型等手段，可以在信息空间实现对物理设备的全方位监控、故障诊断等。目前已有学者利用数字孪生技术在航空、制造、医疗

等领域开展智能运维技术的研究，并取得良好的进展<sup>[7-11]</sup>，但在城市轨道交通领域里，将数字孪生与运维技术结合的研究相对较少。

因此，本文提出一种数字孪生驱动的道岔转辙机三维可视化监控与故障诊断方法，将云边协同技术用于数据的传输与治理，提高云端的数据价值与处理效率；设计基于 WebGL 的三维可视化监控平台，集成状态检测、故障诊断、维修决策等于一体；搭建基于孪生数据的故障诊断模型，有效利用实时交互的设备运行数据，实现转辙机故障诊断；设计并开发基于 Web 端的应用程序，验证所提方法的可行性。相较于仅获取功率曲线的微机监测系统与其他信号智能运维系统，该技术支持工作人员在室内以三维可视化的形式观测转辙机内部运行状态，将文本化的状态信息可视化。在故障发生时，系统可将孪生模型对应的故障位置呈现给工作人员，并给出故障原因及维修建议，从而提高现场维修效率。

## 1 基于数字孪生的道岔转辙机三维可视化监控与故障诊断框架

参考数字孪生五维模型<sup>[12]</sup>与数字孪生体系标准，本文提出一种适用转辙机的数字孪生三维可视化监控与故障诊断系统框架，为后续研究提供基础，该框架自底向上主要包含物理层、数据层、模型层及应用层 4 层结构体系，如图 1 所示。

### 1.1 物理层

物理层包括两部分：一是道岔转辙机物理设备；二是包括转辙机内部高兼容的传感器网络、外部环境监测设备以及物联网关等数据采集与传输设备。借助通信、物联网等技术实时采集转辙机工作时电压、电流、电功率等相关数据。

### 1.2 数据层

数据层主要包括 3 部分：数据传输、数据管理和数据存储。数据传输在室内至室外检测箱阶段采用 ADSL 传输网络，在检测箱至转辙机阶段采用 CAN 总

线通信方式，将采集到的信息以数据、图像、视频等形式输送至孪生系统中，一方面用于驱动模型层中数字孪生体与转辙机实物保持运转一致，另一方面配合深度学习进行异构信息的挖掘，完善道岔转辙机三维孪生模型的动态演化。

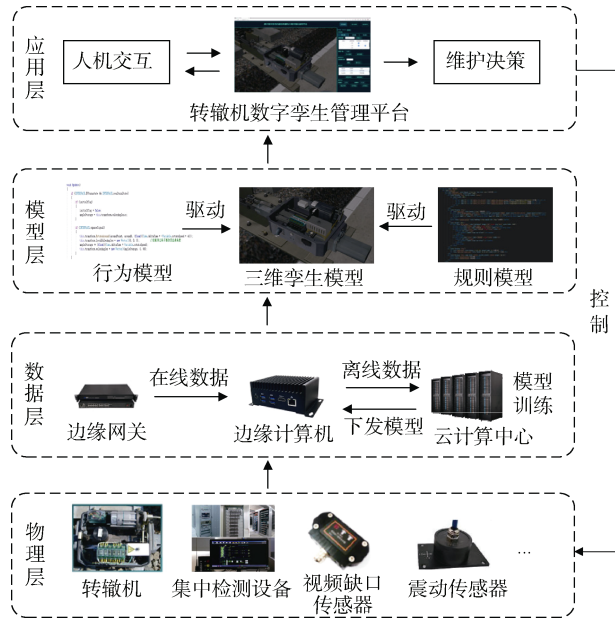


图1 基于数字孪生技术的道岔转辙机三维可视化监控与故障诊断框架

Figure 1 Framework for 3D visualization monitoring and fault diagnosis of switch machines based on digital twin technology

### 1.3 模型层

模型层是道岔转辙机孪生系统的核心，包括道岔转辙机组的三维孪生模型、各类机理模型和数据驱动模型等，映射物理层中各类传感器设备的感知。主要通过CAD、CAE等建模工具构建高保真高精度三维可视化孪生模型，包括各类部件的装配关系与运动副等；机理模型包括道岔转辙机组工作机理、设备故障机理等。

### 1.4 应用层

应用层包括道岔转辙机组工作状态的三维可视化监控、重要零部件的故障诊断和定位、剩余寿命预测、最优维护决策的制定等功能，是用户直观感受数字孪生系统参与实现道岔转辙机三维可视化监控及故障诊断的“窗口”。限于篇幅，本文仅侧重于道岔转辙机的三维可视化监控与故障诊断。

