

DOI: 10.13382/j.jemi.B2407862

# 基于合作博弈策略和 DBO-BiLSTM-Attention 的 电动汽车充电桩故障预测\*

陈庆斌<sup>1</sup> 杨耿煌<sup>1,2</sup> 耿丽清<sup>1,2</sup> 苏娟<sup>3</sup> 尚春虎<sup>1</sup>

(1. 天津职业技术师范大学自动化与电气工程学院 天津 300222; 2. 天津市信息传感与智能控制重点实验室 天津 300222; 3. 中国农业大学信息与电气工程学院 北京 100083)

**摘要:** 针对电动汽车充电桩故障率较高的问题,提出一种基于合作博弈策略和蛭螂优化算法-双向长短期记忆网络-注意力机制(DBO-BiLSTM-Attention)的电动汽车充电桩故障预测方法。首先,通过参数统计分布处理异常值,通过均值填充处理缺失值,对处理后的数据归一化操作;其次,从不同角度出发,选取主观评价方法层次分析法、客观评价方法 CRITIC 权重法和机器学习算法中的随机森林依次计算特征权重,采用合作博弈策略对上述特征权重进行组合,得到新特征权重,并对参数特征矩阵进行放大;然后,分别引入蛭螂优化算法和注意力机制,搭建 DBO-BiLSTM-Attention 模型,在仿真实验下,所提模型训练集和测试集的准确率、 $F1$  系数分别为 0.89、0.89、0.90 和 0.90;最后,构建相关对比实验。结果表明,相比于不进行特征放大的模型,测试集准确率和  $F1$  系数分别提高了 5% 和 6%;相比于不采用合作博弈策略的模型,测试集准确率和  $F1$  系数分别提高了 2% 和 3%,验证所提模型的有效性和合理性。

**关键词:** 充电桩;合作博弈;蛭螂优化算法;双向长短期记忆网络;注意力机制

**中图分类号:** TP391.5;TN06 **文献标识码:** A **国家标准学科分类代码:** 520.2060

## Fault prediction of electric vehicle charging stations based on cooperative game strategy and DBO-BiLSTM-Attention

Chen Qingbin<sup>1</sup> Yang Genghuang<sup>1,2</sup> Geng Liqing<sup>1,2</sup> Su Juan<sup>3</sup> Shang Chunhu<sup>1</sup>

(1. School of Automation and Electrical Engineering, Tianjin University of Technology and Education, Tianjin 300222, China;

2. Tianjin Key Laboratory of Information Sensing and Intelligent Control, Tianjin 300222, China;

3. School of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

**Abstract:** Aiming at the problem of the high failure rate of electric vehicle charging piles, a fault prediction method of electric vehicle charging piles based on cooperative game strategy and dung beetle optimization algorithm-bidirectional long-term and short-term memory network-attention mechanism (DBO-BiLSTM-Attention) is proposed. Firstly, abnormal values are processed through parameter statistical distribution, missing values are processed through mean imputation, and the processed data is normalized. Secondly, from different perspectives, subjective evaluation methods such as analytic hierarchy process, objective evaluation method CRITIC weighting method, and machine learning algorithm random forest are selected to calculate feature weights in sequence. Cooperative game strategy is used to combine the above feature weights to obtain new feature weights, and the parameter feature matrix is enlarged. Then, the beetle optimization algorithm and attention mechanism were introduced separately to build the DBO BiLSTM Attention model. Under simulation experiments, the accuracy and  $F1$  coefficient of the training and testing sets of this model were 0.89, 0.89, 0.90, and 0.90, respectively. Finally, relevant comparative experiments were conducted, and the results showed that compared to the model without feature amplification, the accuracy and  $F1$  coefficient of the test set were improved by 5% and 6%, respectively; Compared with the model that does not adopt cooperative game strategy, the accuracy and  $F1$  coefficient of the test set have been improved by 2% and 3% respectively, verifying the effectiveness and rationality of the proposed model.

**Keywords:** charging pile; cooperative game; dung beetle optimization algorithm; bidirectional long short-term memory network; attention mechanism

收稿日期: 2024-09-29 Received Date: 2024-09-29

\* 基金项目: 国家重点研发计划(2022YFB2403002)、天津市科技计划项目(23YDTPJC00320, 24YDTPJC00740)资助

## 0 引言

随着电动汽车的发展和广泛应用,充电桩作为基础设施,其安全程度受到监管部门等相关单位的高度重视,但电动汽车充电桩运维水平相对落后,故障率较高,如何及时预警避免事故发生具有重要的现实意义<sup>[1-3]</sup>。

目前,对于充电桩研究热点主要是充电策略、控制系统和负荷预测等,关于故障诊断和预测研究相对较少。传统充电桩故障检测方法是通过人工检测和建立分析模型进行故障预测,这些方法判断准确率较低,且随着充电桩结构日益复杂,也难以实现批量化故障检测。随着人工智能技术的不断发展,文献[4]对能量谱和功率谱通过小波包分析得到故障特征,但该方法需多次验证,计算效率较低;文献[5]结合主成分分析法和随机森林算法进行故障预测,但设备要求较多、复杂性更明显;文献[6]提出了一种结合奇异谱分析、双向长短期记忆神经网络(bidirectional long short term memory, BiLSTM)和注意力机制的故障预测方法,可明显提高预测精度,但数据质量要求较高;文献[7]在 BiLSTM 和注意力机制中加入迁移学习,解决了泛化能力较差的问题,但未考虑 BiLSTM 中超参数对预测模型的影响。以上方法在一定程度上均可实现故障预测,但未考虑原始数据中特征大小对模型的影响。同时,传统的合作博弈策略单纯考虑了主观评价方法和客观评价方法,具有一定局限性。

