· 70 ·

DOI: 10. 13382/j. jemi. B2407452

基于 DRSN-BiLSTM 的 S700K 转辙机故障诊断*

王瑞峰 王 智

(兰州交通大学自动化与电气工程学院 兰州 730070)

摘 要:在铁路系统中,转辙机是确保列车安全顺畅运行的关键设备。S700K 转辙机的故障诊断对于预防事故和维护铁路运营 至关重要。为了解决传统诊断方法在速度和准确性上的不足,提出了一种融合深度残差收缩网络(DRSN)与双向长短期记忆 神经网络(BiLSTM)的诊断模型。首先,对转辙机功率曲线进行预处理;其次,利用 DRSN 对预处理数据进行自动特征学习,并 压缩数据长度,提高诊断的快速性,其注意力机制和软阈值化降低了噪声特征的影响,并且 DRSN 网络结构有助于克服网络退 化和过拟合的问题;随后,利用 BiLSTM 的双向结构捕捉时间序列数据中复杂的关系;最后使用 Softmax 分类器进行故障分类。 仿真结果表明 DRSN-BiLSTM 模型的准确率、精确率、召回率均超过了 98.3%,并且该模型故障诊断的准确率相较于 DRSN、深 度神经网络(DNN)和卷积神经网络(CNN)等模型至少提高了 1.47%,并且在添加 15~40 db 高斯白噪声情况下准确率保持在 92.7%以上,较其余模型至少提升 2%。该模型在确保训练过程的高效性的同时提升了转辙机故障诊断准确率,并且在噪声环 境下展现出了优秀的鲁棒性。

关键词: DRSN; BiLSTM; S700K 转辙机; 故障诊断

中图分类号: U284.2; TN911.6 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 DRSN-BiLSTM hybrid model

Wang Ruifeng Wang Zhi

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

Abstract: In the railway system, the switch machine is a critical device to ensure the safe and smooth operation of trains. Fault diagnosis of the S700K switch machine is crucial for accident prevention and the maintenance of railway operations. To address the shortcomings of traditional diagnostic methods in terms of speed and accuracy, a diagnostic model integrating a deep residual shrinking network with a bidirectional long short-term memory network is proposed. First, the power curve of the switch machine is preprocessed. Next, DRSN is used to automatically learn features from the preprocessed data and compress the data length, improving the speed of diagnosis. Its attention mechanism and soft thresholding reduce the influence of noise features, and the DRSN structure helps to overcome network degradation and overfitting issues. Following that, the bidirectional structure of BiLSTM is utilized to capture complex relationships in the time-series data. Finally, a Softmax classifier is employed for fault classification. Simulation results show that the accuracy, precision, and recall rates of the DRSN-BiLSTM model all exceed 98.3%. Compared with models such as DRSN, deep neural network, and convolutional neural network, the diagnostic accuracy of this model is improved by at least 1.47%. Even when Gaussian white noise in the range of $15 \sim 40$ dB is added, the accuracy remains above 92.7%, an improvement of at least 2% over other models. This model not only ensures the efficiency of the training process but also improves the accuracy of point machine fault diagnosis and demonstrates excellent robustness in noisy environments.

Keywords: DRSN; BiLSTM; S700K switch machine; fault diagnosis

收稿日期: 2024-04-19 Received Date: 2024-04-19

^{*}基金项目:国家自然科学基金(61763025)项目资助

0 引 言

在现代铁路系统中,S700K 转辙机担任着至关重要的角色,它不仅保障列车的安全通行,也是提升铁路运输效率的关键。因其户外工作环境的复杂性而容易发生故障,对铁路的安全运营构成潜在风险。鉴于此,研究和开发高效的故障诊断技术,以便准确快速地检测和处理这些故障,已经成为铁路系统维护工作中的一个重点研究方向^[1]。

