

DOI:10.19651/j.cnki.emt.2208912

基于FASSA-SVM的充电桩故障预测算法研究^{*}

张梅 高犁 陈万利

(安徽理工大学电气与信息工程学院 淮南 232001)

摘要:为了电动汽车直流充电桩的安全稳定运行,提出一种基于改进支持向量机的充电桩故障预测算法。该算法首先针对充电桩的运行参数进行缺失值填充、归一化等预处理;然后将预处理后的数据输入支持向量机模型训练,之后引入萤火虫算法改进麻雀算法对支持向量机模型进行参数寻优,得到最优模型;最后利用得到的最优模型预测诊断充电桩运行状态,来判断充电桩是否发生故障。实验结果表明,本文的预测算法预测精度可达94.68%,远高于传统的支持向量机模型的72.34%,能较准确地预测充电桩运行状态,为其预知维修、保障安全运行提供有力保障。

关键词:充电桩;故障预测;支持向量机;麻雀搜索算法;萤火虫算法

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

Research on fault prediction algorithm of charging pile based on FASSA-SVM

Zhang Mei Gao Li Chen Wanli

(School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: For the safe and stable operation of electric vehicle DC charging piles, this paper proposes a charging pile fault prediction algorithm based on improved support vector machine. The algorithm first performs preprocessing such as missing value filling and normalization in the operating parameters of the charging pile; then the preprocessed data is input into the support vector machine model for training, and then the firefly algorithm is introduced for improving the sparrow algorithm to search for the parameters for the support vector machine model. The optimal model is obtained; finally, the obtained optimal model is used to predict and diagnose the operation state for the charging pile to judge whether the charging pile is faulty. The experimental results show that the prediction accuracy of the prediction algorithm in this paper could reach 94.68%, which is much higher than 72.34% of the traditional support vector machine model.

Keywords: charging pile; failure prediction; support vector machine; sparrow search algorithm; firefly algorithm

0 引言

随着全球不可再生能源的消耗与科学技术的发展,新能源动力的汽车行业得以快速发展^[1-3]。在新能源汽车行业扩大的同时,充电桩市场也在同时扩大。充电桩对于新能源产业必不可少,充电桩的稳健推行才可以有效推动新能源行业的发展。而充电桩的及时预警对充电桩的快速维修及安全运行有着重要的现实意义^[4-7]。

新能源产业的充电桩有交流和直流充电桩两种,直流充电桩因其较高的充电效率具有广泛的应用市场。目前针对直流充电桩,研究热点主要是充电策略、控制系统和负电预测等^[8-10],故障诊断与预警研究相对较少。文献[11]将

深度神经网络引入充电桩诊断,实现不同控制策略、不同状态下根据特征自主学习和诊断,提高了预测精度,但存在结构复杂的不足;文献[12]利用小波包分析的方法依靠能量谱和功率谱分析得到故障特征并分析,避免了小波函数的选择对系统故障诊断的影响,但是算法需要反复试验以求得最佳结果,可能会降低计算速率。文献[13]利用随机森林算法,并引入主成分分析降维减少了训练时间,但采集数据的设备要求较多、复杂性更明显。加上算法对数据的精度要求较高使得算法在实际推广中存在一定的阻力。

上述研究从不同角度对直流充电桩故障诊断和预测的优化做出贡献。虽然在多种方面提出改进问题,但依靠的数据受限较多,预测诊断耗时较长,难以将精度和速率合适匹配。

收稿日期:2022-01-21

*基金项目:安徽高校自然科学研究项目(KJ2020A0309)资助

支持向量机(support vector machine, SVM)在一段时间是最好分类的算法,有较好的分类推广能力^[14]。麻雀搜索算法(sparrow search algorithm, SSA)通过模拟麻雀捕食和生活状态构建其算法。大量实验证明,SSA 找寻最佳参数的效率和精度较高^[15]。但存在收敛速度不够快的缺点。萤火虫算法(firefly algorithm, FA)通过模拟萤火虫随着彼此荧光亮度相互移动进行参数寻优,有着结构简单、收敛速度较快的优点。