鉴于此,本文提出一种基于合作博弈策略和蜣螂优化算法-双向长短期记忆网络-注意力机制(dung beetle optimizer-bidirectional long short term memory-attention, DBO-BiLSTM-Attention)的电动汽车充电桩故障预测方法。首先,通过参数统计分布处理异常数据,通过均值填充处理缺失数据,并对处理后的数据进行归一化操作;其次,从不同角度出发,选取多个单一赋权法计算特征权重,利用合作博弈策略<sup>[8-10]</sup>计算组合权重,并对归一化后参数特征矩阵进行放大;最后,引入注意力机制<sup>[11]</sup>解决 BiLSTM<sup>[12]</sup>在长序列样本中可能丢失部分重要信息的问题,并采用蜣螂优化算法(dung beetle optimizer, DBO)<sup>[13-14]</sup>对其中超参数进行寻优,构建 DBO-BiLSTM-Attention 预测模型。以充电桩故障数据为例进行实验,结果表明,所提预测模型可有效提高预测的精确性。

## 1 基于合作博弈策略的特征权重设置

充电桩参数特征权重的确定对充电桩故障预测起确定性作用,恰当的权重设置在突出主要特征的同时,有效避免其他特征的影响。目前,特征权重设置方法包括单一赋权法和组合赋权法,通过多个不同类型的单一赋权

法对充电桩参数特征进行赋权,并利用合作博弈确定组合权重。

### 1.1 特征权重计算方法

在单一赋权法中,为充分结合主观赋权法、客观赋权法和机器学习方法各自的优点,分别选取层次分析法<sup>[15]</sup>、CRITIC 权重法<sup>[16]</sup>和随机森林<sup>[17]</sup>进行特征权重计算。

1) 层次分析法是一种主观赋权方法,通过将复杂的决策问题分解为更小的组成部分,在这些部分之间进行比较和评价。其主要考虑数字大小信息,根据数字大小,越大权重越大。

2) CRITIC 权重法是一种客观赋权方法,利用各特征数据的信息量确定特征权重,完全依靠数据自身的客观属性进行赋权。其主要考虑数据波动项和数据间相关关系,波动性越大权重越大,信息重叠越大权重越大。

3) 随机森林是一种机器学习方法,可以较好地处理高维数据,通过构建多棵决策树并结合各自预测结果,提高模型的性能。在特征权重计算方面,随机森林能评估各个特征对于模型性能的贡献度,进而确定权重的重要程度。

### 1.2 基于合作博弈的组合权重

通过将主观方法层次分析法、客观方法 CRITIC 权重法和机器学习中的随机森林求得的权重进行组合,可有效避免单一方法进行权重确定时的不准确性。相较于引入由经验确定的调节因子进行线性加权的方法,采用合作博弈对各特征进行赋权可有效避免人为经验造成的影响,提高组合权重精确度,使上述方法优点得以正常发挥,消除单一方法的缺陷和不利影响。基于合作博弈的思想,将不同特征权重的计算方法看作一个整体,计算组合权重,进而确定该特征的最终权重,计算步骤如下。

1) 计算  $W(i)$  和  $W(m\_i)$  的相关系数  $L(i)$  为:

$$L(i) = \frac{\sum_{j=1}^n [W_j(i) - \overline{W(i)}] [W_j(m\_i) - \overline{W(m\_i)}]}{\sqrt{\left\{ \sum_{j=1}^n [W_j(i) - \overline{W(i)}]^2 \right\}^{1/2} \left\{ \sum_{j=1}^n [W_j(m\_i) - \overline{W(m\_i)}]^2 \right\}^{1/2}}} \quad (1)$$

式中:  $W_j(i)$  为使用第  $i$  种方法计算的第  $j$  个指标的权重;  $\overline{W(i)}$  为使用第  $i$  种方法得到的  $n$  项指标权重的平均值;  $W_j(m\_i)$  为除第  $i$  种方法外的  $m-1$  种方法计算的第  $j$  个指标的组组合权重;  $\overline{W(m\_i)}$  为  $n$  项指标权重  $W_j(m\_i)$  的平均值。

2) 计算组合权重  $W$ :

$$W = \begin{cases} \sum_{i=1}^n W(i) \cdot L(i), & i \geq 3 \\ \frac{W(1) + W(2)}{2}, & i = 2 \end{cases} \quad (2)$$

3) 将组合权重  $W$  进行归一化得到最终权重。

## 2 DBO-BiLSTM-Attention 预测算法

BiLSTM 对于长序列的样本可能会丢失部分重要信息,影响预测的精度。对此,引入注意力机制可以使模型更加关注于输入序列中的关键部分,进而提高模型对长序列的处理能力。同时,BiLSTM 中超参数(初始学习率、隐藏层神经元个数和 L2 正则化系数等)的选择也对其拟合能力具有关键作用,为获取最佳超参数,采用 DBO 进行寻优,进一步提高模型性能。

### 2.1 DBO 算法

DBO 算法<sup>[18]</sup>是一种模拟自然界中蜣螂行为的群智能优化算法,通过模拟蜣螂的滚球、跳舞、繁殖、觅食和偷窃等行为解决寻优问题。其结合了局部搜索和全局搜索策略,能有效避免陷入局部最优解,并具有较快的收敛速度,步骤如下:

步骤 1) 初始化蜣螂种群和算法参数,计算每个蜣螂的适应度值,根据位置公式更新所有蜣螂位置;

步骤 2) 确保每个蜣螂的位置没有超出搜索空间的上下边界,若超出则进行边界限制出来,否则进行下一步;

