

DOI: 10.13382/j.jemi.B2205611

基于 1DCNN-BiLSTM 组合模型的 S700K 转辙机故障诊断*

王瑞峰 李 扬

(兰州交通大学自动化与电气工程学院 兰州 730070)

摘 要:针对 S700K 转辙机故障诊断有效特征提取困难,信号处理与分类算法难以联合优化的问题,提出了一维卷积神经网络(1DCNN)与双向长短期记忆神经网络(bidirectional long short-term memory, BiLSTM)结合的转辙机故障诊断方法。首先,对微机监测系统采集的转辙机功率曲线进行处理;其次,通过卷积神经网络(convolution neural networks, CNN)的卷积层和池化层对处理后的数据自适应提取故障特征;再经过扁平层(Flatten)把提取的故障特征作为 BiLSTM 层的输入,进一步挖掘深层次的特征;最后使用 Softmax 函数实现智能故障诊断。以某铁路局提供的真实数据验证模型,结果显示所提模型的精确率、召回率和 F_1 值等评价指标分别达到 98.99%、98.89% 和 98.89%,相较于其他经典故障诊断模型,1DCNN-BiLSTM 模型在保证训练速度较快的情况下,将故障诊断的准确率至少提升了 1.08%。

关键词: 1DCNN; BiLSTM; S700K 转辙机; 故障诊断

中图分类号: U284 **文献标识码:** A **国家标准学科分类代码:** 580.80

Fault diagnosis of S700K switch machine based on 1DCNN-BiLSTM hybrid model

Wang Ruifeng Li Yang

(School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Aiming at the problems of S700K switch machine fault diagnosis, which is difficult to extract effective features and signal processing and classification algorithms, a fault diagnosis method for switch machine combining one-dimensional convolutional neural network (1DCNN) and bidirectional long short-term memory neural network (BiLSTM) is proposed. Firstly, the power curve of the switch machine collected by the microcomputer monitoring system is processed. Secondly, the fault features are extracted adaptively from the processed data by the convolution layer and pool layer of CNN. Then through Flatten, the extracted fault features are taken as the input of BiLSTM layer to further mine the deep-level features. Finally, the Softmax function is used to implement intelligent fault diagnosis. The model is validated by the real data provided by a railway bureau. The results show that the accuracy, recall and F_1 value of the proposed model reach 98.99%, 98.89% and 98.89% respectively, which are better than other classical fault diagnosis models, 1DCNN-BiLSTM model improves the accuracy of fault diagnosis by at least 1.08% when the training speed is fast.

Keywords: 1DCNN; BiLSTM; S700K switch machine; fault diagnosis

0 引 言

S700K 转辙机作为铁路信号的基础设备,工作环境复杂,技术性能高,当发生故障时能否及时检测维修极大影响着列车行车安全。现阶段,主要凭借维护技术人员的经验对转辙机故障作出判断与处理,而微机监测系统

采集的动作曲线仅作为判据,故障辨别时间长,定位不准等问题不可避免^[1]。随着现代信息化的发展,对转辙机的故障诊断必将趋向全面自动化。

针对 S700K 转辙机故障诊断,传统的方法分为 3 个步骤:1)对原始信号进行预处理,提取功率曲线特征,代表性的方式有表征时频域特征^[2]、小波变换^[3]、经验模态分解^[4]等。2)使用 t 分布-随机邻近嵌入^[5]、主成分分

析^[6]等方式降低特征数据维度。至此完成特征提取部分,但是这些人工特征提取的方式倾向于提高准确率而降低实际泛化能力,提取特征时也不能包含原始功率曲线的所有信息,降维更可能使重要特征丢失,故需要在诊断准确率与特征完整度之间达到平衡。3)通过隐马尔可夫模型^[5-6]、支持向量机^[7]、神经网络^[2]等分类器完成故障分类。至此完成整个故障诊断,但是信号处理和分类器也难以联合优化。