本文将萤火虫算法与麻雀搜索算法的优点相互结合,提出基于萤火虫算法改进麻雀搜索算法的算法(firefly algorithm improves sparrow search algorithm, FASSA)作为寻优算法,利用 FASSA 对 SVM 参数进行寻优,得到最优模型,最后利用最优模型对充电桩进行故障预警,判断其运行状况是否正常,为充电桩实际推广和预知维修提供可靠依据。

1 实验相关工作

1.1 支持向量机算法(SVM)

SVM 原理可以理解成解决规划问题,在给定的原数据空间内,求解分类直线目标函数可以用式(1)表示:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \epsilon_i \quad (1)$$

$$\text{s. t. } y_i(\omega^T x_i + b) \geq 1 - \epsilon_i, \epsilon_i \geq 0, i = 1, 2, 3, \dots, n$$

式中:min 表示距离分类直线最近的点; C 为惩罚参数; ϵ_i 是松弛因子。

SVM 另一个重要部分为核函数及其核函数参数。核函数能够帮助 SVM 处理其不能解决的非线性问题^[16]。本文选择的是核函数是径向基函数(radial basis function, RBF),RBF 可以将数据反应到相对较高的维数里面,在面对非线性数据时能够较好地完成处理目的^[13]。其表达式如下:

$$\begin{cases} K(x_1, x_2) = e^{-\gamma \|x_1 - x_2\|^2} \\ G = \gamma \end{cases} \quad (2)$$

式中: x_1 为 RBF 中心; G 为核参数,表示被使用限制函数的覆盖范围; $K()$ 表示核函数; $K(x_1, x_2)$ 表示距离中心点 x_1 的最大位置。

1.2 麻雀搜索算法(SSA)

SSA 通过模拟麻雀捕食和生活状态构建其算法。在麻雀种群中分为发现者与加入者,两种身份比率不变但是成员可以变化。发现者负责搜索食物区域,且自身发现食物丰富程度与自身能量成正比。种群中所有麻雀都参与监控捕食者,并在危险值大于阈值时发出警报。每次迭代麻雀都会更新自己的位置并根据自身能量来决定发现者资格得失与否^[17]。

在麻雀种群中由 n 只麻雀组成的种群可表示为如下形式:

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & \ddots & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix} \quad (3)$$

其中, d 表示变量的维数,其选择可以依照问题的类别数量; n 是种群大小。

发现者的位置迭代更新描述为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(-\frac{i}{\alpha \cdot I}\right), & R < ST \\ X_{i,j}^t + Q \cdot L, & R \geq ST \end{cases} \quad (4)$$

式中: t 代表当前迭代数; j 的取值是 $1, 2, 3, \dots, d$; I 表示最大迭代数值,是个可以设定的数值常量; $X_{i,j}^t$ 表示第 i 麻雀在第 j 维空间位置; α 是一个有范围的数值常量, $\alpha \in (0, 1]$; R 和 ST 分别表示需要进入警戒状态的值和暂时不必警戒状态的值,取值范围分别是 $R \in [0, 1]$ 和 $ST \in [0.5, 1]$; Q 是有范围的不确定常量; L 表示全部数值都是常量 1 的大小为 $1 \times d$ 的矩阵。

而当麻雀个体能量足以获得发现者资格时,此时加入者位置更新如下。

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{worst} - X_{i,j}^t}{i^2}\right) & , i > n/2 \\ X_p^{t+1} + |X_{i,j} - X_p^{t+1}| \cdot A^+ \cdot L, & i \leq n/2 \end{cases} \quad (5)$$

其中, X_p 是目前最优坐标; X_{worst} 表示当前最差坐标; A 表示全部数值被不确定地赋值常量 1 或 -1 的大小为 $1 \times d$ 的矩阵,并且 $A^+ = A^T (AA^T)^{-1}$; 当 $i > n/2$ 时,适应度值较低的第 i 个加入者当前空腹状态,需要改变自己当前的空间坐标信息以改变现在空腹状态。

相比较之前的智能算法,SSA 算法拥有更强的找寻最优参数的能力以及难以陷入局部最优的特点。

1.3 萤火虫算法(FA)