步骤 3) 根据更新后的位置重新计算每个蜣螂的适应度值,并检查是否达到停止迭代的条件,若没有则重复执行上述步骤,直到满足终止条件为止,最终输出最优解以适应度值。

### 2.2 BiLSTM 网络

BiLSTM<sup>[19]</sup>是传统单向长短期记忆神经网络(long short term memory, LSTM)的优化改进,包含一个前向 LSTM 层和一个后向 LSTM 层,既有利于前向序列信息输入也有利于后向序列信息输入,充分考虑过去和未来信息,进而提高模型预测的精度。BiLSTM 神经网络结构如图 1 所示。其中,  $x_1, x_2, x_3, \dots, x_t$  为  $t_1 \sim t_t (i \in [1 \sim t])$  各个时刻相应的输入数据;  $A_1, A_2, A_3, \dots, A_t, B_1, B_2, B_3, \dots, B_t$  分别为相应的向前和向后迭代的 LSTM 隐藏状态;  $Y_1, Y_2, Y_3, \dots, Y_t$  为相应的输出数据;  $\omega_1, \omega_2, \omega_3, \dots, \omega_6$  为各层相应的权重。

前向 LSTM、后向 LSTM 的隐藏层更新状态及 BiLSTM 最终输出过程如式(3)~(5)所示。

$$A_i = f_1(\omega_1 x_i + \omega_2 A_{i-1}) \quad (3)$$

$$B_j = f_2(\omega_3 x_i + \omega_5 B_{j+1}) \quad (4)$$

$$Y_i = f_3(\omega_4 A_i + \omega_6 B_i) \quad (5)$$

式中:  $f_1, f_2, f_3$  分别为不同层之间的激活函数。

### 2.3 注意力机制

注意力机制<sup>[20]</sup>是一种模拟人类视觉接收信息的大脑信号处理机制,在某些特定的情况下,人脑会将注意力

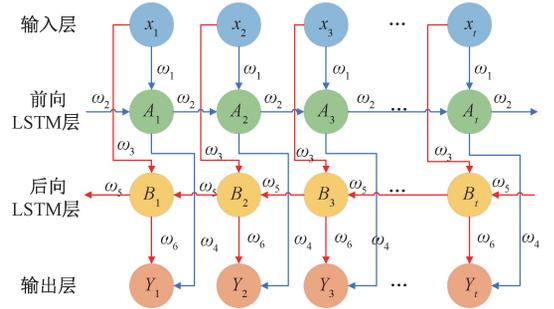


图 1 BiLSTM 网络结构

Fig. 1 BiLSTM network structure

分配在需要重点关注的某些方面,对不需要重点关注的方面减少和不分配。这种机制可以从有限的注意力资源中快速筛选出所需要的信息。注意力状态转换过程如式(6)~(9)所示。

$$S_{ii} = V \tanh(W h_i + U h_i + b) \quad (6)$$

$$a_{ii} = \frac{\exp(S_{ii})}{\sum_{k=1}^t \exp(S_{ik})} \quad (7)$$

$$F = \sum_{i=1}^t a_{ii} \times h_i \quad (8)$$

$$h'_i = f(F, h_i, y_i) \quad (9)$$

式中:  $i = 1, 2, 3, \dots, t - 1$ ;  $a_{ii}$  为 BiLSTM 隐藏层输出值  $h_i$  对当前输入的注意力权重值;  $y_1, y_2, y_3, \dots, y_t$  为输入序列;  $h_1, h_2, h_3, \dots, h_t$  为对于输入序列  $y_1, y_2, y_3, \dots, y_t$  的隐藏层状态值;  $h'_i$  为最终的特征向量;  $V, W, U, b$  为模型的学习参数,随着模型训练过程不断更新。

## 3 充电桩故障预测模型

提出的基于合作博弈策略和 DBO-BiLSTM-Attention 的充电桩故障预测方法具体流程如图 2 所示。

步骤 1) 数据收集。收集充电桩相关数据信息,包括 ID、Label 等基本数据信息, K1K2 驱动信号、电子锁驱动信号、门禁信号、急停信号、THDI-M 和 THDV-M 等参数特征数据信息。

步骤 2) 数据处理。对收集到的充电桩特征数据信息进行处理,通过参数统计分布处理异常数据,通过均值填充处理缺失数据,对处理后的数据进行归一化操作。

步骤 3) 参数特征单一权重计算。对 6 项参数特征分别通过主观方法层次分析法、客观方法 CRITIC 权重法和机器学习中的随机森林 3 种方法进行单一权重计算。