深度神经网络可直接对数据进行建模,挖掘数据与诊断目标的映射关系,CNN、长短期记忆网络(long short-term memory, LSTM)和 BiLSTM 等几种模型在设备故障分类中已经得到了广泛应用^[8-12]。CNN 可以直接应用于原始信号完成特征提取,无需进行复杂的数据预处理(例如特征选择、降维、去噪等)^[13-14],但它不能充分挖掘时序性数据的相关性;LSTM 具有优秀的时序建模能力,但它忽略了时序性数据的完整性;而 BiLSTM 提高了对数据的利用率,但不能突出局部重要信息,也增加了网络深度。

本文提出将 1DCNN 与 BiLSTM 相结合,通过 1DCNN 直接对原始功率数据自适应提取特征,有效避免了传统人工特征提取的复杂性与不确定性,其局部连接和参数共享机制也减小了运算代价;利用 BiLSTM 的双向结构和时间的双向流向充分考虑时序性数据的上下文信息,进一步提取故障特征,提高对数据的利用率;将特征提取与分类融合为一体,利用神经网络自带的 Softmax 函数进行故障分类。因此,整个故障诊断模型是一个整体,在模型训练时只需对整体进行优化,选择最优的结构,最终提高精确诊断。

1 S700K 转辙机功率曲线分析

S700K 转辙机输出工作拉力的具体变化状况可用来判断转辙机的工作状况,而拉力的变化可用转辙机的输出功率体现,因此分析动作功率曲线就能精确判定转辙机是否正常工作。

1.1 正常动作功率曲线分析

S700K 转辙机正常动作功率曲线如图 1 所示,有 5 个阶段。启动阶段,功率迅速上升到一个最大值后下降;随即解锁和转换阶段,功率值在 0.5 kW 上下浮动;然后锁闭时,功率值先稳定后有小幅衰减;最后功率值在表示阶段逐渐衰减为 0 kW。




图 1 S700K 转辙机正常动作功率曲线

Fig. 1 Normal operating power curves of S700K switch machine

1.2 故障动作功率曲线分析

在实际现场, S700K 转辙机常见有 8 种故障类别,其对应的故障功率曲线如图 2 所示,故障现象及原因如表 1 所示。 F_0 表示转辙机正常状态, $F_1 \sim F_8$ 分别表示 8 种故障状态。




图 2 S700K 转辙机故障动作功率曲线

Fig. 2 Fault action power curves of S700K switch machine

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
故障 F ₁	功率在 2.4 s 处小程度上浮并趋于稳定	下拉装备异常,道岔不能正常解锁
故障 F ₂	功率在 2 s 处存在波动,完成时间延长	调整不适,出现非正常阻力,道岔卡阻
故障 F ₃	功率在 4 s 处大幅上升,其值超过 2 kW	动作杆被异物阻碍,道岔转换存在异常
故障 F ₄	功率在 3.8 s 处小幅波动,但能正常转换	道岔杆件等不牢固或安装不当
故障 F ₅	曲线持续上升,并在 4.7 s 锁闭阶段小幅上升	锁闭块或锁舌被卡死,造成锁闭异常
故障 F ₆	锁闭区段 5.1 s 处功率曲线小程度上升后保持	因环境因素导致缺口变化,无法完成锁闭
故障 F ₇	表示阶段曲线正常下降,但没降至 0 kW	道岔表示电路中的断相表示器发生故障
故障 F ₈	表示阶段曲线出现大幅且无规则波动	二极管失效,表示电路故障

2 建立故障诊断模型

原始功率数据处理、1DCNN 特征提取、BiLSTM 特征提取和 Softmax 分类器故障分类 4 个部分。

S700K 转辙机故障诊断过程如图 3 所示。主要包括




图 3 基于 1DCNN-BiLSTM 的 S700K 转辙机故障诊断框图

Fig. 3 Fault diagnosis block diagram of S700K switch machine based on 1DCNN-BiLSTM