FA 灵感来自于萤火虫依照相对亮度并移动的行为^[18]。有以下设定:萤火虫的移动只和亮度挂钩;相对亮度与彼此距离成反比,亮度与吸引力成正比;正常情况下的个体自由移动直到周围出现更亮的个体。

在萤火虫算法中,相对荧光亮度为:

$$I = I_0 \cdot e^{-\gamma r_{i,j}} \quad (6)$$

式中: I_0 为最大荧光亮度,这个值与适应度值有关,成正比关系; γ 为光强吸收系数,亮度与空气中光传播介质的吸光程度有关; $r_{i,j}$ 为个体 i 与 j 之间的相对长度。

萤火虫相互吸引度方程为:

$$\beta = \beta_0 \cdot e^{-\frac{r_{i,j}^2}{2}} \quad (7)$$

式中: β_0 表示 $r = 0$ 时的最大吸引度。

低亮度萤火虫向较亮萤火虫运动方程为:

$$x_i^{t+1} = x_i^t + \beta_0 e^{-\frac{r_{i,j}^2}{2}} (x_j^t - x_i^t) + \alpha \cdot (rand - 1/2) \quad (8)$$

式中: t 代表迭代数; x_i^{t+1} 表示在 $t+1$ 次迭代中第 i 只萤火虫的坐标变量; x_i^t 和 x_j^t 分别表示第 i 只和第 j 只萤火虫的坐标变量; α 为算法移动距离数值, 取值范围为 $\alpha \in [0, 1]$; $rand$ 在 $[0, 1]$ 上随机散落取值。

在每次迭代过程中, 每只萤火虫的位置会随着萤火虫相对荧光亮度和可见性来更新位置从而寻求最优解。FA 算法具有结构简单、易于操作和收敛速度较快等特点^[19]。

2 基于 FASSA-SVM 充电桩故障预测模型

2.1 萤火虫算法改进麻雀搜索算法(FASSA)

由于 SSA 在寻优过程中会可能会陷入局部最优从而降低精度, 因此利用 FA 对 SSA 进行优化以提高寻优精度: 在麻雀种群中载入扰动, 每个个体依照萤火虫相对亮度移动方式找寻种群中吸引力最强个体, 即适应度最佳的个体^[20]。

本文中设定警惕个体为总体的 $1/5$, 警惕者一开始位置是不确定的, 根据麻雀种群中发现者和加入者位置可以迭代的规则, 得出位置更新方程为:

$$X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta \cdot |X_{i,j}^t - X_{best}^t|, & f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{worst}^t|}{(f_i - f_w) + \epsilon} \right), & f_i = f_g \end{cases} \quad (9)$$

其中, X_{best} 是最优坐标; β 是不确定数值常量, 且 $\beta \in [0, 1]$; K 也是不确定数值常量, 表示麻雀改变当前坐标的方向以及作为控制参量数值用于补充过程, $K \in [-1, 1]$; f_i 是当前第 i 个体适应度变量; f_g 和 f_w 分别是种群中最好和最差的适应度变量; ϵ 是不为 0 常数。

$f_i > f_g$ 表示此时的麻雀极大可能遭受被捕食的风险; $f_i = f_g$ 表示麻雀存在想要改变坐标以避免被捕食的想法。

加入 FA 先对萤火虫参数进行初始化, 在 SSA 结束搜索全局最优的过程之后将每个适应度值与最优适应度值进行萤火虫扰动, 搜索范围为维度的大小, 并且对搜索范围进行遍历, 当出现更优的适应度值时将更新原有最优适应度值, 并将其对应的迭代次数进行更新并返回次数。以此来提高 SSA 寻优能力。

2.2 FASSA-SVM 预测模型

充电桩故障的数据参数和预测的分类具有非线性关系, 而且数据具有高度的波动性和随机性。本文进行实验的内容是根据充电桩 6 个特征参数来预测充电桩是否出现故障。实验目的是根据预测情况来验证模型的准确性。基于 FASSA-SVM 的充电桩预测故障模型如图 1 所示。预测模型前端是预处理充电桩电压电流数据 S1~S6, 其中包括缺失值的补充和数据归一化。在 FASSA 优化模块中设置种群参数之后求得最佳参数和适应度值。最后是构建好预测模型 FASSA-SVM 算法进行测试集的预测, 最后输出预测结果来判断充电桩是否发生故障并以此解决实际需求。