## 2 基于云边协同的道岔转辙机数据采集与治理

道岔转辙机孪生系统中包含大量设备运转数据、孪

生模型数据等，将海量数据直接导入云端处理存在延迟较大、带宽不足、数据时效性较低等问题。将周期短、实时性强的边缘计算用于海量数据的预加工与处理，可有效解决云计算的延迟响应、缓解云端计算与存储压力、提升数据价值与实效性。如图2所示。

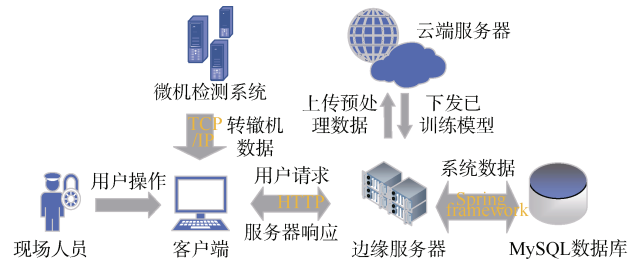


图2 基于云边协同的道岔转辙机数据采集与治理  
Figure 2 Data acquisition and governance of switch machines based on cloud-edge collaboration

### 2.1 道岔转辙机数据采集

传统的微机监测系统无法支持数字孪生对转辙机各项数据的采集，而对其进行全面开发与升级的难度较高。因此本文选用单片机作为节点监测平台，根据现场实际需求，采集转辙机电流数据、尖轨密贴间隙和爬行量等，通过无线网络或CAN通信方式传输至客户端并储存，主控单元总体结构如图3所示。

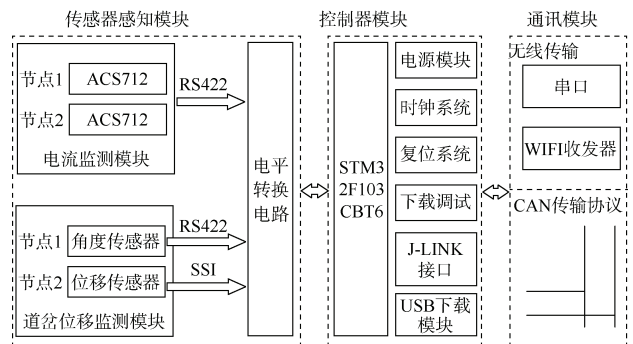


图3 主控单元总体结构

Figure 3 Overall structure of the master control unit

监测节点部分主要由电流传感器、角度编码器和位移传感器构成，通过IO接口与控制器连接实现电流数据与道岔位移数据的采集。其中，对于尖轨横纵位移的数据采集应选取适配的硬件测量仪器，本文采用文献[13]提出的尖轨横纵位移一体化综合测量器，并设计了集电流监测与道岔位移监测一体的转辙机监测系统。道岔位移监测器剖视图如图4所示，通过位移传感器的活动磁环与动作引导杆连接以获取其位移值，角度编码器与芯轴配合以获取旋转角度。




图 4 道岔位移监测器剖视图

Figure 4 Sectional view of switch displacement monitor

## 2.2 边端数据预处理

边端即转辙机与传感器等设备，将边端附近具备小规模计算能力的边缘控制器等视为边缘节点，对传感器采集的原始数据进行存储和清洗，包括缺失数据处理、异常数据剔除等。将经过边缘计算等预处理后的数据上传至云端，可有效提升数据价值、缓解云端压力。道岔转辙机设备的监测数据可视为一个时间段上的离散数据序列，当外界存在干扰时会出现数据的失真或丢失，使待观测的离散数据序列产生异常，因此需要对缺失数据进行填补，对异常数据进行剔除。