2.1 原始功率数据处理

根据《中华人民共和国铁道行业标准》规定的 S700K 转辙机动作时间不大于 6.6 s, 动程为 150~220 mm, 信号微机监测系统对转辙机动作的采样速率不大于 40 ms。为了方便输入到模型中, 只取前 7 s 的功率曲线, 所以共取 175 个点, 而未到 7 s 的向量用 0 补齐, 完成数据的归一化处理, 如式(1)所示。

$$x_c = \frac{x_n - x_{\min}}{x_{\max} - x_{\min}}$$

(1)

其中, x_c 为处理后的结果; x_n 为原始数据; $x_{\max}$ 、 $x_{\min}$ 为最大和最小原始数据值。

2.2 1DCNN 特征提取

传统的 CNN^[15] 采用二维卷积核, 适用于二维数据的特征提取, 但对序列化的数据处理效果不佳^[16], 因此使用一维卷积构造模型处理时序数据, 如图 4 所示。

1) 卷积层

通过大小不同的卷积核与输入分别进行卷积操作完成特征提取, 结果如式(2)所示。




图 4 1DCNN 网络结构图

Fig. 4 1DCNN network structure diagram

$$x_k^l = f(\sum_{i=1}^N x_i^{l-1} * w_{ik}^l + b_k^l)$$

(2)

其中, x_k^l 为 l 层第 k 次卷积映射; $f()$ 为激活函数; N 为输入做卷积的数量; $*$ 为卷积操作; w_{ik}^l 为权值; b_k^l 为偏置量。

本文使用 ReLU 函数防止梯度消失, 如式(3)所示。

$$f(y) = \max(0, y)$$

(3)

2) 池化层

池化层提取主要特征。本文采用最大值池化,如式(4)所示。

$$\hat{x}_k^l = \max(\mathbf{x}_k^l : \mathbf{x}_{k+r-1}^l) \quad (4)$$

其中, $\hat{x}_k^l$ 为向量 $\mathbf{x}_k^l$ 到 $\mathbf{x}_{k+r-1}^l$ 的最大值; r 为步长。

3) Flatten 层

在 Flatten 层中整合经卷积与池化处理后的特征向量,将其作为 BiLSTM 层的输入。

4) 全连接层

各局部特征在全连接层进行整合得到全局特征,最后通过 Softmax 函数计算故障概率值。

2.3 BiLSTM 特征提取

本文将前向 LSTM 和后向 LSTM 组合成 BiLSTM 模型进一步提取深层的特征。

LSTM^[17-18] 网络结构如图 5 所示,它有着独特的门结构用于维持和控制细胞状态,其计算过程分别如式(5)~(10)所示。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t * \tanh(C_t) \quad (10)$$

其中, f_t 、 i_t 、 o_t 分别为 3 个门控的激活值; $\tilde{C}_t$ 为新的候选值向量; C_{t-1} 为之前细胞状态; C_t 为当前细胞状态; h_t 为当前细胞状态; h_{t-1} 为之前状态的输出; x_t 为当前状态的输入; W_f 、 W_i 、 W_c 、 W_o 为权重; b_f 、 b_i 、 b_c 、 b_o 为偏置量; σ 为 sigmoid 激活函数; $\tanh$ 为双曲正切函数。




图 5 LSTM 网络神经元结构图

Fig. 5 LSTM network neuron structure diagram

BiLSTM 网络结构如图 6 所示,每一级隐藏层状态的组合过程如式(11)所示。

$$h_t = \text{LSTM}(x_t, h_{t-1})$$

$$h_i = \text{LSTM}(x_i, h_{i-1}) \quad (11)$$

$$h'_t = a_t h_t + b_t h_i + c_t$$

其中, h'_t 为每一级隐藏层状态; h_t 为前向层状态; h_i 为后向层状态; a_t 、 b_t 为权重; c_t 为偏置。




图 6 BiLSTM 网络结构

Fig. 6 BiLSTM network structure diagram

2.4 Softmax 分类器故障分类

全连接层在最后综合 1DCNN 层和 BiLSTM 层提取的特征完成故障分类。通过 Softmax 函数,输出 S700K 转辙机正常态和 8 种故障态所对应的概率,判断概率最大值所对应的故障类别为最终的诊断结果,如式(12)所示。

