

融入时间序列表征的充电桩复杂故障诊断方法

杨凤坤^{1,2}, 李珺³, 吕海涛^{1,2}, 陈良亮^{1,2}, 郭志冲⁴

(1. 国网电力科学研究院有限公司, 江苏 南京 211106;

2. 国电南瑞南京控制系统有限公司, 江苏 南京 211106;

3. 国网江苏省电力有限公司营销服务中心, 江苏 南京 210000;

4. 东南大学 电气工程学院, 江苏 南京 210096)

摘要:随着电动汽车的飞速发展,充电桩的可靠性和安全性成为保障用户安全和提升出行体验的关键因素。针对已有充电桩故障诊断方法在复杂故障检测中建模因素单一、少样本故障类型表现较差的问题,考虑了充电桩维修工单、历史运营账单以及充电桩上报数据的数据,提出了一种融入时间序列表征的充电桩复杂故障诊断方法。首先,对充电桩工单、订单、报文数据进行数据补全与归一化处理。其次,采用特征工程技术与双向门控循环单元Bi-GRU来提取充电过程中多源数据的关键特征与温度、电压、电流等时序故障表征。最后,基于表征后的数据样本,采用机器学习进行学习训练,判断充电桩是否故障以及复杂故障的类型。实验结果表明,所提方法较单一的机器学习与深度学习表征方法在准确率、精确率、召回率和F1值上均有较好的表现。

关键词:充电桩;复杂故障诊断;双向门控循环单元;时间序列表征

中图分类号:TM910.6;U491.8 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed26616

Complex Fault Diagnosis Method of Charging Piles Integrating with Time Series Representation

YANG Fengkun^{1,2}, LI Jun³, LÜ Haitao^{1,2}, CHEN Liangliang^{1,2}, GUO Zhichong⁴

(1. State Grid Electric Power Research Institute, Nanjing 211106, Jiangsu, China;

2. NARI-TECH Control System Co., Ltd., Nanjing 211106, Jiangsu, China;

3. State Grid Jiangsu Electric Power Company Marketing Service Center, Nanjing 210000, Jiangsu, China;

4. School of Electrical Engineering, Southeast University, Nanjing 210096, Jiangsu, China)

Abstract: With the rapid development of electric vehicles over the past decade, the reliability and safety of charging piles have become key factors in ensuring user safety and enhancing the travel experience. Aiming at existing fault diagnosis methods that model the tasks with single factors and have the poor performances of fault types with few samples in complex fault detection in charging piles, a complex fault diagnosis method was proposed for charging piles that incorporates time-series characterization by taking into account the data of charging pile maintenance work orders, historical operation bills, and charging pile uploaded messages. Firstly, the method completes and normalizes the values of work order, order and message data of the charging pile. Secondly, feature engineering and bidirectional gated recurrent unit (Bi-GRU) are employed to extract the important features of multi-source data and the time series fault representations (temperature, voltage and electricity) during charging. Finally, with the characterized data samples, the methods of machine learning are utilized for training so as to judge whether the charging pile is faulty and the types of complex faults. The experimental results show that the method proposed outperforms the single machine learning and deep learning characterization methods in terms of accuracy, precision, recall and F1 value.

Key words: charging piles; complex fault diagnosis; bidirectional gated recurrent unit (Bi-GRU); time series representation

基金项目: 国家电网公司总部科技项目(5700-202318272A-1-1-ZN)

作者简介: 杨凤坤(1988—),女,硕士研究生,高级工程师,主要研究方向为电动汽车与电网互动技术、电能计量,

Email: fkyang20424@163.com

随着全球能源危机的不断加剧和环境问题的日益突出,电动汽车越来越受到人们的青睐,电动汽车相比传统汽车在节能减排方面有着巨大的优势^[1]。电动汽车产业的迅猛发展也带动了电动汽车充电基础设施的建设,各国政府投入大批资金用于建设电动汽车充电站与充电桩,来满足日益增长的电动汽车充电需求^[2]。随着国家电动汽车充电标准的出台,国网及能源企业纷纷投入充电设施建设,推动了基础设施的快速发展。据中国电动汽车充电基础设施促进联盟统计,截至2025年3月底,全国充电基础设施累计保有量达1 374.9万台,同比增长47.6%。

目前,针对充电桩的安全可靠问题的研究主要有两个方面的研究^[3]。一方面,研究者利用电动汽车动力电池的物理特性和工作原理^[4-5],通过电池管理系统实时监测充电过程中电池的各项数据(电压、电流、温度等),采用小波变换策略^[6-7]、马尔可夫模型^[8]与神经网络模型^[9-10]等实时判断充电过程是否安全;另一方面,一些学者通过建立物理模型分析模拟充电桩的变压器、整流柜、枪线等组件的相关概率参数,利用数学模型^[11-12]评估各充电站的可靠性,并采用基于机器学习中的自适应增强算法^[13-14]和基于深度学习的循环神经网络^[15-17]对充电桩充电模块电路中多维度故障信号进行融合诊断。

然而,上述方法在充电桩复杂故障诊断上仍存在一定的局限性:一方面,现有方法在故障诊断任务考虑的建模因素单一,特别忽略了电压、电流、充电枪温度、环境温度等数据对充电桩故障的影响;另一方面,充电桩复杂故障样本量稀缺的问题致使深度学习性能表现往往差强人意。

