

DOI:10.19651/j.cnki.emt.2312551

基于 ISSA-SVM 的充电桩故障诊断*

何柳 张梅

(安徽理工大学 淮南 232001)

摘要: 针对充电桩故障诊断精度较低的问题,文中首先提出先利用多维尺度分析法处理样本数据,将原始数据映射到更低维的空间,减小模型计算代价;其次在麻雀搜索算法里融入了 Sin 混沌映射和动态自适应权重,提高它的全局搜索能力和寻优精度,然后再利用改进的麻雀搜索算法对支持向量机模型进行参数寻优,同时建立最优诊断模型;最后用所得模型进行充电桩故障诊断,输出诊断结果。最终的实验结果表明:文中提出的充电桩故障诊断模型的诊断准确率高达 95.135 1%,明显高于现有的一些常用模型。同时,文中所选用的支持向量机模型较其他分类模型效果更好,效率更高。

关键词: 充电桩;故障诊断;多维尺度分析法;支持向量机模型;麻雀算法

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

Fault diagnosis of charging pile based on ISSA-SVM

He Liu Zhang Mei

(Anhui University of Science and Technology, Huainan 232001, China)

Abstract: Aiming at the problem of low fault diagnosis accuracy of charging piles, this paper first proposes to use multi-dimensional scale analysis method to process sample data, map the original data to a lower dimensional space, and reduce the cost of model calculation. Secondly, Sin chaos mapping and dynamic adaptive weighting are integrated into the sparrow algorithm to improve its global search ability and optimization accuracy, and then the improved sparrow algorithm is used to optimize the parameters of the support vector machine model, and the optimal diagnosis model is established. Finally, the obtained model is used to diagnose the fault diagnosis of the charging pile and output the diagnosis results. The final experimental results show that the diagnostic accuracy of the fault-diagnosis model of the charging pile proposed in this paper is as high as 95.135 1%, which is significantly higher than that of some existing commonly used models. At the same time, the support vector machine model selected in this paper has better effect and higher efficiency than other classification models.

Keywords: charge pile; fault diagnosis; multidimensional scaling analysis; support vector machine model; sparrow algorithm

0 引言

在全球能源耗竭危机和温室效应严重的背景下,如何有效地减少化石能源消耗是每个国家都必须关注的问题。新能源的发展为我国节能和低碳绿色提供了一种可行方案,相对于传统燃油汽车,新能源充电汽车具有先天的优势,可以减低对传统能源依赖和环境成本,因此与之息息相关的充电设施的建设是至关重要的。

新能源汽车行业具有广阔的发展前景,针对充电桩故障诊断的研究也应运而生,国内外的科研人员将一些常用

的智能算法应用到充电桩故障诊断方面,充电桩故障诊断效率得到提高。一些常用的智能算法包括卷积神经网络、循环神经网络、长短时记忆网络和支持向量机等,每个算法都有各自的优缺点。Yang 等^[1]提出一种基于卷积神经网络的故障分类模型,但卷积神经网络(convolutional neural networks, CNN)参数量大容易引起过拟合。Zang 等^[2]利用鲸鱼优化算法初始化循环神经网络(recurrent neural network, RNN)网络参数,构成改进模型,但 RNN 随着网络层数的增加,会容易出现梯度消失的情况^[2]。郑鑫等^[3]通过 Logistic 混沌映射初始化、柯西高斯变异策略改进的

收稿日期:2023-01-04

* 基金项目:国家自然科学基金(51874010)、安徽高校自然科学基金项目(KJ2020A0309)资助

麻雀搜索算法,进一步丰富了种群复杂性,但寻优过程中很容易进入局部最优估计的问题;张梅等^[4]首先针对充电桩的运行参数进行预处理,之后引入萤火虫算法改进麻雀算法对支持向量机(support vector machine, SVM)进行参数寻优,但运行速度较慢和精确度低;吴丹等^[5]提出搭建一种卷积神经网络和长短时记忆网络(long short-term memory, LSTM)的混合网络结构,对数据进行比较训练,但充电桩参数数据资源有限导致无法提供稳定的评价;