$$P(y_j) = \frac{e^{y_j}}{\sum_{z=1}^m e^{y_z}} \quad (12)$$

其中, $P(y_j)$ 为输出层第 j 类的概率值, m 为分类的数量。

此外,在全连接层前嵌入 Dropout,防止训练过程中过度依赖局部特征,避免过拟合问题。

3 仿真实验及结果分析

本文以某铁路局提供的转辙机动作功率曲线作为仿真数据,进行模型性能验证,正常态和每种故障态各取 50 组样本,共 450 组数据作为训练集。模型训练时,由于数据量相对偏少,使用五折交叉验证法提高对数据的利用率。本文通过 Python 语言, TensorFlow 框架实现模型搭建。

3.1 评价指标

本文通过准确率(A)、精确率(P)、召回率(R)和 F_1 值对模型性能进行评价,如式(13)~(16)所示。

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$F_1 = \frac{2TP}{2TP + FP + FN} \tag{16}$$

其中, TP 为正确预判至这一类的样本数; TN 为正确预判未在这一类的样本数; FP 为错判至这一类的样本数; FN 为属于这一类却错判至其他类的样本数。

3.2 训练模型

在深度神经网络中,超参数用于判断模型的参数,而模型参数设置是否恰当直接影响着模型的性能。模型的训练状态可以通过损失值和准确率等指标监测得出。

迭代次数影响着分类精度和训练总体时间,设置过小会引发欠拟合现象;过多则会出现过拟合问题,且增加运算代价。模型在训练过程中的准确率如图 7 所示,当 epoch 到达 35 次后,准确率数值趋于平稳且达到理想效果。




图 7 准确率随 epoch 增加变化曲线

Fig. 7 Accuracy change curve with epoch increase

模型在训练过程中的损失值如图 8 所示,当 epoch 到达 35 次后,训练集和验证集的损失值趋于 0。因此当 epoch 超过 35 次时,模型准确率和损失函数值变化的幅度极小,可以满足实际现场的维护要求,故选取 35 轮次作为最终的迭代轮次。




图 8 损失值随 epoch 增加变化曲线

Fig. 8 Loss change curve with epoch increase

根据仿真结果最终确定故障诊断模型的超参数如

表 2 所示。

表 2 故障诊断模型超参数设置

超参数名称	超参数值
学习率	0.001
Epoch	35
Dropout	0.5
CNN 卷积核个数	64
CNN 卷积核大小	10,5
CNN 激活函数	ReLU
LSTM 层数	2
LSTM 隐藏层节点数	256
损失函数	交叉熵
优化函数	Adam
batch_size	15

3.3 模型性能验证

从微机监测系统中重新获取正常态和每种故障态的转辙机功率曲线数据,各取 20 组样本构成测试集,对本文模型的准确率进行测试。

如图 9 所示,混淆矩阵直观展示出 1DCNN-BiLSTM 模型对各故障类别的分类结果,图中横纵坐标的 0 代表转辙机的正常态 F_0 ,1~8 代表转辙机的故障态 $F_1 \sim F_8$,其中故障 F_4 易被诊断为故障 F_7 ,由图 2 故障功率曲线可发现,故障 F_4 和故障 F_7 的动作功率曲线在整体上有着很大的相似性,这是导致误判的主要因素。除此以外,故障态 F_1 、 F_2 、 F_3 、 F_5 、 F_6 、 F_7 、 F_8 和正常态 F_0 诊断结果均与现场检修结果一致,其准确率达到 97.88%。




图 9 本文模型的混淆矩阵

Fig. 9 Confusion matrix of this paper's model

3.4 不同故障诊断模型性能对比试验

为了进一步验证 1DCNN-BiLSTM 模型在故障诊断性能上的优势,本文利用相同数据集使用不同的算法模型,将该模型与文献[6]的 PCA-HMM、文献[7]的 CDET-