为了克服上述故障诊断方法所存在的局限,本文从充电桩维修工单出发,充分考虑充电桩的历史运营账单以及上送报文的数据,提出了一种融入时间序列表征的充电桩复杂故障诊断方法。首先,方法对充电桩工单、订单、报文数据进行数据补全与归一化处理。然后,采用特征工程技术与双向门控循环单元Bi-GRU来提取充电过程中多源数据的关键特征与温度、电压、电流等时序故障表征。最后,基于表征后的数据样本,采用机器学习进行学习训练,判断充电桩是否故障以及故障的类型。实验结果表明,文中所提方法较单一的机器学习与深度学习表征方法在准确率、精确率、召回率和F1值上均有较好表现。

1 相关工作

在利用电池管理系统实时监测方面,国内外学者都进行了一系列分析与研究。国外学者提出了基于小波变换的方案,来增强分布式系统的充电桩故障检测能力^[9]。Gómez P I等^[11]通过充电站模型模拟充电器功率转换器模块的热行为,创建了用于识别异常性能的数据集,为充电站内电源转换器的状态监测和维护提供信息。国内学者通过对比电池模型模拟的充电响应信息与电池的充电状态信息、充电机的充电状态信息与电池充电需求信息,提出了一种基于电池模型的充电故障监测方法^[15]。聂晓勇等^[18]人设计了一种基于外部部件互联标准总线的在线监测系统,实时收集充电桩共耦节点的电压与电流数据,分析充电桩的运行状态与特性。

在建立有效的诊断方案和预警模型方面,Grcić I等^[19]国外学者提出一种基于循环神经网络的故障检测方法。目前的相关研究主要集中在电动汽车的充电负荷预测,Amini等^[20]人基于自回归移动平均模型的解耦时间序列来预测随机电力系统运行的电动汽车充电需求。Majidpour M等^[21]人使用客户充电数据和充电站记录提出了充电负荷的预测模型。傅军等^[22]人利用冀北地区电动车充电网络运行数据,针对充电桩异常记录的特征,将广义模型和回归模型进行组合,对该地区电动汽车充电网络的异常率进行了预测。钱立军等^[7]人利用遗传小波神经网络训练原理及多尺度多分辨特点,通过划分5个安全预警等级,设计了一种电动汽车充电安全预警模型。臧斌斌等^[23]利用变分自编码器数据增强方法对故障样本数据进行扩充,利用粒子群优化算法优化门控循环单元(gate recurrent unit, GRU)网络参数,采用支持向量机模型改善网络输出的分类函数,提出了一种改进的GRU直流充电桩故障诊断模型。高德欣^[24]等人基于卷积神经网络(convolutional neural networks, CNN)和双向长短记忆网络(Bi-directional long short-term memory, Bi-LSTM),利用电动汽车的充电历史数据,构建CNN-Bi-LSTM多级安全预警模型。许笑等^[25]人采用数据挖掘处理方法,分析安全故障数据特征,建立充电桩一体化故障树,通过提取规则,分析各层故障源和具体故障类型之间的内在关系。

综上所述,国内外专家学者对充电安全问题

进行了一系列的研究,并取得了一定的成果。然而,由于历史充电数据标注不足,导致无法适配复杂故障任务等问题。此外,从电动汽车用户充电订单角度来研究充电桩故障的鲜有人触及。

2 融入时间序列表征的充电桩复杂故障诊断方法

2.1 充电桩复杂故障诊断流程

融入时间序列表征的充电桩复杂故障诊断方法主要分为三个部分:多源数据处理层、时序故障表征层以及复杂故障诊断层。多源数据处理层聚焦于对充电桩工单、订单、报文数据进行数据融合与归一化处理;故障特征表征层来提取充电过程中的关键特征,着重用双向门控循环单元 Bi-GRU 对时序数据进行建模表征;复杂故障诊断层基于表征后的数据样本,采用机器学习进行学习训练,输出充电桩是否故障以及故障的类型,具体流程图如图 1 所示。




图1 充电桩复杂故障诊断流程图

Fig.1 Flow chart of complex fault diagnosis of charging piles

首先,本文将采集到的充电桩维修工单数据与对应的充电历史报文和订单数据输入到多源数据处理层,多源数据处理层对充电桩工单、订单、报文数据进行数据融合与归一化处理;然后,多源故障特征表征层来提取充电过程中报文数据与充电订单中的关键特征,重点采用 Bi-GRU 对时序数据进行有效表征;复杂故障诊断层基于表征后的数据样本,采用机器学习进行学习训练,输出充电桩是否故障以及故障的类型,并基于评价指标对诊断结果进行评估。

2.2 多源数据处理层

2.2.1 故障特征选取

为了提高充电桩故障诊断模型的表现,本文选取了故障类型差异性较大的故障充电桩和无明显故障充电桩进行对比分析。根据充电桩的维修工单中记录的报修和修复时间点进行定位,分析表明,报修时间前的充电订单可能隐含着充电桩充电异常的信息,因此选取报修时间点的前 7 d 充电订单数据作为故障案例(负样本)。同