支持向量机模型是一种分类工具,具有计算简单,自适应强的优点,但惩罚参数 c 和核函数参数 g 的选择与模型的分类效果密切相关,因此需要利用优化算法进行参数寻优^[6]。

麻雀搜索算法(sparrow search algorithm, SSA)被广泛地应用在参数寻优中,该搜索算法在初始化阶段采用的方式为随机生成,该方式会使种群分布不均,将会影响后续的迭代寻优^[7-8]。改进的麻雀搜索算法(improve sparrow search algorithm, ISSA)在原本 SSA 算法基础上增加 SIN 混沌映射和动态自适应权重。优化后的 ISSA 算法则是利用 SIN 混沌映射对 SSA 算法进行种群初始化的操作,动态自适应权重对麻雀个体的位置进行优化陷入局部最优,提高全局搜索能力和寻优精度。

文中提出了一种基于 ISSA-SVM 的充电桩故障诊断模型,首先利用多维尺度分析将原始数据映射到更低维的空间,再进行归一化处理,使其具有相同的度量尺度;然后利用改进的麻雀搜索算法对训练数据进行参数寻优,找到最优的 c 和 g , 构建出最优模型;最后使用该模型进行充电桩故障诊断,输出诊断结果。

1 算法描述

1.1 支持向量机模型

SVM 模型的核心思想是最大化超平面的间隔,因此建立相应的目标函数与约束条件^[9]。

假设有 m 个样本训练集 $\{x_i, y_i\}$, x_i 和 y_i 分别为样本和输出类型,设最优超平面表达式如下所示:

$$w\varphi(x) + b = 0 \quad (1)$$

表达式中 w 为权值系数, b 为偏值系数。

要求超平面的限制条件为:

$$y_i(w\varphi(x) + b) \geq 1 \quad y_i \in [-1, 1] \quad (2)$$

超平面的目标函数和约束条件为:

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \epsilon_i \\ s. t. y_i(w\varphi(x) + b) \geq 1 - \epsilon_i \end{cases} \quad (3)$$

式中: C 为惩罚因子; ϵ_i 和 ϵ 为松弛变量。

为约束最优化问题的解,引入 Lagrange 函数,使超平面的目标函数转化成对偶问题, α 为拉格朗日乘子,表达式如下:

$$\begin{cases} \max \left\{ \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \varphi(x_i) \varphi(y_j) \right\} \\ s. t. 0 \leq \alpha_i \leq C \sum_{i=1}^l y_i \alpha_i = 0 \end{cases} \quad (4)$$

最优超平面函数为:

$$f(x) = \text{sgn} \left[\sum_{i=1}^l \alpha_i y_i K(x_i, x) + b \right] \quad (5)$$

式中: $K(x_i, x_j)$ 为核函数。

文中中选径向基核函数 RBF, 即:

$$K(x_i, y_i) = \exp\left(-\frac{\|x_i - y_i\|^2}{\partial^2}\right) \quad (6)$$

式中: ∂ 为径向基函数参数。

1.2 SSA 算法

麻雀搜索算法的种群中有 3 种角色,分别为发现者、加入者和警戒者,它具有寻优能力强和收敛速度快的优点^[10-11]。

发现者的职责是为所有的加入者提供食物的范围和方向;加入者的职责是利用发现者来捕获它们的食物;警戒者是当群体中有麻雀发现周围有捕食者时,它们会发出警戒信号,整个种群就会立即躲避危险,进而飞到其他的安全区域进行觅食。

设种群中有 n 只麻雀,则由所有麻雀个体组成的种群可表示为 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$, 所有麻雀个体各自所对应的适应度函数可表示为 $\mathbf{F} = [f(x_1), f(x_2), \dots, f(x_n)]^T$ 。