步骤 4) 参数特征组合权重计算。通过合作博弈策略对每项参数特征的权重进行组合,并依据组合权重进行特征放大,得到新参数特征矩阵。

步骤 5) 充电桩故障预测模型。将新参数特征矩阵

划分为训练集和测试集,通过 DBO-BiLSTM-Attention 模型进行故障预测,得到预测结果。

步骤 6) 结果分析。设计相关对比实验,选择准确率和 F1 系数作为评价指标,并进行实验结果分析。

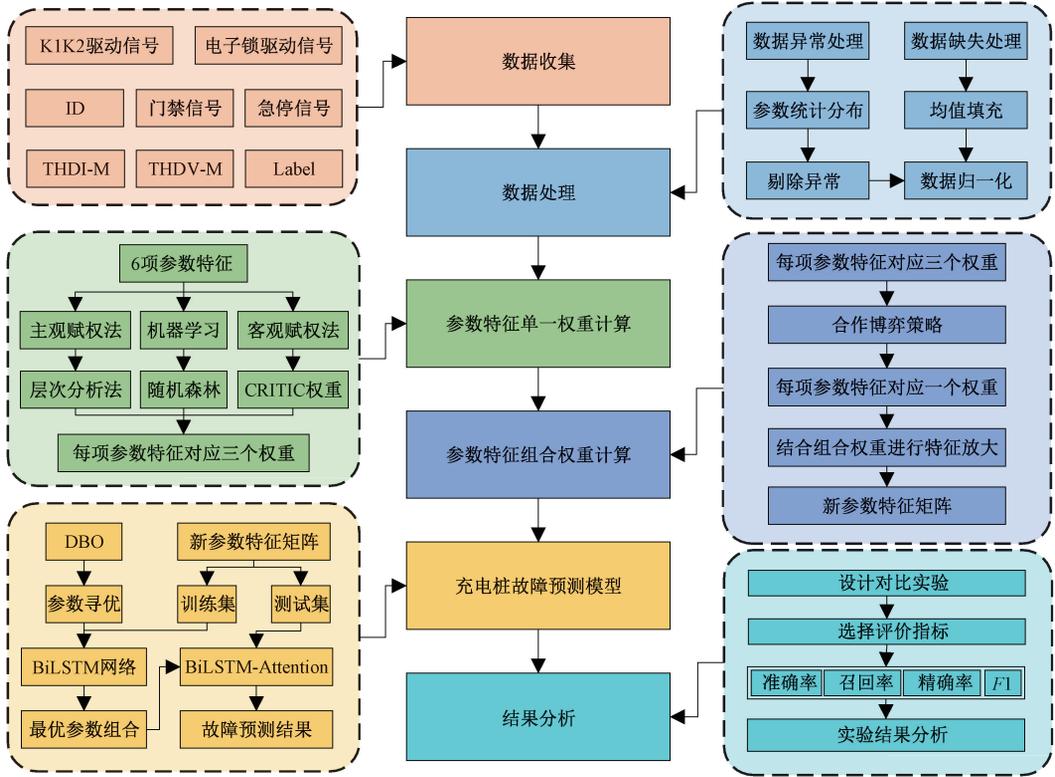


图 2 充电桩故障预测方法具体流程

Fig. 2 Specific process of fault prediction method for charging stations

## 4 算例分析

### 4.1 数据来源

由于充电桩故障预测涉及多个互有关联的参数,选取对充电桩故障预测选取其内部的 K1K2 驱动信号、电子锁驱动信号、急停信号、门禁信号,以及与上级电网相连电压的总谐波失真和电流的总谐波失真这 6 个参数对故障进行预测。使用的数据为百度新手赛中充电桩故障分类与检测数据集。数据说明如表 1 所示。

表 1 数据字段说明

Table 1 Data field description

| 字段名       | 描述                       | 样例 1   | 样例 2   |
|-----------|--------------------------|--------|--------|
| 序号        | 充电桩 ID                   | 3      | 4      |
| K1K2 驱动信号 | K1K2 驱动信号                | 11.848 | 11.820 |
| 电子锁驱动信号   | 电子锁驱动信号                  | 12.124 | 12.123 |
| 急停信号      | 急停信号                     | -0.068 | -0.069 |
| 门禁信号      | 门禁信号                     | 12.058 | 12.078 |
| THDV-M    | 电压的总谐波失真                 | 12.604 | 24.428 |
| THDI-M    | 电流的总谐波失真                 | 43.381 | 39.464 |
| Label     | 正常情况的标签<br>(0 为正常,1 为异常) | 1      | 0      |

表 1 中,急停信号的作用是在充电桩运行过程中发生故障、操作失误、意外发生或其他紧急情况下,切断充电桩电源,停止输出,从而避免进一步的伤害或损失;K1K2 驱动信号的作用包括保证安全、启动充电流程、实现锁止功能等;电子锁驱动信号的作用包括物理连接的确认、安全锁定机制、故障防护等;门禁信号是用于验证用户身份和授权充电的一种安全措施;电压的总谐波失真谐波会使电力系统变得不稳定,导致灯光闪烁,造成视觉上的干扰和不适;电流的总谐波失真谐波会导致额外的电网损耗,降低功率因数,损坏设备。增加电子设备的噪音和干扰,可能影响到无线电和其他设备的正常工作。

### 4.2 评价指标

选取常用的准确率 (accuracy) 和 F1 系数作为评价指标<sup>[21]</sup>,以便全面而深入地评估分类预测模型的性能。其中,准确率指预测正确样本占总样本的比例;F1 系数是结合召回率 (recall) 和精确率 (precision) 的综合评价指标;召回率指实际为正样本的结果中,预测为正样本的比例;精确率指预测为正样本的结果中,实际为正样本的比例。计算公式分别为:

$$L_{accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (10)$$

$$L_{F1-Score} = \frac{2 \times L_{precision} \times L_{recall}}{L_{precision} + L_{recall}} \quad (11)$$

$$L_{recall} = \frac{TP}{TP + FN} \quad (12)$$

$$L_{precision} = \frac{TP}{TP + FP} \quad (13)$$

式中： $L_{accuracy}$ 、 $L_{recall}$ 、 $L_{precision}$  和  $L_{F1-Score}$  分别表示准确率、召回率、精确率和 F1 系数； $TP$  为将正样本预测为正样本的个数； $TN$  为将正样本预测为负样本的个数； $FN$  为将负样本预测为正样本的个数； $FP$  为将负样本预测为负样本的个数。

### 4.3 数据处理

#### 1) 数据缺失

在进行预测之前需要保证数据的完整性,因此,需要检查数据缺失与否并对缺失的数据进行填充。选择均值法对缺失数据进行填充。

$$\hat{X} = \frac{\sum_{i=1}^n \gamma X_i}{n_i} \quad (14)$$

式中： $\hat{X}$  为填充后的结果； $X_i$  为第  $i$  个特征的数据； $n_i$  为第  $i$  个特征的个数； $\gamma$  为 1 时需要填充,为 0 时不需要填充。

#### 2) 数据异常

由于充电桩故障预测涉及 K1K2 驱动信号、电子锁驱动信号、急停信号、门禁信号、电压的总谐波失真和电流的总谐波失真 6 个参数,6 个参数的统计分布如图 3 所示。