传统的 S700K 转辙机故障诊断使用小波变换^[2]、经 验模态分解^[3]、Fisher 准则函数^[4]等进行特征提取,以支 持向量机等为分类器,两者相结合实现故障诊断。例如, 赵林海等^[4]采用 Fisher 准则选择相应故障模式的特征向 量,通过待测样本与各故障模式特征间的灰色关联度,结 合门限得到故障诊断结果。许庆阳等^[5]建立了不同故障 模式下的隐马尔科夫模型,描述每一种退化状态之间的 状态转移,实现道岔健康状态监测与诊断。刘应君等^[6] 提取道岔功率曲线时域特征并降维,以支持向量机作为 分类器对道岔故障进行分类。尽管传统的特征提取方法 能够关注数据中的相关性和因果关系,但这种方法可能 会过分强调准确率而忽视了模型的泛化能力。为了避免 这种情况,应运用深度神经网络强大的学习能力完成对 原始信号的特征提取。

深度学习具有更强的表示学习能力,能够学习复杂的函数,直接从原始数据将输入映射到输出。卷积神经网络(convolutional neural network, CNN),长短期记忆网络(long short-term memory, LSTM),残差神经网络(residual neural network, ResNet)等作为深度学习的代表,在故障诊断领域广泛应用。池毅等^[7]采用的卷积神经网络进行道岔故障诊断。唐维华^[8]采用 LSTM 自动提取特征,再利用神经网络分类器来对转辙机进行故障识别。赵小强等^[9]采用 ResNet 对工况进行故障诊断。

虽然基于深度学习的转辙机故障诊断方法有很多研究,由于转辙机工作环境复杂,存在噪声信号混杂到采集的信号之中,对判断转辙机是否发生故障有一定的干扰。 上述模型未考虑到该种情况,故障诊断会存在一定偏差。 基于此,提出基于深度残差收缩网络(deep residual shrinkage networks, DRSN)和双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)的转辙机故 障诊断方法。通过 DRSN 对原始信号执行自适应特征学 习,提高了特征提取的准确性和可靠性,其内置的注意力 机制和软阈值化设计极大地提升了含噪数据的利用 率^[10];利用 BiLSTM 的双向结构捕捉时间序列数据中复 杂的关系,提高数据的利用率;并用 softmax 分类器进行 故障分类。整个故障诊断模型构成一个完整的整体,在 训练过程中只需对该整体进行优化,选择最佳的结构,以 提高诊断精确度。

1 S700K 转辙机功率曲线分析

在分析 S700K 交流式转辙机动作故障时,其输出工 作拉力变化是判断其工作状态的重要指标。这些变化通 过转辙机的输出功率得到体现^[11]。因此,通过分析动作 功率曲线,可以准确地判断转辙机的运行是否正常。

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。在启 动阶段,功率曲线急剧上升至一个明显的峰值,表明转辙 机动作的开始,并且预示着即将进行的动作序列。随后 转辙机进入动作过程,功率曲线呈现出一系列波动,这些 波动反映了斥离尖轨的运动特性。当转辙机达到锁闭状 态,功率曲线随之下降,直至在缓放阶段结束时降至零, 此时转辙机完成了一次完整的操作周期。



1.2 故障动作功率曲线分析

在铁路现场对 S700K 转辙机进行的故障记录统计分 析中,各种故障的具体现象和成因如表 1 所示,相对应的 故障功率曲线如图 2 所示。

2 模型设计

由于采集到的功率数据包含噪声信息,因此使用 DRSN模型对预处理数据进行特征学习,并降低了噪声 的影响。但其忽略功率数据中的长期依赖关系,因此加 入 BiLSTM 进一步挖掘功率数据的内在特征,提高数据 的利用率。最后利用神经网络自带的 Softmax 函数进行 故障分类。

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
--	---------	--------	--------	-----	--------	----	-------	--------	---------