### 2.2.1 缺失数据填补

当转辙机由于外界条件干扰而发生数据缺失时，从采集器角度切入，采集系统表现为 0 或无数据显示，当采集器瞬时失效，仅为单点数据缺失，考虑其监测数据在时间序列变化缓慢的特征，采用 1 临近插补法对缺失数据进行填补，即将转辙机缺失数据的第 1 临近数据的均值作为填补值。具体方法如下：在转辙机工作状态下监测的第  $T$  个时间内，存在  $N$  个等间隔被采数据，记作  $X = \{x_1, x_2, \dots, x_N\}$ ，当发现第  $i$  个被采数据  $x_i$  缺失时，使用  $x_i$  第 1 临近数据均值作为填补数据，公式为：

$$\hat{x}_i = \frac{1}{2}(x_{i-1} + x_{i+1}) \quad (1)$$

在出现一段数据缺失时可能有以下 3 种情况：采集器无法工作，无论道岔工作与否，均采集不到有数据产生，此时监测系统认为道岔始终无动作；若采集器异常，始终认为道岔在动作状态，则反复采集为 0 的数据，此时监测系统出现为 0 的直线；采集器正常工作时短暂失效，则系统缺失一段数据，此时该部分

可能无任何数据显示。在前 2 种情况下，数据无法恢复，应派遣值班人员前往修复采集器；若采集器短暂失效，可通过工人观测完好部分曲线判断转辙机运行状态或现场排查转辙机是否故障。

### 2.2.2 异常数据剔除

根据道岔转辙机数据特点，在一段正常的功率曲线中近乎所有数据均位于平均值的 3 个标准差之内，为提高其数据采集的精准度与价值，本文使用拉依达准则法对所采集的异常数据进行剔除。对于采集数据集  $X = \{x_1, x_2, \dots, x_N\}$ ，存在采样数据满足式(2)。则认为该采样数据为异常数据，将其剔除，并根据公式 1 将剔除数据补充完整。

$$|x_j - \bar{x}| > 3\sigma \quad (2)$$

$$\text{其中, } \bar{x} = \frac{1}{n} \sum_{j=1}^n x_j, \quad \sigma = \sqrt{\frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2}.$$

## 2.3 云边协同

采用边缘导向与边边联邦结合的云边协同模式，将经过边端预处理后的高质量数据传输至云端，完成道岔转辙机故障诊断模型的整体训练，将云端训练完成的模型下发至边缘节点，边端设备在执行数据预处理等任务的同时，可将现场设备的实时数据输送至模型进行在线诊断，在保证数据隐私与安全的前提下，更好地满足孪生系统对数据的实时性需求。

## 3 基于 Web 的道岔转辙机三维可视化监控与故障诊断

### 3.1 三维可视化监控

转辙机孪生模型的建立是实现三维可视化的基础，可以利用 SolidWorks、3DsMAX、Maya 等 3D 建模软件，依据转辙机各组件的物理参数、运动副与结构关系等，将所需零部件完成建模后进行装配。为满足在 Web 端的流畅展示，需要将建立好的三维孪生模型进行轻量化处理，然后集成在 Web 应用端。通过 MQTT 技术将边端接收并处理过的数据推送至 Web 端应用程序，实现转辙机传感器网络所获取的数据信息在孪生模型中实时映射，将孪生数据集成并融合在三维模型中，如图 5 所示。

### 3.2 基于深度学习的转辙机故障诊断

转辙机在工作时会牵引尖轨进行伸缩动作，此时的牵引力会因转辙机自身的状态而有所变化，因此可以根据牵引力输出的大小判断此时转辙机的工作状

态, 牵引力大小的改变是由转辙机内部电机的功率变化引起的, 因此对转辙机内部电机的动作功率曲线进行研究, 对于转辙机工作状态的判断有很大帮助。




图5 基于 Web 的道岔转辙机三维可视化监控  
Figure 5 Web-based three-dimensional visualization and monitoring of switch machines

在信号集中监测系统中获取的转辙机功率曲线为时序数据, 因此设计基于 CNN-Transformer 的转辙机故障诊断模型, 结合绝对位置编码(tAPE)、相对位置编码(eRPE)以及基于卷积的输入编码, 可改进时间序列数据的位置和数据嵌入, 更准确地区分转辙机不同的故障状态。该模型主要包括以下 6 个部分:

### 3.2.1 嵌入层

首先使用卷积层进行特征提取。将提取到的一维功率信号孪生数据输入至网络, 通过卷积核与输入数据进行卷积操作, 提取局部特征, 结果如公式(3)所示:

$$x_k^l = \text{GELU} \left\{ \text{BatchNorm} \left[ \text{Conv2d} \left( x_{k-1}^{l-1} \right) + b_k^l \right] \right\} \quad (3)$$

式中,  $x_k^l$  为第  $l$  层第  $k$  次卷积映射;  $x_{k-1}^{l-1}$  为第  $l-1$  层第  $k-1$  次卷积映射; GELU 为激活函数; Conv2d 为二维卷积操作;  $b_k^l$  为偏置。