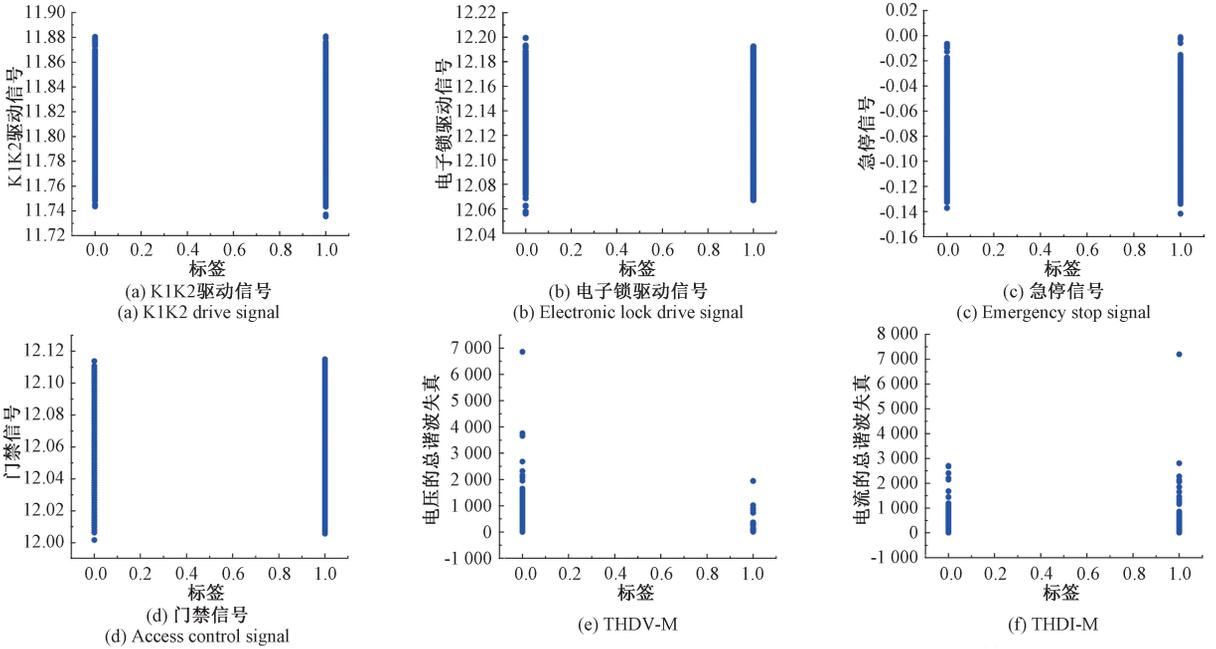


图 3 数据统计分布情况  
Fig. 3 Distribution of data statistics

由图 3 可知,前 4 个属性值没有明显异常数据,从电压总谐波失真数据中可以看出类别为正常的属性值基本分布在 0~4 000,只有一个属性值接近 7 000,可以判断属性值为 6 861 的这条记录为异常记录。同理,从电流总谐波失真数据分布中可以看出,类别为异常的属性值基本分布在 0~3 000,而有一个属性值为 7 197,包含此属性值的记录应为异常记录。由于数据集中数据较多,而明显异常充电桩数据只有两条,故选择删除异常值的处理方法。

#### 3) 数据归一化

由于 6 个特征参数的单位有所不同,为了在训练和

预测时方便计算和提高预测精度,需要将不同单位的数据转换为相同单位下的数据,即归一化,归一区间为 [0, 1], 计算公式如式 (15) 所示。

$$X_1 = \frac{X - X_{min}}{X_{max} - X_{min}} \cdot (\max - \min) + \min \quad (15)$$

式中： $X_1$  为归一化后的结果； $X$  为特征数据； $X_{max}$ 、 $X_{min}$  是在给定放缩范围内的最大值和最小值； $\max$  和  $\min$  取值为 0.9 和 0.1。

进行归一化之前的部分数据如图 4(a) 所示,进行归一化之后的数据如图 4(b) 所示。

由图 4(a) 可知,前 5 个特征均为电压数据,难以和

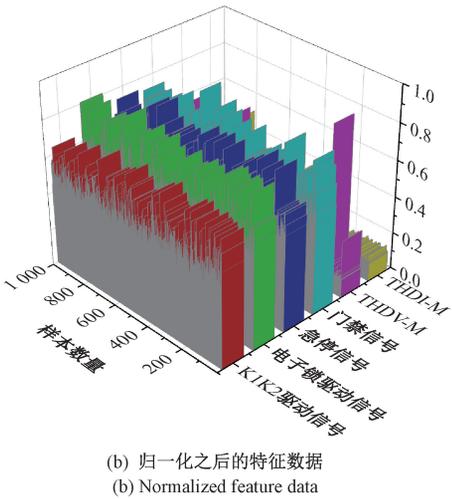
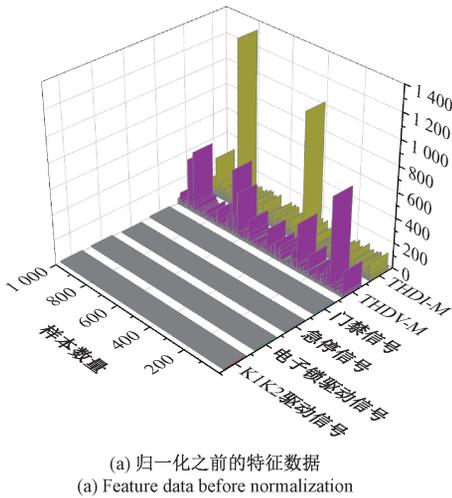