时,考虑到修复后充电桩的运行恢复正常,选取修复后 7 d 内的充电订单数据,将其作为非故障案例(正样本),这样可以增强模型对故障和非故障状态的区分能力。通过以上考虑,本文采用特征工程技术构建的数据集采用了以下主要特征:

1)故障订单结束原因:考虑充电订单的异常结束原因可作为预测充电桩故障的特征指标。本文使用独热(One-Hot)编码^[26]将订单结束原因转换成向量进行编码,步骤如下:首先定义 44 种不同的故障订单结束原因;其次为每种结束原因分配一个唯一的索引,范围从 0 到 43;再次为每种故障订单结束原因创建一个 97 维的向量,并初始化为 0;接着对于每种故障原因,在其对应的索引位置的向量中的元素设为 1,表示该向量代表的故障原因。这样,每个向量都将有一个元素为 1,其余为 0,最终形成一个 One-Hot 编码表示。

2)总订单数:考虑到订单量变化可反映充电桩状态,故障时订单常减少。据此,选取总订单量作为特征。

3)故障订单数:考虑到故障桩通常表现出更高的故障订单比例。据此,选取故障订单占总订单数的比例作为特征。

4)无效订单数:考虑到充电时长过短表示充电桩可能出现故障,因此,将充电时间间隔小于 1 min 的充电订单视为无效订单,选取无效订单在总订单数的占比作为特征。

5)7 d 中每一天的订单占比:考虑每天充电订单比例的变化趋势隐含相关故障的信息,因此,选取 7 d 内每天的充电订单比例作为特征。

6)7 d 中每一天的故障订单占比:考虑每天故障订单比例的变化趋势隐含相关故障的信息,因此,计算 7 d 内每天的故障订单比例,并将每一天的订单占比选取为特征向量。

7)7 d 中每一天的无效订单占比:考虑到每天无效订单比例的变化趋势隐含相关故障的信息,因此,计算 7 d 内每天的无效订单比例,并将每一天的订单占比选取为特征向量。

8)最后一天订单占比:考虑充电桩出现不同故障时,对应最后一天订单数占比不同。因此,本文将正样本 7 d 中第一天订单数占比和负样本 7 d 中最后一天订单数占比作为特征向量。

9)需求电流与当前电流之差的相对值:根据运维经验,考虑到当需求电流与当前电流之差的相对值小于 20% 时,系统可能出现故障。因此,

本文将该相对值作为特征向量。

10)连续两笔订单的平均电流:根据运维经验,考虑到当直流充电桩连续两笔订单的平均电流低于20 A时,可能预示着系统存在故障。因此,本文将两笔订单的平均电流作为特征向量。

11)充电枪温度:考虑到充电枪温度异常表征着设备电流过大或散热不足,可能发生过温故障,据此,本文选取了充电枪温度作为特征。

12)天气温度:气温的变化可能对充电桩的性能和稳定性产生影响,尤其在极端气候条件下可能导致充电桩设备故障。因此,本文选取了历史天气温度数据作为充电特征进行分析。

2.2.2 特征数据归一化

由于不同特征向量因素之间量纲不同,不利于特征向量之间的对比和计算,因此需要将数据进行归一化处理。首先,对“总订单数量”特征因素进行归一化,公式如下:

$$M'_{tj} = M_{tj} / (M_{t,\max} - M_{tj}) \quad (1)$$

式中: M_{tj} 为第*j*条样本的“总订单数量”特征因素的取值; M'_{tj} 为第*j*条样本的“总订单数量”归一化结果; $M_{t,\max}$ 为所有样本数据中“总订单数量”特征因素的最大值。

其次,对“每日订单数”特征因素进行归一化,公式如下:

$$M'_{ij} = M_{ij} / \sum_{i=1}^7 M_{ij} \quad (2)$$

式中: M_{ij} 为第*j*条样本的“第*i*天订单数量”特征因素; M'_{ij} 为第*j*条样本的“第*i*天订单数量”归一化结果。

2.3 时序故障表征层

2.3.1 时序数据处理

为了有效对充电订单与报文数据中时序数据进行表征,需要对提取的特征样本数据做进一步的处理,具体步骤如下:基于充电桩维修工单的报修时间,首先按充电桩ID对其历史充电订单进行时序排序;随后通过交易流水号关联报文数据,同步对齐电流、电压、充电枪温度及环境温度等参数;最后提取各充电订单的时间步骤特征,构建成完整的时序特征数据集。

根据与运维业务人员的沟通发现,由于充电桩复杂故障通常跟上述时序数据有较强的关联,本文进一步将上述时序数据进行表征,从而较好地解决现有方法在故障诊断任务考虑的建模因素单一的局限性。

2.3.2 时序数据表征

由于循环神经网络适用于处理长序列并捕捉序列中的长期依赖关系^[26]。因此,重点采用循环神经网络来表征复杂的时间序列数据。

需要注意的是,尽管每年上报至车联网以及省部级平台的充电桩故障工单数据较多,但大多数工单都是可以通过充电桩自恢复技术(如定时重启)进行修复,因此,最终能够训练模型有效的复杂故障工单相对稀缺。考虑到传统的循环神经网络如循环神经网络RNN、长短期记忆网络LSTM需要在样本数据充足的情况下才能表现出较好的性能,为此本文根据实际数据规模与参数规模进行了权衡,选择了双向门控循环单元Bi-GRU来对时序数据进行表征。