MPSO-SVM、文献[8]的 CNN、文献[9]的 LSTM 和文献[10]的 CNN-LSTM 等 5 个经典故障诊断模型进行对比,结果如表 3 所示。

诊断对比结果显示,1DCNN-BiLSTM 模型在故障类别分类上的精确率、召回率和 F_1 值分别为 98.99%、98.89%和 98.89%,均优于其他模型。相较于 CNN 模型,经 BiLSTM 进一步提取特征的模型准确率确实有了明显的提高,提高了 1.93%;相较于 LSTM 模型,本文模型通过卷积池化操作降低了特征维度,减小了运算代价,使得训练速度提升了 3.39 s,准确率提升了 4.08%;相较于 CNN-LSTM 模型,1DCNN-BiLSTM 模型利用 BiLSTM 的

双向特点进一步挖掘了时序性数据的上下文信息,将模型准确率提高了 1.08%;加之与 PCA-HMM 和 CDET-MPSO-SVM 模型相对比,不管是训练时间还是分类准确率上,传统机器学习的故障诊断模型都远远不如本文模型。同时,由于将 1DCNN 和 BiLSTM 结合使用,使得模型结构相对复杂,但是训练时间也仅仅相较于耗时最少的 CNN 模型高出 0.9 s,就铁路道岔故障诊断任务而言,本文模型已能满足其快速诊断的要求。综上所述,1DCNN-BiLSTM 模型在故障诊断精度与效率均可达到理想效果。

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_1 值/%	准确率/%	训练时间/s
1DCNN	97.87	97.78	97.77	95.95	2.44
LSTM	96.89	96.67	96.66	93.80	6.73
1DCNN-LSTM	98.36	98.33	98.33	96.80	4.16
PCA-HMM	92.74	92.56	92.56	90.53	5.70
CDET-MPSO-SVM	97.26	97.17	97.16	95.27	17.50
1DCNN-BiLSTM	98.99	98.89	98.89	97.88	3.34

3.5 消融实验

为了探究 S700K 转辙机故障诊断 1DCNN-BiLSTM 模型架构中各部分所起的作用,加入多组消融实验分析某个组件对整体性能的影响程度,消融实验步骤如下:

1) 1DCNN,去除 BiLSTM,由 1DCNN 网络作为实验基线模型,1DCNN 提取故障特征,建立故障数据集,再通过的 Softmax 函数得到故障分类结果。

2) BiLSTM,在基线模型的基础上采用 BiLSTM 代替 1DCNN 提取 S700K 转辙机故障特征,使得基线模型更加注重数据的前后相关性。

3) 1DCNN-LSTM,在基线模型的基础上加入 LSTM 模块,提高基线模型对数据的利用率。

4) 1DCNN-BiLSTM,作为本文所提模型,将前 3 个分块实验模型进行融合,利用 1DCNN 初步提取转辙机故障特征,再通过 BiLSTM 进一步挖掘更深层次的特征,最后使用 Softmax 函数输出最终诊断结果。

从微机监测系统中再次获取正常态与每种故障态的

转辙机功率数据各 15 组,4 种模型消融实验性能对比结果如表 4 所示,其中 F_4 道岔杆件不牢固、 F_5 锁闭块或锁舌卡死、 F_6 无法锁闭和 F_7 断相表示器故障。

由表 4 可知,1DCNN-BiLSTM 模型在故障 F_4 、 F_5 、 F_6 和 F_7 这 4 种发生频率较高的故障类别分类上的精确率、召回率和 F_1 值分别不小于 93.75%、93.33%和 96.55%,均优于其他模型。对于故障 F_4 和 F_7 ,即使模型更加注重数据的前后相关性,BiLSTM 模型性能也要弱于 1DCNN 模型,且平均准确率低了 1.27%,平均训练时间增加了 4.33 s。相较于在 1DCNN 模型的基础上增加 LSTM 模型,显然增加 BiLSTM 模型更能充分挖掘数据深层次的特征,对数据的利用率更高,因此 1DCNN-BiLSTM 模型准确率达到 98.56%,相较于 1DCNN-LSTM 模型至少提高了 1.35%,且训练时间为 3.06 s,仅仅较用时最少的 1DCNN 模型多了 0.83 s。综上所述,本文将 1DCNN 与 BiLSTM 有效结合,充分发挥出 1DCNN 与 BiLSTM 的优势,使得模型性能达到理想效果。