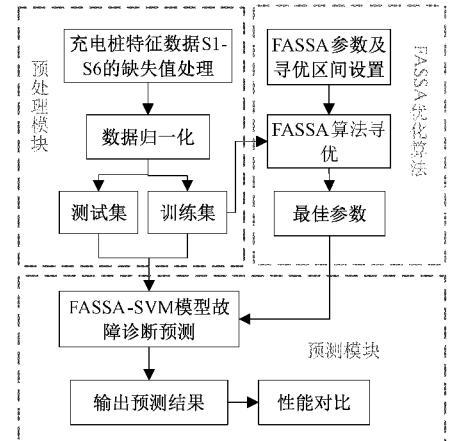


图 1 基于 FASSA-SVM 的充电桩故障预测模型

预测具体步骤如下:

步骤 1) 数据的预处理, 麻雀种群和萤火虫种群初始化, 设置适应度函数, 设置适应度函数的方程如下:

$$fitness = \frac{1}{D} \sum_{i=1}^D \frac{T_i - \hat{T}_i}{T_i} \quad (10)$$

其中, D 代表数据集; T_i 代表样本的实际值; \hat{T}_i 代表样本的训练值。适应度值会在后续的 FASSA 搜索最优参数的过程中不断更新。

之后将预处理的数据输入 SVM 模型中训练;

步骤 2) 利用式(10)计算适应度值 fitness, 将适应度值导入 SSA 模型中参数求解惩罚参数 C 和核函数参数 G 以及适应度值;

步骤 3) 根据式(4)、(5)迭代次数更新每只麻雀在每次迭代中的适应度值及其对应的 C, G 参数;

步骤 4) 引入 FA 算法, 利用式(9)对麻雀位置进行更新, C, G 参数和适应度值随之更新。以达到在最优、最差适应度值和维度范围内再一次参数寻优的目的;

步骤 5) 若求解的适应度值满足终止条件, 利用迭代得到的最优 C, G 参数和最后适应度值构建 SVM 预测模型;

步骤 6) 将之前步骤中利用充电桩数据训练得到的结果和改进之后预测算法结合, 使得模型能更好地利用 S1~S6 六组特征向量进行预测;

步骤 7) 将测试集输入 SVM 预测模型进行预测, 输出预测结果。

3 实验与结果分析

本文提出的改进麻雀优化的 SVM 预测模型, 实验相关的编译环境: Python3.8.2; 开发环境: PyCharm2020.1.4。设备的操作系统: Windows 10 64 位; 内存: 12.00 GB; 主频: 2.3 GHz; 处理器: Core i5-6300HQ; 显卡: NVIDIA GeForce 940MX。

3.1 数据预处理

本文采用 2019 年百度新手赛充电桩故障检测的数据

集实验。从中随机选取近千组数据用于本实验。数据集的前75%作为训练集,其中包含训练模型和参数寻优;后25%作为测试集,用于验证准确度。数据集拥有6个特征S1~S6,其中,S1为K1K2开关门禁信号;S2为电子锁驱动信号;S3为紧急停闸电压数值;S4为电压门禁电压数

值;S5为谐波失真的电压数值;S6为谐波失真的电流参数。S1~S5均为电压信号,S6为电流信号。部分样本数据如图2所示。由图2可以初步判断,前5组数据与后一组数据单位存在区别,在数据输入前需要进行预处理以降低实验误差。