门控循环单元GRU网络在RNN的基础上引入了门控机制,通过记忆单元来有效地控制信息的流动,较好地缓解了传统RNN在处理长序列时容易出现的梯度消失和梯度爆炸问题。双向门控循环单元则是结合了循环网络双向结构的优点,可以同时捕捉输入序列的正向和反向信息^[27],同时具有比LSTM更少的学习参数,Bi-GRU的网络建模框架如图2所示。




图2 Bi-GRU的网络建模框架

Fig.2 Network modeling framework of Bi-GRU

为此,本文方法需要通过Bi-GRU网络先对原始的时序特征数据进行训练,以捕捉数据中的时序信息特征。前向GRU单元隐藏状态更新公式如下式所示:

$$z_t^{(f)} = \sigma(W_z x_t + U_z h_{t-1}^{(f)} + b_z) \quad (3)$$

$$r_t^{(f)} = \sigma(W_r x_t + U_r h_{t-1}^{(f)} + b_r) \quad (4)$$

$$\tilde{h}_t^{(f)} = \tanh[W_h x_t + U_h(r_t^{(f)} \odot h_{t-1}^{(f)}) + b_h] \quad (5)$$

$$h_t^{(f)} = (1 - z_t^{(f)}) \odot h_{t-1}^{(f)} + z_t^{(f)} \odot \tilde{h}_t^{(f)} \quad (6)$$

后向 GRU 单元隐藏状态更新公式如下式所示:

$$z_t^{(b)} = \sigma(W_z x_t + U_z h_{t+1}^{(b)} + b_z) \quad (7)$$

$$r_t^{(b)} = \sigma(W_r x_t + U_r h_{t+1}^{(b)} + b_r) \quad (8)$$

$$\tilde{h}_t^{(b)} = \tanh[W_h x_t + U_h(r_t^{(b)} \odot h_{t+1}^{(b)}) + b_h] \quad (9)$$

$$h_t^{(b)} = (1 - z_t^{(b)}) \odot h_{t+1}^{(b)} + z_t^{(b)} \odot \tilde{h}_t^{(b)} \quad (10)$$

双向整合与输出层用于将前向和后向隐藏状态进行拼接,具体公式如下式所示:

$$h_t = [h_t^{(f)}; h_t^{(b)}] \quad (11)$$

式中: x_t 为时刻 t 的输入向量; $h_t^{(f)}$, $h_t^{(b)}$ 分别为前向和后向 GRU 在时刻 t 的隐藏状态; z_t 为更新门,用于控制保留多少历史信息; r_t 为重置门,可决定忽略多少历史信息; $\tilde{h}_t$ 为候选隐藏状态; W , U 分别为输入和隐藏状态的权重矩阵; b 为偏置向量; σ 为 Sigmoid 激活函数,能将值映射到 $(0, 1)$ 区间; $\tanh$ 为双曲正切激活函数,可将值映射到 $(-1, 1)$ 范围; $\odot$ 为元素级别的乘法运算; $[\cdot; \cdot]$ 为向量的拼接操作。

2.4 复杂故障诊断层

2.4.1 故障特征融合

在特征工程技术人工提出特征的基础上,方法进一步将基于 Bi-GRU 时序数据的表征进行拼接融合,以提供机器学习模型作为数据输入使用,具体公式如下:

$$V_{\text{merge}} = [V_{\text{manual}}; V_{\text{time}}] \quad (12)$$

式中: $V_{\text{manual}} \in R^m$ 与 $V_{\text{time}} \in R^n$ 分别为人工提取的特征向量以及通过 Bi-GRU 的时序数据学习得到的表征向量; m 为特征向量的维度; n 为时序特征向量的维度。

2.4.2 复杂故障诊断

在获得融合表征后的数据样本后,采用常规的机器学习进行学习训练与评估。训练的损失函数如下:

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \frac{1}{n} \sum_{i=1}^n L[f_{\theta}(V_{\text{merge}}^i) - y_i] + \lambda \Omega(\theta) \quad (13)$$

式中: V_{merge}^i 为第 i 个数据样本的表征输入; $f_{\theta}(\cdot)$ 为机器学习模型的预测标签输出; y_i 为第 i 个数据样本复杂故障的真实标签; $\Omega(\theta)$ 为正则化项惩罚; λ 为平衡超参数; θ 为待学习优化的机器学习模型参数。

最终,方法根据训练优化后的模型参数,判

断出充电桩是否故障以及复杂故障的类型。

3 实验分析

3.1 数据集准备

本文的实验所采用的编程语言为 Python,采用的数据来源为某市 2024 年 7 月 1 日至 2024 年 7 月 31 日公路、高速以及城市公共的直流快充桩数据,包括维修工单数据、多种型号的电动汽车充电历史订单与报文数据。经过数据清洗、充电桩编号对齐、充电流水订单对齐、“自恢复”等无效工单过滤等方式,最终构建的时序数据集的样本数量仅为 138 条,其中故障样本 70 例,非故障样本 68 例,结合故障特征选取以及时序特征提取的条件限制,共选取了 119 种特征作为基础特征以及 32 维基于 Bi-GRU 对时序数据编码的故障特征。