Fig. 2 Fault action power curves of S700K switch machine

2.1 原始功率数据处理

S700K型转辙机的动作时间应不超过 6.6 s。信号 微机监控系统对转辙机动作的采样频率应不超过 40 ms。便于模型输入,采用前 7 s 内的功率曲线数据,即选取 176 个数据点^[12]。对于不足 7 s 的部分,使用 0 来填充向 量。在进行模型训练之前,需要对数据使用式(1)进行 归一化处理。

$$x_n = \frac{x_c - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

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

2.2 深度残差收缩网络

深度残差收缩网络^[13]是一种改进深度残差网络^[14] 模型,通过在 ResNet 中引入软阈值化模块和注意力机 制,使得网络能够更有效地识别和区分含噪数据。 软阈值化是一种常用于信号降噪的算法。其核心原 理是将输入数据逐步收缩至零点附近,从而在减少噪声 干扰的同时保留信号的主要特征,软阈值化公式如 式(2)所示。

$$y = \begin{cases} x - \tau, & x > \tau \\ 0, -\tau \le x \le \tau \\ x + \tau, & x < -\tau \end{cases}$$
(2)

其中,x,y表示输入和输出特征,T表示阈值(T>0)。

由式(2)可知,软阈值化的核心为阈值 τ 的获取。注 意力机制中的挤压激励网络(squeeze-and-excitation networks, SENet)通过一个小型网络学习到每个特征通 道的重要性,并生成相应的权重系数,这些权重系数用于 对特征通道进行加权,从而突出重要特征,抑制不重要特 征。使用软阈值操作将 SENet 中的加权操作替代,形成 的网络可以自适应地调整每个样本的阈值 τ 。SENet 模 块如图 3 所示。





Fig. 3 SENet module

图 3 中 F_{u} 为卷积操作,将尺寸为 $W' \times H' \times C'$ 的特征 输入 X 转换成尺寸为 $W \times H \times C$ 的特征输出 U_{\circ} F_{sq} 为挤压 操作,通过全局平均池化将每个通道上的整个空间特征 编码为全局特征,将 U 的维度压缩为 $1 \times 1 \times C$; F_{ex} 为激励 操作,学习各通道间的非线性关系。 F_{scale} 是将每个通道 被 Sigmoid 激活后的值乘以 U 上原始特征。

DRSN 的核心思想是在深度残差网络的基础上,引 入软阈值函数来消除噪声相关特征的影响,从而提高网 络的泛化能力和鲁棒性。软阈值化的阈值的设置是一个 难题。SENet 通过引入软阈值函数替代传统的非线性 层,不仅简化了模型结构,而且通过对每个特征通道进行 软阈值处理,实现了阈值的自适应调整。DRSN 的基本 模块为残差收缩单元,结构如图4所示。



Fig. 4 Residual shrinkage unit structure

图4中输入和输出特征的尺寸均为*C*×W×1,BN表示批标准化,ReLU表示整流线性单元激活函数,Conv表示卷积层,其中*K*表示卷积中卷积核的个数,GAP表示全局均值池化。恒等路径不仅能解决梯度消失问题,而且在模型训练时,损失能通过残差项的恒等映射以实现更为方便的反向传播。

2.3 双向长短时记忆网络

BiLSTM^[15]通过结合两个方向的信息流动,提高了对 序列数据的提取能力。其由两个LSTM 层组成,一个负 责正向(从左到右)处理输入序列,另一个负责逆向(从 右到左)进行同样操作。LSTM^[16-17]网络结构如图 5 所 示,它有3个独特的门结构控制着信息在网络中的流动, 具体计算过程如式(3)~(8)所示。

- $f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$ (3)
- $i_{t} = \sigma(W_{i} \cdot [h_{t-1}, x_{t}] + b_{i})$ $\tag{4}$

$$\widetilde{C}_{t} = \tanh(W_{c} \cdot [h_{t-1}, x_{t}] + b_{c})$$
(5)

$$C_t = f_t * C_{t-1} + i_t * \widetilde{C}_t \tag{6}$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$
⁽⁷⁾

$$h_t = o_t * \tanh(C_t) \tag{8}$$

其中, W_o 、 W_c 、 W_i 和 W_f 为权重, b_o 、 b_c 、 b_i 和 b_f 为偏置 项, σ 为 Sigmoid 激活函数, tanh 为双曲正切激活函数, * 为卷积。