卷积操作:  $y = \text{Conv2d}(x, W, b)$ , 具体计算式为:

$$y_{i,j,k} = \sum_{m=1}^H \sum_{n=1}^W x_{i+m,j+n,k} W_{m,n} + b_k \quad (4)$$

式中,  $x_{i+m,j+n,k}$  是输入特征图中的一个元素, 表示在第  $i+m$  层、第  $j+n$  行和第  $k$  列的像素值;  $W$  和  $H$  为卷积核的宽度和高度, 分别取 8 和 1;  $W_{m,n}$  是卷积核在第  $m$  行和第  $n$  列的权重;  $b_k$  是第  $k$  个通道的偏置项;  $y_{i,j,k}$  是输出特征图第  $i$  层、第  $j$  行和第  $k$  列的像素值。

批量归一化:  $y_{\text{BN}} = \text{BatchNorm2d}(y)$ , 具体计算式为:

$$y_{\text{BN}} = \gamma \frac{y - \mu}{\sqrt{\sigma^2 + f}} + \beta \quad (5)$$

式中,  $y_{\text{BN}}$  是输入特征;  $\mu$  和  $\sigma^2$  分别是均值和方差;  $\gamma$  和  $\beta$  为可学习参数;  $f$  为小常数, 防止分母为 0。

激活函数 GELU:  $y_{\text{GELU}} = \text{GELU}(y_{\text{BN}})$ , 具体计算式为:

$$y_{\text{GELU}} = 0.5 y_{\text{BN}} \left[ 1 + \tanh \left( \sqrt{\frac{2}{\pi}} \left( y_{\text{BN}} + 0.044715 y_{\text{BN}}^3 \right) \right) \right] \quad (6)$$

Dropout:  $y_{\text{Dropout}} = \text{Dropout}(y_{\text{GELU}}, p)$ , 具体计算式为:

$$y_{\text{Dropout}} = \begin{cases} 0 & r < p \\ \frac{y_{\text{GELU}}}{1-p} & r \geq p \end{cases} \quad (7)$$

式中,  $r$  是在  $[0, 1]$  区间内均匀分布的随机数;  $p$  是 Dropout 率。

### 3.2.2 位置编码层

本文算法支持 3 种绝对位置编码方法(tAPE、Sin、Learn)和 2 种相对位置编码方法(eRPE、Vector)。

绝对位置编码如式(8)所示:

$$x_{\text{pos}}^l = \text{PosEncode} \left( x_k^l \right) \quad (8)$$

式中, PosEncode 表示位置编码操作, 可以是 tAPE、Sin 或 Learn 方法。本文采用 tAPE 方法。

相对位置编码如式(9)所示:

$$x_{\text{rpos}}^l = \text{Attention} \left( x_{\text{pos}}^l \right) + \text{RelPosEncode} \left( x_{\text{pos}}^l \right) \quad (9)$$

式中, Attention 为注意力机制, RelPosEncode 可以是 eRPE 或 Vector 方法。本文采用 eRPE 方法。

### 3.2.3 Transformer 编码器层

在 Transformer 编码器层中, 首先进行注意力机制计算, 然后进行前馈神经网络计算。

注意力机制首先通过查(Query)、键(Key)和值(Value)进行计算, 然后进行层归一化。具体计算如下:

查询、键和值的计算公式为:

$$Q = W_Q x_{\text{pos}}^l \quad (10)$$

$$K = W_K x_{\text{pos}}^l \quad (11)$$

$$V = W_V x_{\text{pos}}^l \quad (12)$$

式中,  $W_Q$ 、 $W_K$ 、 $W_V$  分别是查询、键和值的权重矩阵。

注意力得分的计算如公式(13)所示:

$$A = \text{softmax} \left( \frac{QK^T}{\sqrt{d_k}} \right) \quad (13)$$

式中,  $A$  是注意力权重矩阵,  $d_k$  是键的维度。

加权值的计算如式(14)所示:

$$Z=AV \quad (14)$$

层归一化:  $x'_{\text{tpos}} = \text{LayerNorm}(x'_{\text{tpos}} + Z)$ , 具体计算公式如式(15)所示:

$$y_{\text{LN}} = \frac{y - \mu}{\sqrt{\sigma^2 + f}} \gamma + \beta \quad (15)$$