表 4 消融实验结果

Table 4 Results of ablation experiment

模型	精确率/%				召回率/%				F_1 值/%				准确率/ %	训练时 间/s
	F_4	F_5	F_6	F_7	F_4	F_5	F_6	F_7	F_4	F_5	F_6	F_7		
1DCNN	93.33	93.75	100	93.33	93.33	100	93.33	93.33	93.33	96.77	96.55	93.33	95.79	2.23
BiLSTM	92.86	100	93.75	87.5	86.67	93.33	100	93.33	89.66	96.55	96.77	90.32	94.52	6.56
1DCNN-LSTM	100	100	100	88.24	86.67	100	100	100	92.86	100	100	93.75	97.21	3.49
1DCNN-BiLSTM	100	100	100	93.75	93.33	100	100	100	96.55	100	100	96.77	98.56	3.06

4 结 论

本文提出了 1DCNN 与 BiLSTM 结合的 S700K 转辙机故障诊断方法,1DCNN 直接对原始功率数据分层特征提取,避免了复杂的信号预处理与特征降维,并将特征提取与诊断分类融合到一个学习体系中联合优化,以微机监测系统转辙机动作功率曲线进行仿真分析及性能对比。结果表明,相较于传统信号特征提取的方法,该方法的精确率、召回率和 F_1 值至少提高了 1.73%、1.72% 和 1.73%,训练时间至少减少了 2.36 s;该模型分类准确率达到 97.88%,与其他故障诊断模型相比,准确率至少提升了 1.08%。因此,将 1DCNN 与 BiLSTM 结合的方法可以有效提升 S700K 转辙机故障诊断模型的性能。对于未知原始功率曲线,该模型可在 2 s 内完成诊断分类,可以满足道岔故障快速诊断的要求,能适用于铁路现场的实时道岔故障检测。

参考文献

- [1] OU D X, XUE R, CUI K. A data-driven fault diagnosis method for railway turnouts[J]. Transportation Research Record, 2019, 2673(4): 448-457.
- [2] 孔令刚,焦相萌,陈光武,等. 基于多域特征提取与改进 PSO-PNN 的道岔故障诊断[J]. 铁道科学与工程学报, 2020, 17(6): 1327-1336.
KONG L G, JIAO X M, CHEN G W, et al. Turnout fault diagnosis based on multi-domain feature extraction and improved PSO-PNN [J]. Journal of Railway Science and Engineering, 2020, 17(6): 1327-1336.
- [3] 武晓春,楚昕. 基于小波包分解与 GG 模糊聚类的转辙机退化阶段划分研究[J]. 铁道学报, 2022, 44(1): 79-85.
WU X CH, CHU X. Research on division of degradation stage of turnout equipment based on wavelet packet decomposition and GG fuzzy clustering[J]. Journal of the China Railway Society, 2022, 44(1): 79-85.
- [4] LEI M H, YANG P. Development of diagnosis system based on mixed programming and combined extraction method for switch machine [J]. Hydromechatronics Engineering, 2014, 42(6): 59-63.
- [5] 周智利. 基于 HMM 的转辙机故障预测研究[D]. 成都:西南交通大学, 2020.
ZHOU ZH L. Research on fault prediction of switch machine based on hidden markov model[D]. Chengdu: Southwest Jiaotong University, 2020.
- [6] 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 Q Y, LIU ZH T, ZHAO H B. Method of turnout fault diagnosis based on hidden Markov model [J]. Journal of the China Railway Society, 2018, 40(8): 98-106.
- [7] 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 Y J, SI Y B, CHEN G W, et al. Turnout fault diagnosis based on CDET/MPSO-SVM [J]. Journal of Beijing Jiaotong University, 2021, 45(2): 52-59.
- [8] 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 Y, CHEN G W. Real-time turnout fault diagnosis based on one-dimensional convolutional neural network[J]. Computer Engineering and Applications, 2022, 58(20): 293-299.
- [9] 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 W H. Extraction and recognition of switch machine fault features based on LSTM/NN [J]. Computer Applications and Software, 2019, 36(1): 159-163.
- [10] 韩宇,李剑,马慧宇,等. 基于 CNN-LSTM 的桥梁结构损伤诊断方法[J]. 国外电子测量技术, 2021, 40(7): 1-6.
HAN Y, LI J, MA H Y, et al. Bridge structure damage diagnosis method based on CNN-LSTM [J]. Foreign Electronic Measurement Technology, 2021, 40(7): 1-6.
- [11] 王雨虹,王志中,付华,等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研[J]. 仪器仪表学报, 2022, 43(3): 87-97.
WANG Y H, WANG ZH ZH, FU H, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [12] 陈保家,陈学力,肖文荣,等. 小样本下滚动轴承故障的多源域迁移诊断方法[J]. 电子测量与仪器学报, 2022, 36(2): 219-228.
CHEN B J, CHEN X L, XIAO W R, et al. Multi-source domain transfer diagnosis method for rolling bearing faults under small samples [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 219-228.
- [13] 刘立,朱健成,韩光洁,等. 基于 1D-CNN 联合特征提取的轴承健康监测与故障诊断[J]. 软件学报, 2021, 32(8): 2379-2390.
LIU L, ZHU J CH, HAN G J, et al. Bearing health