发现者的位置更新如下:

$$x_{i,j}^{t+1} = \begin{cases} x_{i,j}^t \exp\left(\frac{-i}{\alpha \times i_{\max}}\right), & R_2 < ST \\ x_{i,j}^t + Q \cdot L, & R_2 \geq ST \end{cases} \quad (7)$$

其中, t 为迭代数, $\alpha \in (0, 1)$, i_{\max} 为最大迭代数, R_2 为报警值, ST 为安全值, j 的范围是 $\{1, 2, \dots, d\}$, d 为维度, L 是一个 $1 \times d$ 的矩阵,并且里面的元素全为 1, Q 为随机数^[12]。

跟随者的位置更新方式如下:

$$\mathbf{A}^+ = \mathbf{A}^T (\mathbf{A} \mathbf{A}^T)^{-1}$$

$$x_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst}}^t - x_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ x_{i,j}^{t+1} + |x_{i,j}^t - x_{i,j}^{t+1}| \cdot \mathbf{A}^+ \cdot L, & i \leq \frac{n}{2} \end{cases} \quad (8)$$

其中, x_{worst}^t 表示第 t 代适应度最差的个体位置, $x_{i,j}^{t+1}$ 表示第 $t+1$ 代中适应度最佳的个体位置, \mathbf{A} 表示一个 $1 \times d$ 的矩阵^[13]。

戒者位置更新方式如下:

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

其中, x_{best}^t 为第 t 代中最优位置, β 为步长值, 正态分布服从 $[0, 1]$, $k \in [-1, 1]$, ϵ 为常数, f_i 为当前麻雀的适应

度值, K 表示麻雀移动的方向, f_w 为最差适应度值, f_g 为最佳适应度值。

1.3 SSA 算法

1) Sin 混沌映射

Sin 混沌映射是一种映射折叠次数无限的模型, 为了避免陷入局部最优, 提高全局搜索能力和寻优精度, 文中采用 Sin 混沌映射对 SSA 算法进行种群初始化^[14]。

$$\begin{cases} X_{n+1} = \sin(2/X_n) & n = 0, 1, \dots, N \\ -1 \leq X_n \leq 1 & X_n \neq 0 \end{cases} \quad (10)$$

2) 动态自适应权重

文中引入动态权重因子 ω , 要做好全局搜寻和局部搜寻的平衡, 同时提高收敛速度。权重系数的计算公式如下:

$$\omega = \tanh(2(1 - t/i_{\max})) \quad (11)$$

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + \omega(Y_{j,g}^t - X_{i,j}^t) \cdot \text{rand} & R_2 < ST \\ X_{i,j}^t + Q & R_2 \geq ST \end{cases} \quad (12)$$

式中: $Y_{j,g}^t$ 为上一代中第 j 维的全局最优解。

融合 Sin 混沌和动态自适应权重的改进麻雀算法流程如下:

- 1) 利用 Sin 混沌映射初始化种群, 初始化发现者和加入者^[15]。
- 2) 计算各只麻雀的适应度值, 并排序。
- 3) 麻雀更新发现者位置。
- 4) 麻雀更新加入者位置。
- 5) 随机选择警戒者, 更新警戒者位置。
- 6) 计算适应度值并更新麻雀位置。
- 7) 设置循环结束条件, 满足条件则结束循环, 输出最优麻雀, 不满足则重复执行步骤 2)~6)。