式中,  $y_{\text{LN}}$  是输入特征。

前馈神经网络包括 2 个线性层和 ReLU 激活函数, 计算如下。

第 1 个线性层:

$$F_{\text{FN1}} = \text{ReLU}(W_1 x'_{\text{tpos}} + b_1) \quad (16)$$

式中,  $W_1$  和  $b_1$  为第 1 个线性层的权重向量和偏置; ReLU 为激活函数;  $F_{\text{FN1}}$  为第 1 个线性层的输出。

第二个线性层:

$$F_{\text{FN2}} = W_2 F_{\text{FN1}} + b_2 \quad (17)$$

式中,  $W_2$  和  $b_2$  为第 2 个线性层的权重向量和偏置;  $F_{\text{FN2}}$  为第 2 个线性层的输出。

输出层归一化:

$$\text{out} = \text{LayerNorm}(x'_{\text{tpos}} + F_{\text{FN2}}) \quad (18)$$

式中, LayerNorm 为层归一化操作, 计算方式与前述相同。

综上所述, Transformer 编码器层首先通过注意力机制计算加权值并进行层归一化, 然后通过前馈神经网络进一步处理特征并再次进行层归一化。

### 3.2.4 全局平均池化层

在全局平均池化层中, 通过自适应平均池化操作将特征向量缩小为固定大小, 结果如公式(19)所示:

$$\text{gap}_i = \frac{1}{T} \sum_{t=1}^T \text{out}_{i,t} \quad (19)$$

式中,  $\text{out}$  是输入特征;  $T$  是时间步的数量;  $\text{gap}_i$  是第  $i$  个通道的全局平均池化结果。

### 3.2.5 展平层

展平层将多维特征向量展开为一维向量, 以便输入到全连接层。展平操作的具体计算式如式(20)所示:

$$\text{flat} = \text{Flatten}(\text{gap}) \quad (20)$$

式中, Flatten 为展平操作, 将多维张量展开为一维张量。

### 3.2.6 输出层

在输出层中, 通过全连接层将特征向量映射到分

类标签, 如式(21)所示:

$$y = W_{\text{out}} \text{flat} + b_{\text{out}} \quad (21)$$

式中,  $W_{\text{out}}$  和  $b_{\text{out}}$  分别是全连接层的权重向量和偏置; flat 是展平后的特征向量;  $y$  是输出的分类结果。

## 3.3 尖轨密贴位移量与爬行位移计算

如图 6 所示, 道岔位移监测器应放置于尖轨一侧, 通过其伸出的引导杆与尖轨端铰链来反映尖轨密贴与爬行位移变化<sup>[14]</sup>。根据已知的横向位移  $t$  和纵向位移  $s$ , 能够求出检测器引导杆的初始安装参数  $l_0$  与安装片转角度  $\beta$ 。




图 6 监测器测量原理

Figure 6 Monitor measuring principle

$$l_0 = \sqrt{\frac{\Delta l - (s^2 + t^2)}{2(\cos \Delta \theta - 1)} + \frac{\Delta l^2}{4}} - \frac{\Delta l}{2} \quad (22)$$

$$\frac{l_0 + \Delta l}{\sin \angle CAO} = \frac{\sqrt{s^2 + t^2}}{\sin \Delta \theta} \quad (23)$$

$$\beta = 90^\circ - \arctan \frac{t}{s} - \angle CAO \quad (24)$$

假设尖轨初始位置为  $A$ , 向上爬行的最终位置为  $C$ 。通过测量器可将其爬行位移转化为引导杆轴线方向的直线位移  $\Delta l$  和角度位移  $\Delta \theta$ ,  $d$  为尖轨移动的距离, 此时可通过以下公式求解角度与线性位移量。

$$d^2 = l_0^2 + (l_0 + \Delta l)^2 - 2l_0(l_0 + \Delta l) \cos \Delta \theta \quad (25)$$