为缓解少数故障类型样本规模过少的问题,本文采用合成少数类过采样技术(synthetic minority oversampling technique, SMOTE)对小样本故障进行扩充。该技术通过线性插值在少数类样本与其近邻样本之间生成合成样本来改善数据分布的平衡性^[28]。这种同类线性插值生成扩充样本的方式,可以有效避免模型训练出现的过拟合情况,相较于简单复制样本,插值生成的新样本增强了特征空间多样性^[29]。由此,本文针对故障样本量较小的故障类型(如交直流充电故障、数据校验异常故障、BMS 通信故障、充电枪过温故障等)按原始样本约 3 倍的比例进行扩充,采用的核心公式为

$$X_{\text{new}} = x_i + \gamma(x_{ij} - x_i) \quad (14)$$

式中: x_i 为少数类中的原始样本; x_{ij} 为 x_i 的随机选择的 k 近邻样本。

考虑到少数样本类的规模,本文选取同类 2 个最近邻, γ 为 $[0, 1]$ 区间内的随机数,用于控制插值的位置数据平衡。同时,考虑到输入数据集的时序性以及有效的样本规模较小,在实验中仅对训练集与测试集进行手动划分,不再考虑验证集进行参数的交叉验证,其中,训练集与测试集的划分比例约为 8:2,即训练集 165 条,测试集 51 条。

3.2 两类故障诊断任务

建立模型的目的是通过输入的特征数据来判断某个特征向量对应的目标,故障诊断模型的输出两个目标分别对应两类故障诊断任务,具体

的故障诊断任务和相应类型的训练集和扩充后的数据集的条数如表1所示。

其中,第一类故障诊断任务为充电桩是否故障分类,即是否二分类;第二类故障诊断任务为故障类型分类,故障类型共计7种。

设定判断阈值为0.5,应用阈值进行预测。当模型输出故障概率值大于阈值时,判定预测为故障,当模型输出故障概率值小于阈值时,判定预测为正常。

表1 两类故障诊断任务与扩充后相应类型的数据条数
Tab.1 Table of two types of fault diagnosis tasks and the number of corresponding types of data after expansion

故障诊断任务	训练集(165条)		测试集(51条)	
	故障(108条)	非故障(57条)	故障(40条)	非故障(11条)
故障类型	通信类故障(14条)		通信类故障(5条)	
	绝缘监测告警故障(10条)		绝缘监测告警故障(6条)	
	模块通信类故障(10条)		模块通信类故障(5条)	
	充电枪过温故障(19条)	无故障(57条)	充电枪过温故障(6条)	无故障(11条)
	BMS通信故障(20条)		BMS通信故障(6条)	
	交直流充电故障(16条)		交直流充电故障(6条)	
	数据校验异常故障(19条)		数据校验异常故障(6条)	

3.3 评估方法

对于每个测试样本,记录模型输出的计算准确率(Accuracy)、精确率(Precision)、召回率(Recall)和F1值(F1)四个分类评估指标,公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (15)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (16)$$

表2 任务1评估结果

Tab.2 Assessment results of task 1

故障诊断任务	对比模型	Accuracy/%	Precision/%	Recall/%	F1/%
任务1:是否故障	Decision Tree	84.32	87.87	84.32	86.04
	Random Forest	84.32	85.56	84.32	84.94
	Neural Net	96.09	96.27	96.09	96.18
	AdaBoost	86.27	87.42	86.27	86.86
	Naive Bayes	92.16	92.46	92.16	92.32
	Bi-GRU merge+Decision Tree	96.09 ↑	95.63 ↑	96.09 ↑	95.76 ↑
	Bi-GRU merge+Random Fores	92.16 ↑	92.55 ↑	92.16 ↑	92.44 ↑
	Bi-GRU merge+Neural Net	96.09	96.27	96.09	96.18
	Bi-GRU merge+AdaBoost	94.12 ↑	95.23 ↑	94.12 ↑	94.68 ↑
	Bi-GRU merge+Naive Bayes	92.16	92.46	92.16	92.32

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (17)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \quad (18)$$

式中:TP为故障样本被模型识别为正确的数量;TN为非故障样本被模型识别为正确的数量;FP为故障样本被模型错误识别的数量;FN为被非故障样本被模型错误识别的数量。

3.4 对比分析实验结果

为了对本文提出方法的有效性进行检验,将本文提出的方法输入5种传统机器学习算法,分别为决策树算法(Decision Tree)、随机森林算法(Random Forest)、AdaBoost算法、神经网络算法(Neural Network)和朴素贝叶斯算法(Naive Bayes)。对不同的算法采取相同的训练方式,输出得到两类故障识别任务的评估结果。

为验证本文提出的融入时间序列表征的充电桩复杂故障诊断方法,采用Bi-GRU故障特征融合预训练后再输入机器学习模型得到评估结果。经实验调优选取模型参数为:Bi-GRU隐藏层维度为32、层数为6、Dropout率为0.3,并采用自适应矩阵优化器(adaptive moment estimation, Adam)进行模型训练,学习率设置为0.001。对于式(13)融合时间序列表征的训练损失函数,其中的平衡超参数λ采用网格搜索的方式从集合{0.001,0.01,0.1}来进行确定,最终λ设置为0.01。