Fig. 5 Structure diagram of LSTM network neurons

BiLSTM 网络同时提取正向和反向特征,BiLSTM 网络结构如图 6 所示。其中隐藏层的表达式如式 9 所示。

其中, h_i 为前向隐藏层状态, h_i 为后向隐藏层状态, a_i 、 b_i 为权重; c_i 为偏置。



2.4 Softamx 分类器故障分类

将 DRSN 层和 BiLSTM 层的特征整合,随后通过 Softmax 计算得出最高概率的故障。如式(10)所示。

$$P(y_{j}) = \frac{e^{y_{j}}}{\sum_{z=1}^{m} e^{y_{z}}}$$
(10)

其中, $p(y_j)$ 为输出层第 j 类的概率值, m 为分类的数量。

3 实验仿真及结果分析

通过 Python 进行模型搭建,以某铁路局的 450 组转 辙机动作功率曲线数据为例,其中包括正常状态及 8 个 故障状态数据各 50 组。9 种状态数据中各抽取 35 组样 本,共 315 组数据作为训练集。采用 DRSN-BiLSTM 模型 对转辙机进行故障诊断,并利用准确率 A、精确率 P、召回 率 R、F1 分数等指标,将其性能与其他传统模型进行了 比较分析。指标如式(11)~(14)所示。

$$A = \frac{TP + TN}{TP + TN + FP + FN}$$
(11)

$$P = \frac{TP}{TP + FP} \tag{12}$$

$$R = \frac{TP}{TP + FN} \tag{13}$$

$$F_1 = \frac{2TP}{2TP + FP + FN} \tag{14}$$

3.1 模型训练

在深度神经网络的应用中,超参数的选择对模型的 整体性能会产生显著影响。不同超参数对 DRSN-BiLSTM 模型性能影响如表 2 所示。由表 2 可知在学习 率为 0.001,批量大小为 32,残差块数为 4,LSTM 层数及 其隐藏成节点数分别为 2 和 128,优化函数为 Adam 时模 型的综合性能最佳。

表 2 不同超参数配置下 DRSN-BiLSTM 模型性能评估

Table 2 Performance evaluation of DRSN-BiLSTM model under different hyperparameter configurations

学习率	批量大小	残差块数	LSTM 层数	LSTM 隐藏层节点数	优化函数	准确率	训练时间/s
0.001	32	4	2	128	Adam	0.981	3.14
0.001	64	4	2	128	Adam	0.961	2.5
0.001	32	4	2	128	SGD	0. 92	4.21
0.001	32	4	2	256	Adam	0.976	5.34
0.01	32	4	2	128	Adam	0. 921	2.41
0.001	32	3	2	128	Adam	0.963	2.68
0.001	32	5	2	128	Adam	0.983	4.6

准确率随迭代次数变化曲线如图 7 所示,模型在训练过程中的准确率随着迭代次数的增加而提高,最终达到 98.42%。当迭代次数达到 45 次时,模型表现出最佳的网络效果。损失值随迭代次数变化曲线如图 8 所示,当迭代次数到达 45 次后,训练集和验证集的损失值趋于稳定。综上,选择 45 轮次作为最终的迭代轮次。



3.2 对比试验

为了验证 DRSN-BiLSTM 模型在故障诊断的有效性, 利用相同数据集将该模型与 CDET/MPSO-SVM 模型、



图 8 损失值随 epoch 增加变化曲线 Fig. 8 Curve of loss value with increasing epoch

PCA-HMM 模型、深度神经网络(deep neural network, DNN)^[18]、CNN^[19]、BiLSTM^[20]、LSTM、DRSN 和 k 近邻算 法(k-nearest neighbor, KNN)^[21]进行对比,每个模型进行 了 20 次重复实验,并计算平均值以评估模型性能。结果 如表 3 所示。除 KNN 由于其在多次实验中的分类错误 频繁变化而未进行深入分析外,其他模型的混淆矩阵如 图 9(a)~(h)所示。