$$\frac{l_0}{\sin \angle ADO} = \frac{AD}{\sin \Delta \theta} \quad (26)$$

$$\frac{AD}{\sin \angle ACD} = \frac{d}{\sin \angle ADO} \quad (27)$$

$$\sin \angle ACB = \sin \angle ACD + \beta - \Delta \theta \quad (28)$$

$$s = d \sin \angle ACB \quad (29)$$

$$t = d \cos \angle ACB \quad (30)$$

## 4 系统实现与功能验证

### 4.1 原型系统

为验证本文所提方法, 以 Visual Studio 为集成开

发环境,客户端部分采用 Java 编程语言和 Vue 框架实现业务逻辑和人机交互界面,包括转辙机孪生模型和工作环境,功率显示和故障诊断辅助功能等;数据传输部分设计集电流、尖轨横纵位移于一体的检测系统,实时采集现场转辙机相关数据,并通过无线传输或 CAN 总线传输方式将转辙机功率曲线和尖轨位移量送至客户端显示界面和部署于边缘服务器的诊断模型,其中云端负责定期接收并训练数据库中存储的历史功率数据,边端负责数据的预处理与实时诊断,包括剔除或替换缺失数据以及接收已训练好的模型用于现场数据的故障诊断;服务器部分在 Springboot 框架上采用 Java 语言编写;故障诊断模型部分采用 PyTorch 库搭建至边缘服务器与云端服务器,将接收的每条数据在边端诊断完成后,输出结果反馈给客户端界面;使用 MySQL 数据库存储相关历史数据,由 spring framework 框架连接至服务器,如图 7 所示。




图 7 基于数字孪生的道岔转辙机三维可视化监控平台  
Figure 7 Digital twin-based three-dimensional visualization and monitoring platform for switch machines

### 4.2 转辙机故障诊断功能验证

本算法针对转辙机功率曲线的 1 维时序数据进行分类,适用于多种类型转辙机。本文以 S700K 转辙机为例,选取实际工作环境中的正常状态与常见的 8 种故障状态,用 F0~F8 表示(F0 表示正常状态),故障现象及原因见表 1 所示。本研究以某地铁集团提供的 S700K 转辙机动作功率曲线数据进行故障诊断模型的功能验证,对各故障状态数据分别取 50 组,转辙机故障数据集具有不平衡和小样本的特征,而算法中分类器的性能会因数据集的不平衡而受到影响,因此大量现有文献通过扩充故障集的形式提升分类器的性能。本文算法在转辙机不平衡样本分类中具有优势,因此为满足故障与正常数据占比符合现场情况,使用 Smote 算法将 500 组正常数据扩充至 5 000 组,共 5 400 组数

据,训练集与验证集比例为 8 : 2。通过 Python 语言,PyTorch 框架搭建模型。

表 1 S700K 转辙机常见故障现象及原因

Table 1 Common faults and causes of S700K switch machine

故障编码	故障现象	故障原因
F <sub>1</sub>	功率在转换阶段的 2.5 s 处迅速上升并稳定	下拉装备异常,无法解锁
F <sub>2</sub>	进入转换阶段波动异常,解锁耗时长	道岔存在异常阻力导致卡阻
F <sub>3</sub>	进入锁闭时阶段功率增幅异常	存在异物阻碍动作杆工作
F <sub>4</sub>	进入锁闭前功率小幅增长	杆件转置等出现松动
F <sub>5</sub>	功率呈阶梯状上升,锁闭阶段有异常上幅波动	锁闭块或锁舌卡死
F <sub>6</sub>	完成锁闭阶段时功率异常增加并保持	转辙机缺口出现变化
F <sub>7</sub>	完成锁闭阶段后,功率无法降为 0 kW	断相表示器故障
F <sub>8</sub>	完成锁闭阶段后功率起伏波动异常	二极管失效,表示电路故障

#### 4.2.1 评价指标

本研究通过精确率  $P$ 、召回率  $R$  和  $F_1$  分数评价模型性能,三者的计算公式为:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (31)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (32)$$

$$F_1 = \frac{2N_{TP}}{2N_{TP} + N_{FP} + N_{FN}} \quad (33)$$

式中,  $N_{TP}$  为正确分类至本类的样本数;  $N_{FP}$  为错误分类至本类的样本数;  $N_{FN}$  为将本类误判至其他类的样本数量。

#### 4.2.2 模型性能验证

在 3.2 节给出的故障诊断模型基础上,对 S700K 转辙机的功率数据进行训练与验证,将训练的最优模型保存至本地,最终超参数设置见表 2 所示。为测试该模型算法性能,采用独立于训练数据集和验证数据集的真实测试数据集,取正常数据与 8 种故障数据各 50 组,并结合随机噪声生成 3 600 组数据,将其输入至不同经典算法模型中进行对比,包括文献[15]的 PCA-HMM、文献[16]的 CDET-MPSO-SVM、文献[17]的 CNN、文献[18]的 LSTM、文献[19]的 1DCNN-BiLSTM 等。结果见表 3。对比结果显示,本文提出的 CNN-Transformer 模型在转辙机故障类别分类上的精确率、召回率和  $F_1$  值分别为 98.67%、98.63%和 98.65%,