本文方法与传统方法在两类故障诊断目标下的具体评估效果分别如表2和表3所示。根据实验结果,整体来说,融入Bi-GRU的编码时序数据特征后对Decision Tree, Random Forest, AdaBoost以及Naive Bayes的分类任务效果是有提升的,并且对于二分类任务,整体的提升效果更加明显。其中Decision Tree表现最为稳定,在任务1

表 3 任务2评估结果

Tab.3 Assessment results of task 2

故障诊断任务	对比模型	Accuracy/%	Precision/%	Recall/%	F1/%
任务 2:故障类型	Decision Tree	49.02	62.42	49.02	54.92
	Random Forest	50.10	29.13	50.10	36.86
	Neural Net	54.90	56.32	54.90	55.60
	AdaBoost	52.94	55.12	52.94	53.92
	Naive Bayes	56.86	43.12	56.86	49.12
	Bi-GRU merge+Decision Tree	60.78 ↑	67.56 ↑	60.78 ↑	63.98 ↑
	Bi-GRU merge+Random Fores	52.94 ↑	29.79 ↑	52.94 ↑	38.14 ↑
	Bi-GRU merge+Neural Net	54.90	56.32	54.90	55.60
	Bi-GRU merge+AdaBoost	58.82 ↑	62.14 ↑	58.82 ↑	60.54 ↑
	Bi-GRU merge+Naive Bayes	56.86	43.12	56.86	49.12

中,其准确率与F1值分别达到96.09%和95.76%;在任务2中,准确率与F1值分别提升至60.78%和63.98%。

此外,在选定 Decision Tree 算法的基础上,进一步对比分析了在不同 Bi-GRU 隐藏层维度设置下(16 维、32 维、64 维)对两类故障诊断任务的效果,如图 3 所示。由对比结果可以看出,融入 Bi-

GRU 编码时序数据特征的 Decision Tree 方法,其准确性在隐藏层维度设置为 32 维时比 16 维与 64 维的表现更好。

为评估不同时间序列模型在故障诊断任务中的性能,本文选取了不同时间序列模型 RNN, LSTM, GRU 及其双向变种模型 (Bi-LSTM, Bi-GRU) 在相同的隐藏层维度、层数和 Dropout 率设置下 (32 维、6 层、0.3) 对故障特征进行预训练融合,结合 Decision Tree 模型分别对两类故障诊断目标进行评估,实验结果如表 4 所示。

综合任务 1 与任务 2 的实验结果表明,所有时间序列模型与 Decision Tree 的融合结果均显著优于单独使用 Decision Tree 模型。其中,Bi-GRU 与 Decision Tree 结合的模型在两个任务中的效果最优:在任务 1 中,其准确率与 F1 值分别高出其他融合模型 1.80%~7.85% 与 1.20%~6.40%;在任务 2 中,其准确率与 F1 值分别高出其他融合模型 3.64%~7.21% 与 3.90%~4.84%。上述结果表明,在小样本学习场景下,Bi-GRU 模型在捕获时序特




图 3 融入不同维度 Bi-GRU 编码时序数据特征的 Decision Tree 的故障诊断结果

Fig.3 Fault diagnosis results of Decision Tree with different dimensions of Bi-GRU coded time series data characteristics

表 4 不同时间序列模型故障特征融合预训练结合 Decision Tree 的评估结果对比

Tab.4 Comparison of evaluation results of fault feature fusion pre-training combined with Decision Tree in different time series models

故障诊断任务	对比模型	Accuracy/%	Precision/%	Recall/%	F1
任务 1:是否故障	Decision Tree	84.32	87.87	84.32	86.04
	RNN merge+Decision Tree	88.24 ↑	90.48 ↑	88.24 ↑	89.36 ↑
	LSTM merge+Decision Tree	88.57 ↑	90.75 ↑	88.57 ↑	89.64 ↑
	GRU merge+Decision Tree	92.86 ↑	93.75 ↑	92.86 ↑	93.30 ↑
	Bi-LSTM merge+Decision Tree	94.29 ↑	94.89 ↑	94.29 ↑	94.56 ↑
	Bi-GRU merge+Decision Tree	96.09 ↑	95.63 ↑	96.09 ↑	95.76 ↑
任务 2:故障类型	Decision Tree	49.02	62.42	49.02	54.92
	RNN merge+Decision Tree	53.57 ↑	66.07 ↑	53.57 ↑	59.14 ↑
	LSTM merge+Decision Tree	53.57 ↑	66.96 ↑	53.57 ↑	59.48 ↑
	GRU merge+Decision Tree	53.57 ↑	68.45 ↑	53.57 ↑	60.08 ↑
	Bi-LSTM merge+Decision Tree	57.14 ↑	62.76 ↑	57.14 ↑	59.82 ↑
	Bi-GRU merge+Decision Tree	60.78 ↑	67.56 ↑	60.78 ↑	63.98 ↑