诊断对比结果显示, DRSN-BiLSTM 模型在故障类别 分类上的准确率、精确率和召回率值分别为 98.33%、 PCA-HMM

表 3 不同诊断模型性能对比

81.56

81.56

Table 3 Performance comparison of different diagnostic models										
模型名称	准确率/%	精确率/%	召回率/%	F1 值	训练时间/s					
DRSN-BiLSTM	98.33	98.69	98. 52	98.61	3.41					
DRSN	96.45	97.22	97.03	97.12	2.72					
BiLSTM	92.67	94.44	92. 59	93.51	7.12					
CNN	95.65	96.45	95.56	96.11	2.44					
DNN	83.28	87.63	86. 22	86.91	2.15					
LSTM	87.59	90.96	89. 21	90.07	6.64					
KNN	89.62	91.23	91.22	91.22	1.75					
CDET/MPSO-SVM	97.26	97.17	97.16	97.16	17 50					

81.58

82.74



Fig. 9 Confusion matrix of different models

5.70

98.69%和98.52%,均优于其他模型。由表3可知,DNN 模型和 PCA-HMM 模型准确率分别为 83.23% 和 82.74%。由图9(f)和(h)可知, PCA-HMM 和 DNN 对 F1 ~F6 故障不能正确分类,在于其内部结构对数据结构特 征以及时序特征的提取效果均不佳。LSTM 模型的平均 准确率为 87.59%,由图 9(e)可知 LSTM 模型对 F1、F2、 F4、F5、F6和F7故障无法进行准确分类。BiLSTM模型 由于充分学习了上下文数据的信息,因此 BiLSTM 模型 相较于 LSTM 模型的平均准确率更高,达到了 92.67%, 但由图 9(d) 可知 BiLSTM 模型对故障 F6 和 F7 能准确识 别,但误判故障 F1、F2、F4 和 F5,说明模型对局部特征提 取有欠缺。DRSN 模型的平均准确率为 96.45%, 由图 9(b)可知, DRSN 模型对故障 F1、F2、F3 和 F5 实现准确 分类,但误判故障 F4、F6 和 F7,表明在时序特征的提取 上, DRSN 相较于 BiLSTM 模型较弱。由表 3 和图 9(g) 可知,CDET/MPSO-SVM 模型不仅准确率高于 DRSN 模 型,而且对故障 F6 实现准确分类,但训练时间远超 DRSN 模型。

对于各个模型的运行速度,KNN运行速度最快,但 在诊断稳定性方面表现不佳。而 DRSN 和 CNN 模型虽 然在训练时间上与 DRSN-BiLSTM 模型相近,但在准确性 方面, DRSN-BiLSTM 模型展现了更高的水平。LSTM 模 型和 BiLSTM 模型在训练时间和准确率方面均不及 DRSN-BiLSTM 模型。且该模型的准确率相比于 CNN 模 型提高了 2.68%,相比于 DRSN 模型提高了 1.88%,但训 练时间只比 CNN 模型多0.97s,能够满足诊断的快速性。

3.3 消融实验

为了探究 DRSN-BiLSTM 模型架构中各部分对诊断 性能的影响。取 9 种状态的功率数据各 15 组进行消融 实验。消融实验结果如表 4 所示。DRSN-BiLSTM 模型 在频繁发生的 F4~F7 故障类别的分类任务中,评价指标 均优于其他模型。由表 4 可知,对于故障 F4 和 F7, DRSN 模性性能弱于 BiLSTM 模型,表明 BiLSTM 对时序 特征提取能力更强。但对于故障 F5, DRSN 模型优于 BiLSTM 模型,表明其具有对单点数据更强的特征提取能 力。DRSN-BiLSTM 模型的准确率为 98.56%高于其余模 型,且训练时间相较于 BiLSTM 模型缩短了 3.5 s。综上 所述, DRSN-BiLSTM 模型结合 DRSN 和 BiLSTM 的优点, 提升了模型的数据提取能力,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/%				भीः स्रे के 101	训练时间(
	F4	F5	F6	F7	F4	F5	F6	F7	F4	F5	F6	F7	- 催佣伞/%	则练时问/S
DRSN	86.67	100	100	81.33	86.63	100	93.33	86.64	86.65	100	96.55	83.9	96. 79	2. 53
BiLSTM	100	86.67	93.33	80. 52	93.33	86.33	100	100	96.55	86.49	96.55	89.2	93. 52	6.56
DRSN-BiLSTM	100	100	100	92.75	93.33	100	100	100	96.55	100	100	96.24	98.56	3.06