均优于其他模型。

表 2 故障诊断模型超参数设置

Table 2 Hyperparameter settings of fault diagnosis model

超参数名称	超参数值
学习率	0.001
Epoch	50
Dropout	0.01
Transformer Embedding 维度	16
Transformer FFN 维度	256
多头注意力的头数	8
固定位置编码	tAPE
相对位置编码	eRPE
批量大小	16
网络架构	CNN-Transformer
数据归一化	False

表 3 不同故障诊断模型性能对比

Table 3 Performance comparison of different fault diagnosis models

模型	精确率/%	召回率/%	F <sub>1</sub> 值/%	时间/s
1DCNN	95.47	95.31	95.39	92
LSTM	94.82	94.67	94.74	264
1DCNN-BiLSTM	97.13	97.13	97.12	143
PCA-HMM	91.54	91.51	91.52	304
CDET-MPSO-SVM	95.24	95.21	95.22	717
CNN-Transformer	98.67	98.63	98.65	136

## 5 结语

为促进城市轨道交通信号设备智能运维技术的发展, 将数字孪生技术引入转辙机设备的三维可视化监控, 便于工作人员对现场设备的信息获取, 完善现有智能运维系统在可视信息方面的缺失, 实现对设备状态检测的可视化与智能化。本文针对城市轨道交通信号设备转辙机展开研究, 详细描述了针对转辙机的数字孪生关键技术与方法; 考虑实际情况, 设计集电流、尖轨横纵位移于一体的道岔转辙机数据采集系统, 实时监测现场转辙机电流与尖轨横纵位移量, 并将云边协同技术用于现场海量数据的采集与治理; 提出使用基于 CNN-Transformer 的故障诊断算法, 试验证明在转辙机数据不平衡的情况下依然有较高的诊断性能; 最后设计了基于数字孪生的道岔转辙机三维可视化监控与故障诊断系统, 可在室内实时监测转辙机内部运动状态和各种参数信息, 实现转辙机故障的报警与诊断, 有效提高作业人员日常的运维效率, 降低转辙机运维成本。

## 参考文献

- [1] SUN Yongkui, CAO Yuan, XIE Guo, et al. Sound based fault diagnosis for RPMs based on multi-scale fractional permutation entropy and two-scale algorithm[J]. IEEE transactions on vehicular technology, 2021, 70(11): 11184-11192.
- [2] 钟志旺, 陈建译, 唐涛, 等. 基于 SVDD 的道岔故障检测和健康管理方法[J]. 西南交通大学学报, 2018, 53(4): 842-849.  
ZHONG Zhiwang, CHEN Jianyi, TANG Tao, et al. SVDD-based research on railway-turnout fault detection and health assessment[J]. Journal of southwest Jiaotong University, 2018, 53(4): 842-849.
- [3] 胡小晨, 郭宁, 沈拓, 等. 基于主成分分析和深度森林算法的 S700K 转辙机故障诊断[J]. 同济大学学报(自然科学版), 2024, 52(1): 35-40.  
HU Xiaochen, GUO Ning, SHEN Tuo, et al. PCA-gcForest-based fault diagnosis of S700K switch machine[J]. Journal of Tongji University (Natural Science), 2024, 52(1): 35-40.
- [4] 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): 98-106.  
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): 98-106.
- [5] 郑启明, 姚新文, 陈光武, 等. 基于改进对抗网络与自适应数据对齐的转辙机故障诊断研究[J]. 铁道学报, 2023, 45(10): 96-104.  
ZHENG Qiming, YAO Xinwen, CHEN Guangwu, et al. Research on fault diagnosis method for switch machine based on improved generative adversarial networks with adaptive data alignment[J]. Journal of the China railway society, 2023, 45(10): 96-104.
- [6] 何晖, 代萌, 李雪, 等. 基于 DCNN-SVM 的道岔智能故障诊断方法研究[J]. 铁道学报, 2023, 45(9): 103-113.  
HE Hui, DAI Meng, LI Xue, et al. Research on intelligent fault diagnosis method for turnouts based on DCNN-SVM[J]. Journal of the China railway society, 2023, 45(9): 103-113.
- [7] JIA Pengyi, WANG Xianbin, SHEN Xuemin. Accurate and