征方面展现出更强的能力。相较于其他对比的时间序列模型,Bi-GRU的双向门控机制结构参数量更少,这一特性有效降低了模型在小样本数据上过拟合的风险,同时加速了模型学习的收敛过程,提升了模型的预测准确率与泛化能力。

4 结论

本文提出了一种融入时间序列表征的充电桩复杂故障诊断方法。首先,对充电桩工单、订单、报文数据进行数据补全与归一化处理。然后,采用特征工程技术与双向门控循环单元 Bi-GRU 来提取充电过程中故障特征与时序故障表征。最后,采用机器学习方法对表征后的数据样本进行学习训练,判断充电桩是否存在故障以及故障的类型。实验结果表明,融入时间序列表征后的机器学习方法较单一的机器学习在准确率、精确率、召回率和 F1 值上均有较好的表现。相较于其他深度学习表征模型,Bi-GRU 学习后的时间序列表征融入决策树之后,在是否故障以及复杂故障诊断这两项任务上具有更好的效果。

在未来的研究中,模型将尝试引入预训练模型提高模型性能,同时聚焦小样本学习框架来进一步提升充电设施复杂故障诊断的效果。

参考文献

- [1] 李伟,李颖奇,候雷浩,等.单相四象限整流器故障诊断方法研究[J].电气传动,2024,54(10):90-96.
LI Wei, LI Yingqi, HOU Leihao, et al. Fault detection method research of single-phase four-quadrant rectifier[J]. Electric Drive, 2024, 54(10): 90-96.
- [2] 徐昌宝,丁健,宋宏剑,等.计及电能质量约束的充电设施布局优化方法[J].电气传动,2022,52(22):51-59.
XU Changbao, DING Jian, SONG Hongjian, et al. Charging facility distribution optimization method considering power quality constraints[J]. Electric Drive, 2022, 52(22): 51-59.
- [3] 高辉,彭成薇,李炜卓,等.电动汽车与充电设备充电安全预警研究综述[J].电力系统自动化,2024,48(7):47-61.
GAO Hui, PENG Chengwei, LI Weizhuo, et al. Review on early warning of charging safety for electric vehicles and charging equipment[J]. Automation of Electric Power Systems, 2024, 48(7): 47-61.
- [4] 赵树恩,屈贤.基于LabVIEW的电动汽车氢浓度实时检测系统设计[J].科技通报,2015,31(3):149-152.
ZHAO Shuen, QU Xian. Design of electric vehicles hydrogen concentration real-time detection system based on LabVIEW[J]. Bulletin of Science and Technology, 2015, 31(3): 149-152.
- [5] XIONG R, YU Q, SHEN W, et al. A sensor fault diagnosis method for a lithium-ion battery pack in electric vehicles[J]. IEEE Transactions on Power Electronics, 2019, 34(10): 9709-9718.
- [6] JIANG L, DIAO X, ZHANG Y, et al. Review of the charging safety and charging safety protection of electric vehicles[J]. World Electric Vehicle Journal, 2021, 12(4): 184.
- [7] 钱立军,赵明宇,张卫国.一种电动汽车充电安全预警模型设计方法[J].电网与清洁能源,2016,32(12):114-119.
QIAN Lijun, ZHAO Mingyu, ZHANG Weiguo. A method to design the security early warning model of EV charging[J]. Power System and Clean Energy, 2016, 32(12): 114-119.
- [8] 黄焘,彭科,程旭,等.车联网环境下充电桩健康状态综合评估与短期预测方法研究[J].电力信息与通信技术,2022,20(7):109-116.
HUANG Tao, PENG Ke, CHENG Xu, et al. Research on comprehensive evaluation and prediction method of health status of charging pile in internet of vehicles environment[J]. Electric Power Information and Communication Technology, 2022, 20(7): 109-116.
- [9] GUPTA A, SARANGI S, SINGH A K. Wavelet based enhanced fault detection scheme for a distribution system embedded with electric vehicle charging station[C]//2023 5th International Conference on Power, Control & Embedded Systems (ICP-CES), Allahabad, India, 2023: 1-6.
- [10] GE Q, QIAO H, LI C, et al. Real-time charging risk assessment for electric vehicles based on improved broad BP-AHP[J]. IEEE Transactions on Industrial Electronics, 2021, 69(9): 9472-9482.
- [11] GÓMEZ P I, MORENO A B, LIN J. Data-driven thermal modelling for anomaly detection in electric vehicle charging stations [C]//2022 IEEE Transportation Electrification Conference & Expo (ITEC), Anaheim, CA, USA, 2022: 1005-1010.
- [12] 郭葳,尹新涛,王俊霞,等.基于曼哈顿距离法的充电桩远程运维系统设计[J].电力系统保护与控制,2018,46(13):134-140.
GUO Wei, YIN Xintao, WANG Junxia, et al. Design of long-distance operation and maintenance system of charging pile based on Manhattan distance method[J]. Power System Protection and Control, 2018, 46(13): 134-140.
- [13] GAO D, WANG Y, ZHENG X, et al. A fault warning method for electric vehicle charging process based on adaptive deep belief network[J]. World Electric Vehicle Journal, 2021, 12(4): 265.
- [14] WANG W, PENG X, YANG Y, et al. Self-training enabled efficient classification algorithm: an application to charging pile risk assessment[J]. IEEE Access, 2022, 10: 86953-86961.
- [15] 张元星,李斌,颜湘武,等.基于电池模型的电动汽车充电故障监测与预警方法[J].电力系统保护与控制,2021,49(10):143-154.
ZHANG Yuanxing, LI Bin, YAN Xiangwu, et al. Monitoring and early warning method of EV charging failure based on a battery model[J]. Power System Protection and Control, 2021,