图 4 相关特征数据  
Fig. 4 Related feature data

第 6 个特征电流数据的单位相匹配,相对特征表现不明显,需要归一化处理。由图 4(b)可知,归一化后的 6 个特征数据表现较归一化之前良好,可视性更强,具有更好的比较性。

#### 4.4 新参数特征矩阵

选取客观方法 CRITIC 权重法、主观方法层次分析法和机器学习中的随机森林分别对 6 项参数特征进行单一权重计算,并通过合作博弈策略计算 6 项参数特征的组合权重。为便于表达,M1 表示 CRITIC 权重法、M2 表示层次分析法、M3 表示随机森林、M4 表示层次分析法和 CRITIC 权重法通过合作博弈策略计算的组合权重、M5 表示上述 3 种单一权重计算方法通过合作博弈策略计算的组合权重,结果如图 5 和表 2 所示。

由图 5 和表 2 可知,各项参数特征经过合作博弈策略后组合权重均位于单一权重之间,可以较好地结合不同单一权重的优点,使权重结果更加精准。同时,由于随机森林算法主要是通过参数特征 THDI-M 进行故障预

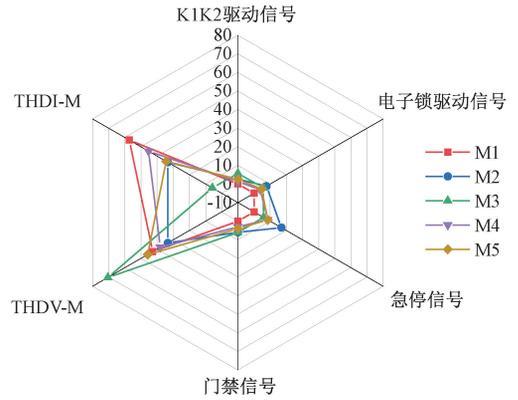


图 5 权重分布情况  
Fig. 5 Weight distribution

测,因此相较于 M4、M5 中 THDI-M 的权重有所提升。结合表 2 中 5 种方法的参数特征权重计算结果,对原始参数特征进行放大,放大结果如表 3 所示。

表 2 权重计算结果

Table 2 Weight calculation results

| 参数特征      | M1     | M2     | M3     | M4     | M5     |
|-----------|--------|--------|--------|--------|--------|
| K1K2 驱动信号 | 0.015  | 2.620  | 5.700  | 1.317  | 2.528  |
| 电子锁驱动信号   | 0.014  | 7.655  | 5.900  | 3.834  | 4.671  |
| 急停信号      | 0.014  | 16.947 | 5.900  | 8.480  | 8.535  |
| 门禁信号      | 0.012  | 6.003  | 6.100  | 3.007  | 4.034  |
| THDI-M    | 42.73  | 33.388 | 70.500 | 38.059 | 45.840 |
| THDV-M    | 57.216 | 33.388 | 5.800  | 45.302 | 34.392 |

表 3 新参数特征矩阵

Table 3 New parameter feature matrix

| 参数特征      | 原始数据   | 归一化数据 | M4    | M5    |
|-----------|--------|-------|-------|-------|
| K1K2 驱动信号 | 11.848 | 0.686 | 0.903 | 1.733 |
| 电子锁驱动信号   | 12.124 | 0.515 | 1.975 | 2.407 |
| 急停信号      | -0.068 | 0.544 | 4.617 | 4.646 |
| 门禁信号      | 12.058 | 0.500 | 1.504 | 2.017 |
| THDI-M    | 12.604 | 0.104 | 3.965 | 4.776 |
| THDV-M    | 43.381 | 0.111 | 5.022 | 3.813 |

#### 4.5 预测结果分析

为验证所提模型的有效性,对以下 8 种预测模型分别进行讨论,8 种模型评价指标分布情况如图 6 所示,计算结果如表 4 所示。

模型 1,不进行特征放大,通过朴素贝叶斯<sup>[22]</sup>模型进行故障预测。

模型 2,不进行特征放大,通过支持向量机<sup>[23]</sup>模型进行故障预测。

模型 3,不进行特征放大,通过预测算法 DBO-BiLSTM-Attention 模型进行故障预测。

模型 4,采用权重计算结果 M5 进行特征放大,通过 BiLSTM 模型进行故障预测。

模型 5,采用权重计算结果 M5 进行特征放大,通过 DBO-BiLSTM 模型进行故障预测。

模型 6,采用权重计算结果 M5 进行特征放大,通过 BiLSTM-Attention 模型进行故障预测。

模型 7,采用权重计算结果 M4 进行特征放大,通过 DBO-BiLSTM-Attention 模型进行故障预测。

模型 8(本文),采用权重计算结果 M5 进行特征放大,通过 DBO-BiLSTM-Attention 模型进行故障预测。

结合图 6 和表 4 可知,相较于传统方法模型 1 和模型 2,无论是训练集还是测试集,所提模型在准确率和 F1 系数均提升 20%以上,有明显提升。相较于模型 3 不进行特征放大,训练集中准确率和 F1 系数提升约 4%,测试集中准确率和 F1 系数提升约 5%,验证了对参数特征进行放大可以在突出主要特征的同时,有效避免其他特征的影响。模型 4~6 是所提模型中预测算法部分的消融实验,其中,模型 5 性能优于模型 4 和 6,表明选取恰当的 BiLSTM 参数有助于提高模型性能,模型 6 性能优于模型 4,验证了注意力机制的有效性。相较于模型 7,本文模型性能均有所提升,表明在合作博弈策略中加入随机森林算法有助于更合理地对特征进行放大。综上,验证了所提模型的有效性和合理性。