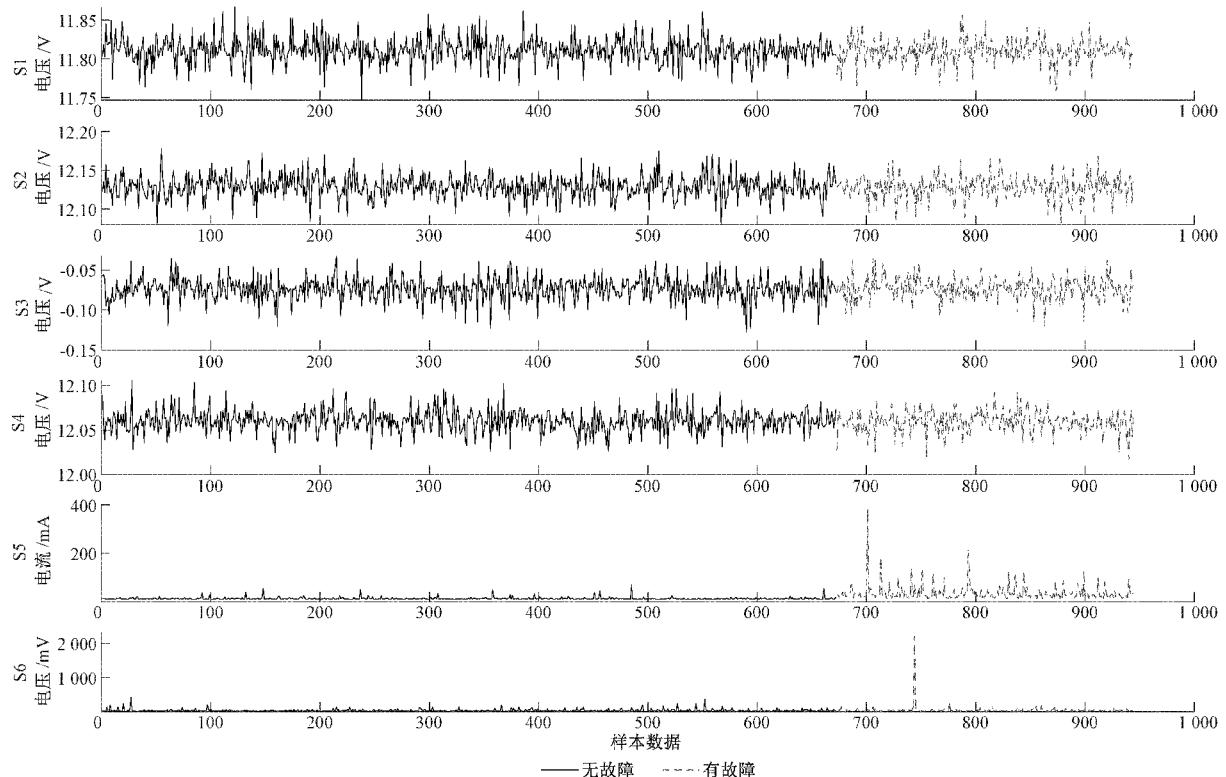


图2 充电桩故障诊断特征参数数据

1) 数据缺失处理

在进行预测之前需要保证每组数据的完整性,如此就需要检查数据缺失与否并对缺失的进行填充。本文选择的是均值法来填充缺失数据。

$$\bar{X} = \frac{\sum_{i=1}^n \gamma X_i}{n_i} \quad (11)$$

其中, X_i 为数据值, n_i 是数据个数, γ 判断数据需要进行填充, $\gamma = 1$ 表示需要进行填充, $\gamma = 0$ 表示不需要进行填充。

2) 数据归一化处理

考虑到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 $[-1, 1]$ 。表达式如下:

$$X_s = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \cdot (\max - \min) + \min \quad (12)$$