2 充电桩故障诊断模型

本文利用 ISSA 算法优化 SVM 模型, 为实现更高精度的充电桩故障诊断, 文中构建了基于 ISSA-SVM 充电桩故障诊断模型, 如图 1 所示。

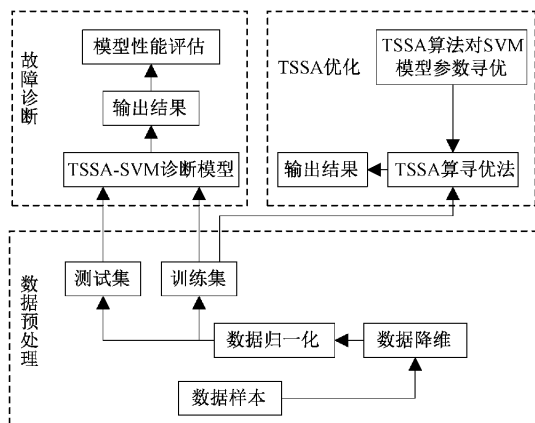


图 1 基于 ISSA-SVM 的充电桩故障诊断模型

图 1 所示的充电桩故障诊断模型主要由数据预处理、ISSA 参数寻优和故障诊断构成。数据预处理首先利用多维尺度分析将原始数据映射到更低维的空间, 再进行归一化处理, 使其具有相同的度量尺度; 并将其进行序列划分; 优化部分是利用 ISSA 算法对 SVM 模型的参数 c 和 g 进行寻优, 得到最优参数; 故障诊断部分是利用构建出的最优模型对测试数据进行故障诊断, 且文中准备多组对比实验来论证所提方法的优越性。

3 实验与结果分析

3.1 数据描述

文中利用 2019 年百度新手赛充电桩故障检测的数据集进行实验。每组数据包含六个特征参量, 这里选取部分数据进行实验, 如图 2 所示。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。有故障标签为 1, 无故障标签为 0。

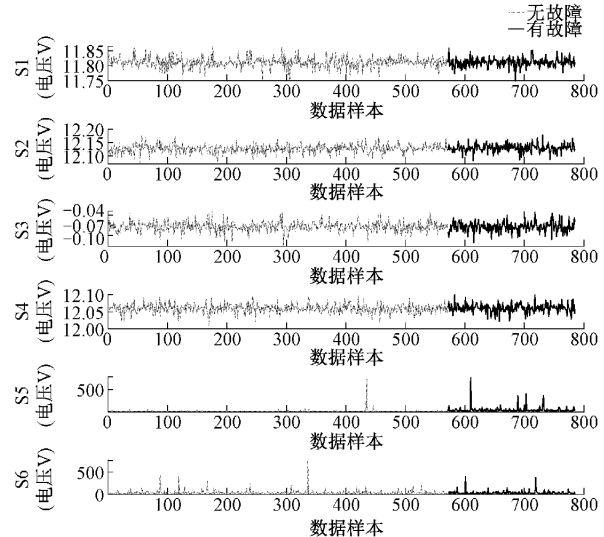


图 2 部分数据样本图

若使用原始数据集里所有特征数据进行故障分类, 工作数据量大, 势必会影响模型的运行速度, 且分类精度低, 检测效果不理想。因此在模型训练前, 需对原始样本进行预处理操作。

3.2 数据降维

由于充电桩的原始故障数据中存在的无效和冗余信息会影响模型收敛速度及实验效果。常用的降维算法有: 主成分分析 (principal component analysis, PCA)、核主成分分析 (kernel principal component analysis, KPCA) 和多维尺度分析 (multidimensional scaling, MDS)。

其中 MDS 算法可以有效处理在高维情况下出现的样本数稀疏和距离计算困难等问题, 它更加关注与高维数据内部的特征。所以文中采取 MDS 来进行数据降维, 从而提高模型的收敛速度及诊断精度。MDS 降维前后的效果

图如图所示。

经典 MDS 算法流程如下:

- 1) 计算原始空间中数据点的距离矩阵
- 2) 计算内积矩阵 B
- 3) 对 B 进行特征值分解, 获取特征值 Δ 和特征向量 V
- 4) 取特征值较大的前 Z 项及其对应的特征向量:

$$Z = V_Z \Delta_Z^{\frac{1}{2}} \quad (13)$$

文中利用 MDS 降维算法将特征数据降至 3 维, 得到样本的特征数据降维结果, 如图 3 所示。

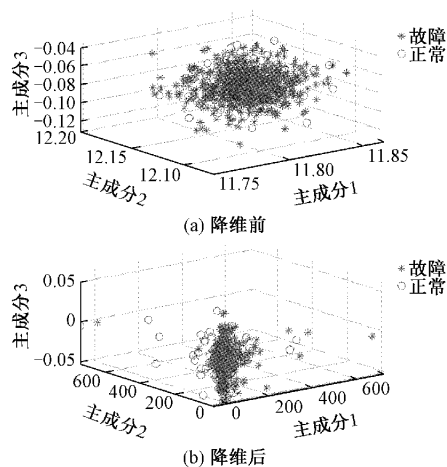


图 3 MDS 降维前后的效果图

3.3 数据归一化

文中采用区间值法进行数据归一化处理, 数据按一定比例缩放特定区间, 避免数值之间的相互影响, 表达式如下:

$$X_i = \frac{X - \min X}{\max X - \min X} \times [1 - (-1) + (-1)] \quad (14)$$

其中, X 、 X_i 是归一化处理前后的数据, $i = 1, 2, \dots, n$, $\max X$ 是数据样本中的最大值, $\min X$ 为数据样本中最小的值。有故障标签为 1, 正常运行标签为 0。如表 1 和 2 所示, 它是进行归一化前、后的部分数据。

表 1 归一化前的部分数据表

特征 1	特征 2	特征 3	故障类型
-23.628 5	-14.303 4	-0.001 5	1
-16.938 1	-4.121 5	-0.005 6	1
-1.129 6	-12.398 5	-0.003 4	1
22.814 3	-9.496 6	-0.012 1	0
-15.654 9	-10.180 1	0.002 2	0
4.009 8	1.633 9	0.025 6	0

3.4 基于 ISSA-SVM 的充电桩故障诊断结果

将所采用的 785 个样本数据按照 8:2 的比例拆分为训练集和测试集, 用训练集对 ISSA-SVM 模型进行训练, 然后将训练好的模型对测试集进行故障检测, 如图 4 所示, 得到的关于 ISSA-SVM 的充电桩故障结果。

表 2 归一化后的部分数据表

特征 1	特征 2	特征 3	故障类型
0.054 0	0.001 3	0.443 3	1
0.062 4	0.014 6	0.407 4	1
0.082 3	0.003 8	0.426 4	1
0.112 8	0.007 6	0.351 0	0
0.064 0	0.006 7	0.475 0	0
0.090 2	0.022 2	0.677 7	0

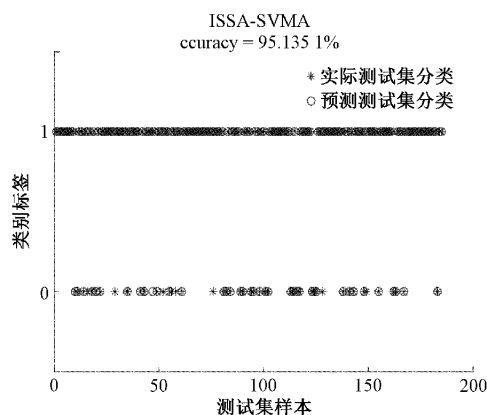


图 4 基于 ISSA-SVM 的充电桩故障诊断结果图

由图 4 可知, ISSA-SVM 模型的诊断准确率为 95.135 1%, 具有较好的充电桩故障分类效果, 诊断效果优良, 在充电桩故障诊断上具有一定的现实意义。

3.5 实验验证

为了验证本文所提出的基于 ISSA-SVM 的充电桩故障诊断模型的泛化能力, 现针对原数据集中的另 600 组故障数据, 按照 $x:y$ 划分为训练集与测试集, 经前文所述特征处理后, 输入 ISSA-SVM 分类模型中进行故障诊断, 诊断结果如图 5 所示。