- monitoring and fault diagnosis based on joint feature extraction in 1D-CNN [J]. Journal of Software, 2021, 32(8): 2379-2390.
- [14] 郑一珍, 牛蒯楷, 熊晓燕, 等. 基于一维卷积神经网络的圆柱滚子轴承保持架故障诊断[J]. 振动与冲击, 2021, 40(19): 230-238, 285.
- ZHENG Y ZH, NIU L K, XIONG X Y, et al. Fault diagnosis of cylindrical roller bearing cage based on 1D convolution neural network[J]. Journal of Vibration and Shock, 2021, 40(19): 230-238, 285.
- [15] CHEN Y, QU R. Study on infringement identification of art works based on CNN image recognition technology [J]. Journal of Physics: Conference Series, 2021, 1802(3): 032084.
- [16] 韩晓东, 李光亚, 胡雅妮, 等. 基于一维 CNN 的时域超声信号识别技术研究[J]. 电子测量技术, 2022, 45(12): 20-25.
- HAN X D, LI G Y, HU Y N, et al. Research on time-domain ultrasonic signal recognition technology based on one-dimensional CNN [J]. Electronic Measurement Technology, 2022, 45(12): 20-25.
- [17] LIU H, LIN F, CHEN D H. A novel wind DC microgrid energy management strategy based on LSTM forecast

model[J]. Journal of Physics: Conference Series, 2021, 1871(1): 012014.

- [18] CHI D W. Research on electricity consumption forecasting model based on wavelet transform and multi-layer LSTM model [J]. Energy Reports, 2022, 8: 220-228.

作者简介



王瑞峰(通信作者), 1989 年于兰州铁道学院获得学士学位, 现为兰州交通大学教授, 主要研究方向为交通信息工程及控制。

E-mail: 3599083622@qq.com

Wang Ruifeng (Corresponding author)

received her B. Sc. degree from Lanzhou Railway College in 1989. Now she is a professor at Lanzhou Jiaotong University. Her main research interests include traffic information engineering and control.



李扬, 现为兰州交通大学硕士研究生, 主要研究方向为转辙机故障诊断。

E-mail: 2460252843@qq.com

Li Yang is a M. Sc. candidate at Lanzhou Jiaotong University. His main research interest includes fault diagnosis of switch machine.