3.4 抗噪性分析

在实际的数据采集过程中,数据往往会包含一些噪声。为了模拟这种情况并提高模型的鲁棒性,向训练集和测试集中添加不同信噪比的高斯白噪声,将 DRSN-BiLSTM 模型与 DRSN 模型、CNN 模型和 BiLSTM 模型进行测试,结果如图 10 所示。测试结果表明,随着信噪比的降低,所有模型的准确率都有所下降。对于信噪比大于 30~40 db 的低噪声数据,BiLSTM 模型表现最差,准确率不足 90%,而 DRSN-BiLSTM 模型能保持 95%以上的准确率。且对于信噪比小于 15~25 db 的噪声数据,仍能保持 92.7%以上的准确率。综上,DRSN-BiLSTM 模型展现出了良好的抗噪声能力,能够有效地处理在数据采集过程中不可避免的噪声干扰。

4 结 论

文中提出了融合 DRSN 模型与 BiLSTM 模型的 S700K 转辙机故障诊断方法, DRSN 模型通过注意力机



制和软阈值化处理,有效地消除了噪声的影响,并且避免 了复杂的信号预处理与特征降维。加入 BiLSTM 模型, 利用其时序特征提取能力强的特点挖掘更深层特征,并 将特征提取与诊断分类进行联合优化。相比 DRSN、 BiLSTM 等模型, DRSN-BiLSTM 结合的方法在保证运行 速度的同时,其精确率、召回率和 F₁ 值至少提高了 1.47%、1.49%和 1.49%,并且在数据添加噪声的情况 下,该方法仍能保持 92.7%以上的准确率。因此 DRSN 与 BiLSTM 结合的方法,能够满足实际现场诊断需求。 尽管文中提出的方法在转辙机故障诊断上取得良好的结 果,但仍存在不足的地方。神经网络算法复杂度大,应进 一步优化模型结构以缩减训练时间,从而提高模型的网 络负载和实时性。

参考文献

 [1] 李新琴,张鹏翔,史天运,等.基于深度学习集成的高速铁路信号设备故障诊断方法[J].铁道学报,2020, 42(12):97-105.

> LI X Q, ZHANG P X, SHI T Y, et al. Fault diagnosis method of high speed railway signal equipment based on deep learning integration [J]. Journal of Railways, 2020, 42(12): 97-105.

[2] 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.

 [3] 雷默涵,杨萍.基于混合编程和结合特征提取方法的 转辙机故障诊断系统开发[J].机床与液压,2014, 42(6):59-63.

LEI M H, YANG P. Development of fault diagnosis system for switch machine based on hybrid programming and feature extraction method [J]. Machine and Hydraulics, 2014, 42(6): 59-63.

[4] 赵林海,陆桥.基于灰关联的道岔故障诊断方法[J]. 铁道学报, 2014, 36(2): 69-74.

ZHAO L H, LU Q. Method of turnout fault diagnosis based on grey correlation analysis [J]. Journal of the China Railway Society, 2014, 36(2): 69-74.