- efficient digital twin construction using concurrent end-to-end synchronization and multi-attribute data resampling[J]. IEEE internet of things journal, 2023, 10(6): 4857-4870.
- [8] 杨伟新, 樊小伟, 孙荣富, 等. 数字孪生驱动的风电机组三维可视化监控与故障预警方法[J]. 弹箭与制导学报, 2023, 43(2): 94-102.
- YANG Weixin, FAN Xiaowei, SUN Rongfu, et al. Digital twin-driven 3D visualization monitoring and fault warning for wind turbine[J]. Journal of projectiles, rockets, missiles and guidance, 2023, 43(2): 94-102.
- [9] 李浩, 王昊琪, 刘根, 等. 工业数字孪生系统的概念、系统结构与运行模式[J]. 计算机集成制造系统, 2021, 27(12): 3373-3390.
- LI Hao, WANG Haoqi, LIU Gen, et al. Concept, system structure and operating mode of industrial digital twin system[J]. Computer integrated manufacturing systems, 2021, 27(12): 3373-3390.
- [10] 梁宏涛, 孔翎超, 刘国柱, 等. 融合数字孪生的风电机组故障检测 ASL-CatBoost 方法[J]. 系统仿真学报, 2024, 36(4): 873-887.
- LIANG Hongtao, KONG Lingchao, LIU Guozhu, et al. ASL-CatBoost method for wind turbine fault detection integrated with digital twin[J]. Journal of system simulation, 2024, 36(4): 873-887.
- [11] 王红军, 林俊强, 邹湘军, 等. 基于数字孪生的果园虚拟交互系统构建[J]. 系统仿真学报, 2024, 36(6): 1493-1508.
- WANG Hongjun, LIN Junqiang, ZOU Xiangjun, et al. Construction of a virtual interactive system for orchards based on digital twin[J]. Journal of system simulation, 2024, 36(6): 1493-1508.
- [12] 陶飞, 刘蔚然, 张萌, 等. 数字孪生五维模型及十大领域应用[J]. 计算机集成制造系统, 2019, 25(1): 1-18.
- TAO Fei, LIU Weiran, ZHANG Meng, et al. Five-dimension digital twin model and its ten applications[J]. Computer integrated manufacturing systems, 2019, 25(1): 1-18.
- [13] 翟文革, 郑培珍, 江海川, 等. 尖轨密贴爬行测量方法及系统[J]. 计测技术, 2021, 41(5): 58-64.
- ZHAI Wenge, ZHENG Peizhen, JIANG Haichuan, et al. Measurement method and system for closing and creeping of switch rail[J]. Metrology & measurement technology, 2021, 41(5): 58-64.
- [14] 郑培珍, 任同群, 王大志, 等. 尖轨横纵位移综合测量系统及远程数据采集与控制[J]. 机电工程技术, 2023, 52(3): 62-66.
- ZHENG Peizhen, REN Tongqun, WANG Dazhi, et al. Comprehensive measurement system for horizontal and vertical displacements of switch rail and its wireless transmission[J]. Mechanical & electrical engineering technology, 2023, 52(3): 62-66.
- [15] 许庆阳, 刘中田, 赵会兵. 基于隐马尔科夫模型的道岔故障诊断方法[J]. 铁道学报, 2018, 40(8): 98-106.
- XU Qingyang, LIU Zhongtian, ZHAO Huibing. Method of turnout fault diagnosis based on hidden Markov model[J]. Journal of the China railway society, 2018, 40(8): 98-106.
- [16] 刘应君, 司涌波, 陈光武, 等. 基于 CDET/MPSO-SVM 的道岔故障诊断[J]. 北京交通大学学报, 2021, 45(2): 52-59.
- LIU Yingjun, SI Yongbo, CHEN Guangwu, et al. Turnout fault diagnosis based on CDET/MPSO-SVM[J]. Journal of Beijing Jiaotong University, 2021, 45(2): 52-59.
- [17] 池毅, 陈光武. 基于一维卷积神经网络的实时道岔故障诊断[J]. 计算机工程与应用, 2022, 58(20): 293-299.
- CHI Yi, CHEN Guangwu. Real-time turnout fault diagnosis based on one-dimensional convolutional neural network[J]. Computer engineering and applications, 2022, 58(20): 293-299.
- [18] 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): 159-163.
- TANG Weihua. Extraction and recognition of switch machine fault features based on lstm/nn[J]. Computer applications and software, 2019, 36(1): 159-163.
- [19] 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): 193-200.
- 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): 193-200.

(编辑: 王艳菊)