### 5 结论

在充电桩故障预测方法中,大多模型未考虑原始数据中特征大小对模型的影响,且传统的合作博弈策略单纯考虑了主观评价方法和客观评价方法,具有一定局限性。针对这一问题,提出一种基于合作博弈策略和 DBO-BiLSTM-Attention 的电动汽车充电桩故障预测方法。该方法选取主观评价方法层次分析法、客观评价方法 CRITIC 权重法和机器学习算法中的随机森林依次计算特征权重,采用合作博弈策略对上述特征权重进行组合,得到新特征权重,并对参数特征矩阵进行放大。同时,分别引入蛭螂优化算法和注意力机制,搭建 DBO-BiLSTM-Attention 模型,可有效提高充电桩故障预测准确率。

综上,将合作博弈策略引入充电桩故障预测后,拓宽了传统故障预测的技术道路,为充电桩实时故障预测提供了一个有效手段。未来的研究方向将重点提高模型的运行效率和实时性,以更好地应对实际复杂环境。

### 参考文献

[ 1 ] YANG Y Y, ZHU W. Research based on improved CNN-SVM fault diagnosis of V2G charging pile [ J ]. Electronics, 2023, 12(3) :655-655.

[ 2 ] 张梅,高犁,陈万利. 基于 FASSA-SVM 的充电桩故障预测算法研究[J]. 电子测量技术, 2022, 45(12) : 48-53.

ZHANG M, GAO L, CHEN W L. Research on fault prediction algorithm of charging pile based on FASSA-SVM [ J ]. Electronic Measurement Technology, 2022, 45(12) :48-53.

[ 3 ] 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 Z Q, JIN T, LIU Y L, et al. Open circuit fault

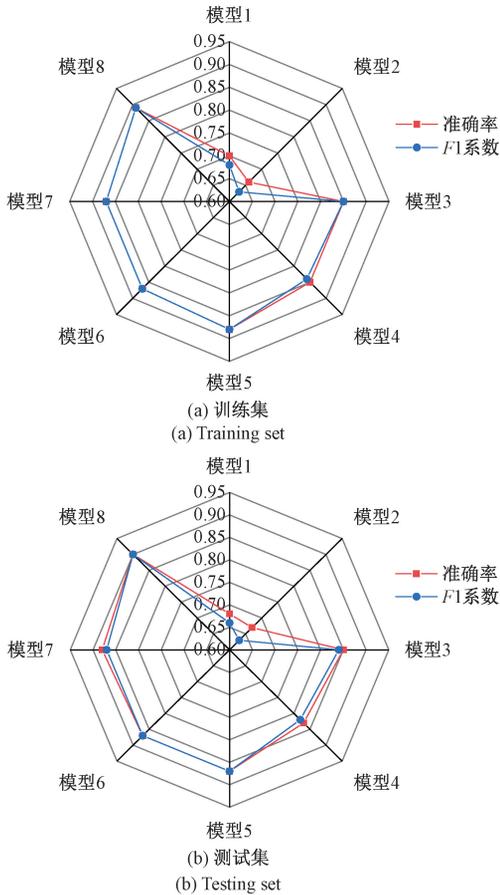


图 6 评价指标分布情况

Fig. 6 Distribution of evaluation indicators

表 4 评价指标计算结果

Table 4 Calculation results of evaluation indicators

| 模型   | 训练集  |       | 测试集  |       |
|------|------|-------|------|-------|
|      | 准确率  | F1 系数 | 准确率  | F1 系数 |
| 模型 1 | 0.70 | 0.68  | 0.68 | 0.66  |
| 模型 2 | 0.66 | 0.63  | 0.67 | 0.63  |
| 模型 3 | 0.85 | 0.85  | 0.85 | 0.84  |
| 模型 4 | 0.85 | 0.84  | 0.83 | 0.82  |
| 模型 5 | 0.88 | 0.88  | 0.87 | 0.87  |
| 模型 6 | 0.87 | 0.87  | 0.87 | 0.87  |
| 模型 7 | 0.87 | 0.87  | 0.88 | 0.87  |
| 模型 8 | 0.89 | 0.89  | 0.90 | 0.90  |