X_{\max} 和 X_{\min} 都是在给定缩放范围内的最大值和最小值,max和min可以取值0.9和0.1; X_s 为进行归一化之后的数值。

进行归一化之前的部分数据如图3所示。由图3可知,前5组数据均为电压数据,难以和后一组的电流数据的单位合适匹配,相对特征表现不明显,需要归一化处理。

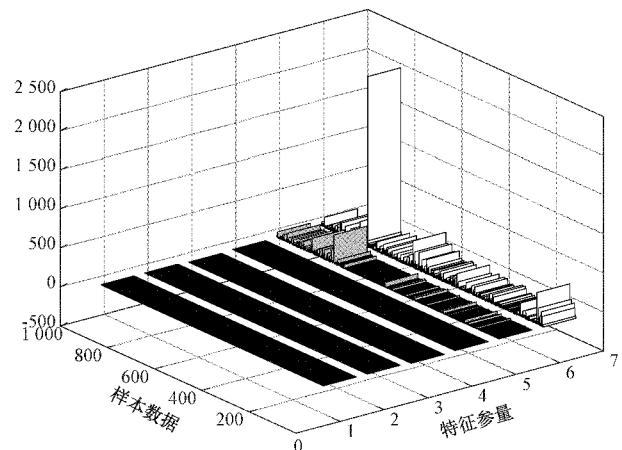


图3 归一化处理之前的特征参量数据

进行归一化之后的数据展示如图4所示。由图4可以看出归一化之后的6组数据特征表现较归一化之前良好,可读性更强,具有较好的对比性。

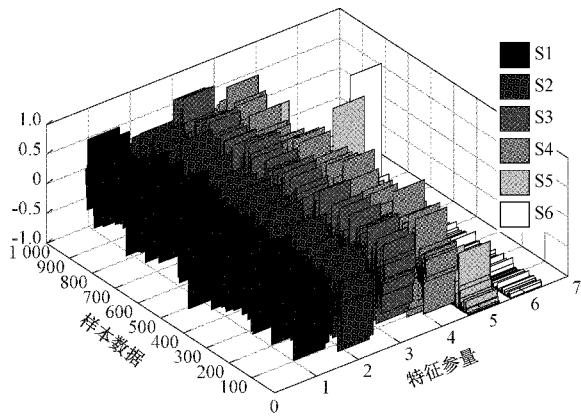


图 4 归一化处理之后的特征参量数据

3.2 参数寻优结果

传统的 SVM 模型 C 、 G 参数自行调节设置, 难以控制精度。本文选取 FASSA 优化算法对 C 、 G 参数进行搜寻: 1) SSA 算法计算设置种群中的每个个体适应度值及其种群最优的参数; 2) 在计算好最优参数的麻雀种群上加入萤火虫扰动, 使得每个个体与周围寻优的参数再进行一次比对, 以求出更好的 C 、 G 参数。FASSA 算法寻优结果 $C = 3.4775$, $G = 0.997$, 最优适应度值为 0.0531。

为验证上述优化算法找寻最佳参数的准确性, 以下采用网格搜索法遍历相同的上下区间的 C 、 G 参数, 搜索结果如图 5 所示。由图 5 可以看出, FASSA 算法的寻优结果与验证算法的寻优结果相差甚小, 因此本优化算法准确性得以验证。

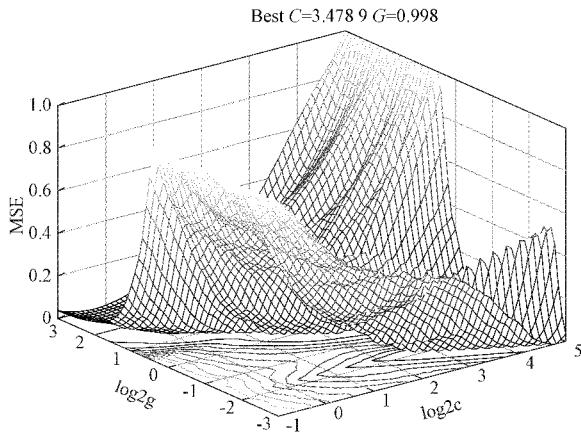


图 5 算法参数寻优结果

为验证 FASSA 优于 SSA, 作适应度曲线如图 6 所示。由图 6 可看出, FASSA 的最优适应度值的迭代次数为 31, SSA 的为 145, FASSA 效率明显优于 SSA。

3.3 模型预测结果比较

为证明本文所提出算法相对良好的特点, 选取了 SVM, SSA-SVM 和 FASSA-SVM 三种模型进行预测对比。测试集均为相同的数据, 预测指标为准确度。经过多次实验后, 记录每种模型在对数据进行预测过程中的最好结