- 49(10):143-154.
- [16] 刘梓强,金涛,刘宇龙,等.基于张量重构融合诊断的电动汽车直流充电桩开路故障诊断方法[J].中国电机工程学报,2023,43(5):1831-1843.
- LIU Ziqiang, JIN Tao, LIU Yulong, et al. Open circuit fault diagnosis method of electric vehicle DC charging pile based on tensor reshape fusion diagnostic model[J]. Proceedings of the CSEE, 2023, 43(5):1831-1843.
- [17] 李芝娟,吴丹,雷珽,等.基于软分类的直流充电桩故障预警方法[J].电气传动,2023,53(7):78-84.
- LI Zhijuan, WU Dan, LEI Ting, et al. Fault early warning method of DC charging pile based on soft classification[J]. Electric Drive, 2023, 53(7):78-84.
- [18] NIE Xiaoyong, LIU Jieyi, XUAN Liang, et al. Online monitoring and integrated analysis system for EV charging station[C]//2013 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), Hong Kong, China, IEEE, 2013.
- [19] GRČIĆ I, PANDŽIĆ H, ŠUNDE V. Electric vehicle charging station fault detection: a machine learning approach[C]//CIRED Porto Workshop 2022: E-mobility and power distribution systems, Hybrid Conference, Porto, Portugal, 2022:745-749.
- [20] AMINI M H, KARGARIAN A, KARABASOGLU O. ARIMA-based decoupled time series forecasting of electric vehicle charging demand for stochastic power system operation[J]. Electric Power Systems Research, 2016, 140(11):378-390.
- [21] MAJIDPOUR M, QIU C, CHU P, et al. Forecasting the EV charging load based on customer profile or station measurement[J]. Applied Energy, 2016, 163(2):134-141.
- [22] 傅军,孙志杰,孟尚雄,等.充电桩运行异常率预测[J].数理统计与管理,2019,38(1):87-93.
- FU Jun, SUN Zhijie, MENG Shangxiong, et al. Forecasting of the abnormal rate of EV charging infrastructure[J]. Journal of Applied Statistics and Management, 2019, 38(1):87-93.
- [23] 臧斌斌,高辉,刘建,等.基于改进GRU模型的直流充电桩故障预测[J].计算机系统应用,2023,32(2):356-363.
- ZANG Binbin, GAO Hui, LIU Jian, et al. Fault prediction of DC charging pile based on improved GRU model[J]. Computer Systems & Applications, 2023, 32(2):356-363.
- [24] 高德欣,郑晓雨,王义,等.电动汽车充电状态监测与多级安全预报警方法[J].电工技术学报,2022,37(9):2252-2262.
- GAO Dexin, ZHENG Xiaoyu, WANG Yi, et al. A State monitoring and multi-level safety pre-warning method for electric vehicle charging process[J]. Transactions of China Electrotechnical Society, 2022, 37(9):2252-2262.
- [25] 许笑,高翔,李光熹,等.基于数据挖掘的电动汽车充电设施充电安全故障特性分析[J].电器与能效管理技术,2022(3):15-22.
- XU Xiao, GAO Xiang, LI Guangxi, et al. Analysis on charging safety fault characteristics of electric vehicle charging facilities based on data mining[J]. Electrical & Energy Management Technology, 2022(3):15-22.
- [26] 吕飞亚,张英俊,潘理虎.注意力机制的Bi-LSTM模型在招聘信息分类中的应用[J].计算机系统应用,2020,29(4):242-247.
- LÜ Feiya, ZHANG Yingjun, PAN Lihu. Bi-LSTM model of attention mechanism application in recruitment information classification[J]. Computer Systems & Applications, 2020, 29(4):242-247.
- [27] 徐铭,徐航,陈洋,等.基于卷积残差编码网络的水泥辊压机故障诊断[J].重庆工商大学学报(自然科学版),2026,43(2):133-138.
- XU Ming, XU Hang, CHEN Yang, et al. Fault diagnosis of cement roller press based on convolution residual coding network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(2):133-138.
- [28] 王忠震,黄勃,方志军,等.改进SMOTE的不平衡数据集分类算法[J].计算机应用,2019,39(9):2591-2596.
- WANG Zhongzhen, HUANG Bo, FANG Zhijun, et al. Improved SMOTE unbalanced data integration classification algorithm[J]. Journal of Computer Applications, 2019, 39(9):2591-2596.
- [29] 张玮.基于SMOTE-SSA-CNN的开关柜故障诊断方法[J].电气传动,2024,54(10):83-89.
- ZHANG Wei. Fault diagnosis method for switchgear based on SMOTE-SSA-CNN[J]. Electric Drive, 2024, 54(10):83-89.

收稿日期:2025-05-07

修改稿日期:2025-07-18