- 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.
- [ 4 ] 杨凤坤, 徐石明, 周静, 等. 基于小波包分析的电动汽车直流充电桩功率器件开路故障诊断研究[J]. *电器与能效管理技术*, 2018 (23):79-85.  
YANG F K, XU SH M, ZHOU J, et al. Research on fault diagnosis of DC charger power device based on wavelet packet analysis [J]. *Electrical & Energy Management Technology*, 2018 (23):79-85.
- [ 5 ] 王群飞, 尹忠东, 鄂涛. 基于随机森林算法的 V2G 充电桩故障诊断研究[J]. *电测与仪表*, 2024, 1(8):111-118.  
WANG Q F, YIN ZH D, E T. Research on fault diagnosis of V2G charging pile based on random forest algorithm[J]. *Electrical Measurement & Instrumentation*, 2024, 1(8):111-118.
- [ 6 ] 程侃如, 王玉璋, 杨志鹏, 等. 基于 SSA 和注意力机制 BiLSTM 的燃气轮机传感器故障诊断方法研究[J]. *动力工程学报*, 2023, 43(9):1181-1189.  
CHENG K R, WANG Y ZH, YANG ZH P, et al. Gas turbine sensor fault diagnosis method based on SSA and BiLSTM with attention mechanism [J]. *Journal of Chinese Society of Power Engineering*, 2023, 43(9):1181-1189.
- [ 7 ] 王雷, 何坤, 李宗帅, 等. 基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究[J]. *电子测量与仪器学报*, 2023, 37(7):205-212.  
WANG L, HE K, LI Z SH, et al. Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(7):205-212.
- [ 8 ] QI Y, XUE K L, WANG W, et al. Coal and gas protrusion risk evaluation based on cloud model and improved combination of assignment [J]. *Scientific Reports*, 2024, 14(1):4551-4551.
- [ 9 ] 吴建斌, 谷志红, 王正, 等. 基于博弈变权-云模型的配电网设备精益运维多属性评价[J]. *科学技术与工程*, 2021, 21(27):11615-11623.  
WU J B, GU ZH H, WANG ZH, et al. Multi-attribute evaluation on lean operation and maintenance of distribution network equipment based on game variable weight cloud model [J]. *Science Technology and Engineering*, 2021, 21(27):11615-11623.
- [10] LI S W, WU H B, YANG X D, et al. Node vulnerability-aware co-deployment of D-PMUs and FTUs for active distribution networks[J]. *International Journal of Electrical Power and Energy Systems*, 2023, 155(6):109484.
- [11] ZAHRA F, ELAHEH M, MAHMOOD J. A deep model for short-term load forecasting applying a stacked autoencoder based on LSTM supported by a multi-stage attention mechanism [J]. *Applied Energy*, 2022, 327(1):120063.
- [12] 方斯顿, 刘龙真, 孔赖强, 等. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计[J]. *电力系统自动化*, 2024, 48(4):160-168.  
FANG S D, LIU L ZH, KONG L Q, et al. State-of-health estimation for lithium-ion batteries incorporating indirect health indicators based on bi-directional long short-term memory networks[J]. *Automation of Electric Power Systems*, 2024, 48(4):160-168.
- [13] XUE J K, SHEN B. Dung beetle optimizer: A new meta-heuristic algorithm for global optimization [J]. *The Journal of Supercomputing*, 2022, 79(7):7305-7336.
- [14] LI D J, LI M Y, YANG L, et al. Rolling bearing fault diagnosis in strong noise background based on vibration signals[J]. *Signal, Image and Video Processing*, 2023, 18(2):1295-1303.
- [15] 沈赋, 杨光兵, 杨志文, 等. 考虑天然气管道泄漏的电气网络多目标优化调度[J]. *高电压技术*, 2023, 49(4):1362-1371.  
SHEN F, YANG G B, YANG ZH W, et al. Multi-objective optimal dispatch of electric-gas networks considering natural gas pipeline leakage [J]. *High Voltage Engineering*, 2023, 49(4):1362-1371.
- [16] 魏子茹, 卢延辉, 王鹏宇, 等. 基于 CRITIC 法的灰色关联理论在无人驾驶车辆测试评价中的应用[J]. *机械工程学报*, 2021, 57(12):99-108.  
WEI Z R, LU Y H, WANG P Y, et al. Application of grey correlation theory based on CRITIC method in autonomous vehicles test and evaluation [J]. *Journal of Mechanical Engineering*, 2021, 57(12):99-108.
- [17] BEHZAD R S, GREGORY P, VINCENT C, et al. Predicting uncertainty of a chiller plant power consumption using quantile random forest: A commercial building case study[J]. *Energy*, 2023, 283:129112.
- [18] 周亚中, 何怡刚, 邢致恺, 等. 基于 IDBO-ARIMA 的电力变压器振动信号预测[J]. *电子测量与仪器学报*, 2023, 37(8):11-20.  
ZHOU Y ZH, HE Y G, XING ZH K, et al. Power transformer vibration signal prediction based on IDBO-ARIMA [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(8):11-20.
- [19] MA T, CHEN H, ZHANG K, et al. The rheological

intelligent constitutive model of debris flow: A new paradigm for integrating mechanics mechanisms with data-driven approaches by combining data mapping and deep learning[J]. Expert Systems With Applications, 2025, 269:126405-126405.

- [20] 左震, 郭润泽, 孙备, 等. 海面无人艇对舰船目标的细粒度检测方法[J]. 仪器仪表学报, 2024, 45(12): 221-233.

ZUO ZH, GUO R Z, SUN B, et al. Fine-grained detection of ship objects by unmanned surface vehicles[J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 221-233.

- [21] 王铨浩, 骆忠强, 漆梓渊. 基于改进 YOLOv5 的变压器漏油检测[J]. 国外电子测量技术, 2023, 42(9): 169-176.

WANG CH H, LUO ZH Q, QI Z Y. Transformer oil leakage detection based on improved YOLOv5 [J]. Foreign Electronic Measurement Technology, 2023, 42(9): 169-176.

- [22] ADNAN A, AWAIS A, SAJID A. An adaptive learning approach for customer churn prediction in the telecommunication industry using evolutionary computation and Naïve Bayes[J]. Applied Soft Computing Journal, 2023, 137:110103.

- [23] 孙东杰, 宋爱国. 基于传感阵列的动态足底压力分布测量系统[J]. 仪器仪表学报, 2022, 43(6): 83-91.

SUN D J, SONG AI G. A dynamic plantar pressure

distribution measurement system based on sensor array[J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 83-91.

## 作者简介



陈庆斌, 2022 年于天津职业技术师范大学获得学士学位, 现为天津职业技术师范大学硕士研究生, 主要研究方向为智能信息处理及应用。

E-mail: c1185955913@163.com

**Chen Qingbin** received his B. Sc. degree from Tianjin University of Technology and Education in 2022. Now he is a M. Sc. candidate at Tianjin University of Technology and Education. His main research interests include intelligent information processing and application.



杨耿煌, 2001 年于中国农业大学获得学士学位, 2007 年于中国农业大学获得博士学位, 现为天津职业技术师范大学教授、天津电子信息职业技术学院教授, 主要研究方向为智能信息处理技术。

E-mail: ygh@tute.edu.cn

**Yang Genghuang** received his B. Sc. degree from China Agricultural University in 2001 and Ph. D. degree from China Agricultural University in 2007, respectively. Now he is a professor at Tianjin University of Technology and Education and Tianjin Electronic Information College. His main research interest includes intelligent information processing.