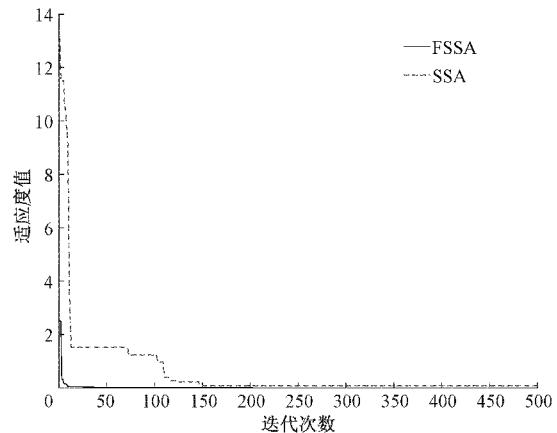


图 6 FASSA 与 SSA 的适应度曲线图

果。不同模型预测结果如图 7~9 所示。初步可以看出 SVM 模型中偏离正确值的预测值相较于其他两种优化算法的误差更多, 而 FASSA-SVM 的预测波动幅度更小。

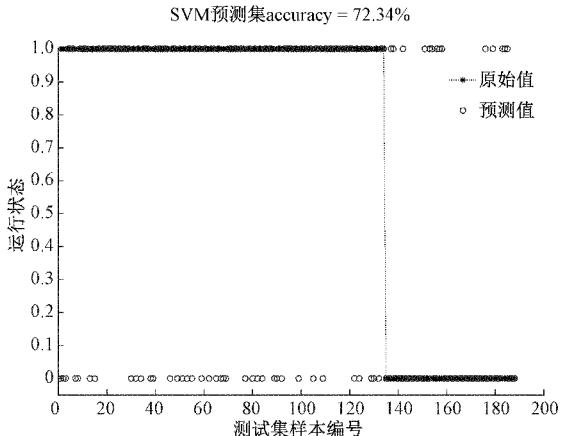


图 7 SVM 预测结果

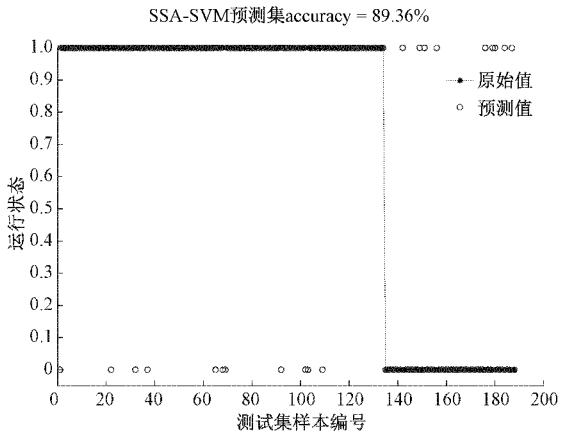


图 8 SSA-SVM 预测结果

图 7~9 中, 0 表示运行正常, 1 表示故障。由图可知, FASSA-SVM 的预测精度为 94.68%, 相较于 SSA-SVM 的 89.36% 和 SVM 的 72.34% 而言, 明显更佳。再结合参

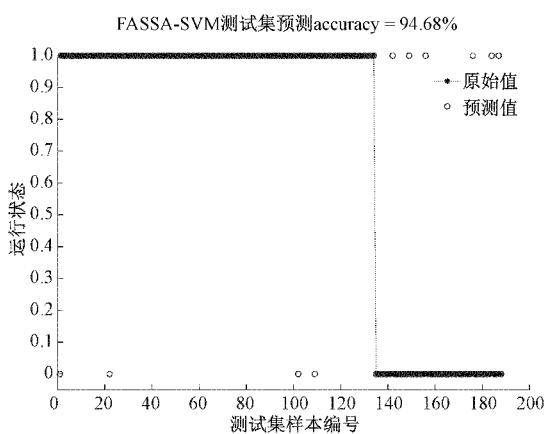


图 9 FASSA-SVM 预测结果

数寻优结果和两种优化算法的迭代结果,可以看出 FASSA-SVM 无论在准确度还是在得到最优适应度值的迭代次数上都优于其他两种预测模型,具有更好的适应性。

综上可知,基于 FASSA-SVM 的充电桩故障分类预测的精度要远高于 SSA-SVM 算法和传统的 SVM 算法,而且寻优收敛速度也更快。

4 结 论

针对充电桩故障预测,本文提出了一种基于 FASSA-SVM 的预测算法,以实际充电桩数据为例进行了相关实验。对比传统的 SVM 模型及 SSA 优化的 SVM 模型,本文的 FASSA-SVM 模型预测精度更高,可达 94.68%。在优化 SVM 时,相比 SSA 优化算法,FASSA 寻优的迭代次数少很多,效率更高。通过遍历整个区域内的 SVM 参数,可发现 FASSA 的寻优结果极其精确。综上,本文所提出的充电桩预测算法在预测精度和效率上都有明显优势,具有一定的应用前景。