- [5] 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.
 XUQY, LIUZHT, ZHAOHB. Method of turnout fault diagnosis based on hidden markov model [J]. Journal of the China Railway Society, 2018, 40(8): 98-106.
- [6] 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. Switch fault diagnosis based on CDET/MPSO-SVM [J]. Journal of Beijing Jiaotong University, 2021, 45(2): 52-59. [7] 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 diagnosisbased on one-dimensional convolutional neural network [J]. Computer Engineering and Applications, 2022, 58(20): 293-299.

- [8] 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.
- [9] 赵小强,梁浩鹏.使用改进残差神经网络的滚动轴承 变工况故障诊断方法[J].西安交通大学学报,2020, 54(9):23-31.
 ZHAO X Q, LIANG H P. A fault diagnosis method of rolling bearing under variable conditions using improved residual neural network [J]. Journal of Xi' an Jiaotong University, 2020, 54(9):23-31.
- [10] ZHAO M H, ZHONG SH SH, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.
- [11] 王瑞峰,陈旺斌.基于灰色神经网络的 S700K 转辙机 故障诊断方法研究[J].铁道学报,2016,38(6): 69-72.

WANG R F, CHEN W B. Research on fault diagnosis method for s700k switch machine based on grey neural network [J]. Journal of the China Railway Society, 2016, 38(6): 69-72.

- [12] 米根锁,窦媛媛. 基于 CEEMDAN 与改进核极限学习 机的 S700K 转辙机健康状态诊断[J]. 电子测量与仪 器学报, 2023, 37(6): 232-239.
 MI G S, DOU Y Y. Health status diagnosis of S700K switch machine based on CEEMDAN and improved nuclear extreme learning machine [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 232-239.
- [13] 唐世钰,童靳于,郑近德,等.改进的深度残差收缩网络轴承故障诊断方法[J].振动与冲击,2023,42(18):217-224,285.
 TANG SH Y, TONG J Y, ZHENG J D, et al. Improved deep residual shrinkage network bearing fault diagnosis method[J]. Vibration and Shock, 2023, 42(18):217-224,285.
- [14] HE K M, ZHANG X Y, REN SH Q, et al. Deep

residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

[15] 陈安民,张春元,张泽林.基于长短期记忆网络的无人 机认知无线电频谱预测[J].国外电子测量技术, 2021,40(1):37-43.

CHEN AN M, ZHANG CH Y, ZHANG Z L. Drone cognitive radio spectrum prediction based on long short term memory networks [J]. Foreign Electronic Measurement Technology, 2021, 40(1): 37-43.

- [16] LIU H, LIN F, CHEN D H. A novel wind DC microgrid energy management strategy based on LSTM forecast model[C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1871(1): 012014.
- [17] CHI D W. Research on electricity consumption forecasting model based on wavelet transform and multilayer LSTM model [J]. Energy Reports, 2022, 8: 220-228.
- [18] 宋继明,毛继兵,马卫华,等. 基于深度神经网络的特高压变压器滤油注油过程故障诊断技术研究[J]. 电网与清洁能源,2023,39(12):95-103.
 SONG J M, MAO J B, MA W H, et al. Research on oil filtration and injection process fault diagnosis for ultrahigh

voltage transformers based on deep neural networks [J]. Power System and Clean Energy, 2023, 39 (12): 95-103.

 [19] 伍济钢,文港,杨康.改进一维卷积神经网络的航空发动机故障诊断方法[J].电子测量与仪器学报,2023, 37(3):179-186.

> WU J G, WEN G, YANG K. An improved onedimensional convolutional neural network method for aircraft engine fault diagnosis [J]. Journal of Electronic

Measurement and Instrumentation, 2023, 37 (3): 179-186.

 [20] 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究[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 multistrategy sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2021, 40(1): 95-101.

 [21] ABEYWICKRAMA T, CHEEMA M A, TANIAR D. Knearest neighbors on road networks: A journey in experimentation and in-memory implementation [J]. Proceedings of the VLDB Endowment, 2016, 9(6): 492-503.

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.



王智,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

Wang Zhi is a M. Sc. candidate at Lanzhou Jiaotong University. His main research interest includes fault diagnosis of

switch machine.