参考文献

- [1] 白政.“十四五”时期新能源汽车产业竞争力提升的方向与路径[J]. 价格理论与实践, 2021(2): 18-24.
- [2] 左世全, 赵世佳, 祝月艳. 国外新能源汽车产业政策动向及对我国的启示[J]. 经济纵横, 2020(1): 113-122.
- [3] PALMER C. 电动汽车市场加速发展[J]. Engineering, 2021, 7(2): 13-18.
- [4] 李惠玲, 白晓民. 电动汽车充电对配电网的影响及对策[J]. 电力系统自动化, 2011, 35(17): 38-43.
- [5] 陈良亮, 张浩, 倪峰, 等. 电动汽车能源供给设施建设现状与发展探讨[J]. 电力系统自动化, 2011, 35(14): 11-17.
- [6] 尚夏, 王美佳, 许刘晓, 等. 城市区域电动汽车充电设施配置优化[J]. 浙江大学学报(工学版), 2020, 54(6): 1210-1217.
- [7] 杨校辉, 张娟, 史志鸿, 等. 电动汽车充电桩认证结算单元的设计与实现[J]. 电力系统保护与控制, 2018, 46(11): 118-123.
- [8] 南斌, 徐成司, 董树锋, 等. 考虑多充电模式的充电桩优化控制策略[J]. 电力工程技术, 2021, 40(5): 2-9.
- [9] 杨小刚, 王慧华. 基于负载的新能源汽车充电桩控制系统设计[J]. 现代电子技术, 2020, 43(24): 131-134.
- [10] 刘晓天, 傅军, 赵思翔, 等. 基于二层规划并计及负荷预测的电动汽车充电桩选址定容方法[J]. 电测与仪表, 2021, 58(5): 144-150.
- [11] 赵翔, 陈良亮, 李明贞, 等. 一种基于深度神经网络的直流充电桩故障诊断方法[J]. 电测与仪表, 2021, 58(6): 148-152.
- [12] 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.
- [13] 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/OL]. 电测与仪表: 1-9 [2022-01-05].
- [14] 马晨佩, 李明辉, 巩强令, 等. 基于麻雀搜索算法优化支持向量机的滚动轴承故障诊断[J]. 科学技术与工程, 2021, 21(10): 4025-4029.
- [15] 吕鑫, 慕晓冬, 张钧, 等. 混沌麻雀搜索优化算法[J]. 北京航空航天大学学报, 2021, 47(8): 1712-1720.
- [16] 奉国和. SVM 分类核函数及参数选择比较[J]. 计算机工程与应用, 2011, 47(3): 123-124, 128.
- [17] FENGHUA W E N, JIHONG X, ZHIFANG H E, et al. Stock price prediction based on SSA and SVM[J]. Procedia Computer Science, 2014, 31: 625-631.
- [18] 程美英, 倪志伟, 朱旭辉. 萤火虫优化算法理论研究综述[J]. 计算机科学, 2015, 42(4): 19-24.
- [19] BARMAN M, CHOUDHURY N B D. Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept[J]. Energy, 2019, 174: 886-896.
- [20] 汤安迪, 韩统, 徐登武, 等. 基于混沌麻雀搜索算法的无人机航迹规划方法[J]. 计算机应用, 2021, 41(7): 2128-2136.

作者简介

张梅,硕士,副教授,主要研究方向为物联网应用、智能检测与故障诊断。

E-mail: xwz098@163.com

高犁(通信作者),硕士研究生,主要研究方向为电力预测技术。

E-mail: yunfeng47745@163.com