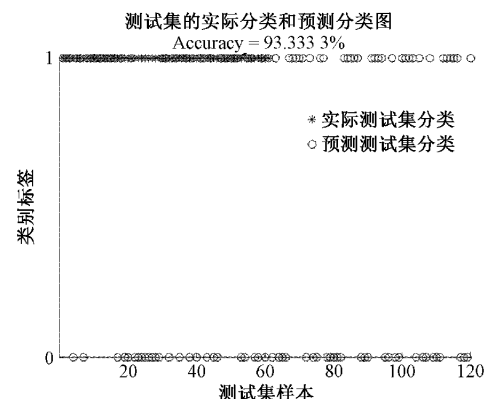


图 5 故障诊断结果图

由图 5 可知, 在不同的数据集上, 本文所提出的 ISSA-SVM 故障诊断模型也取得了较好的诊断结果, 其测试集准确率表现为 93.333%, 达到预期目的, 因此表明本文所建立的充电桩故障诊断模型具有良好的泛化能力。

3.6 模型评估

为了验证文中所提出的充电桩故障诊断模型与 MDS 降维方法的优越性,文中设计了如下实验:

实验一 验证 MDS 降维方法的优越性

采用 MDS 降维方法进行训练与测试,MDS 将原始数据映射到更低维的空间,对比结果,验证文中 MDS 特征提取方法的优越性。

实验二 验证 SVM 模型故障诊断优越性

分别采用充电桩故障诊断常用的分类模型:分别选取反向传播 (back propagation, BP)、极限学习机 (extreme learning machine, ELM)、神经网络 (radial basis function neural network, RBF) 和 SVM 四种主流分类器对数据进行诊断。对比实验结果,验证 SVM 模型在充电桩故障诊断上的优越性。

实验三 验证寻优 ISSA 算法优越性

针对 SVM 模型,分别采用灰狼算法 (grey wolf optimizer, GWO)、粒子群算法 (particle swarm optimization, PSO)、SSA 算法和 ISSA 算法进行优化,验证 ISSA 优化算法的优越性。

1) 不同降维算法对比

这里分别采用 PCA、MDS 和 KPCA 三种不同算法对数据进行降维,在采用 ISSA-SVM 模型的情况下,得到数据样本的降维结果,如图 6 所示。MDS 算法准确值高于 PCA 和 KPCA,MDS 算法在数据是 3 维时准确值达到了 0.951,且当维度大于 3 维后,准确值反而有所下降。在保证模型准确值的前提下,文中利用 MDS 算法将数据降维至 3 维。

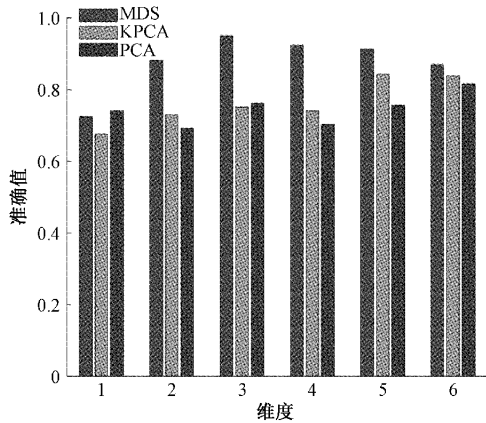


图 6 维度与准确值之间的关系图

由图 6 所知,MDS 的降维效果明显比 KPCA、PCA 好,所以文中采取的 MDS 算法来对数据进行降维处理。

2) 不同诊断模型的对比

采用 MDS 算法对数据进行预处理,并将归一化后的数据特征作为输入量利用分类模型进行分类。分别选取 BP、ELM、RBF 和 SVM 4 种主流分类器对数据进行诊断,各分类模型的诊断结果如图 7 所示。

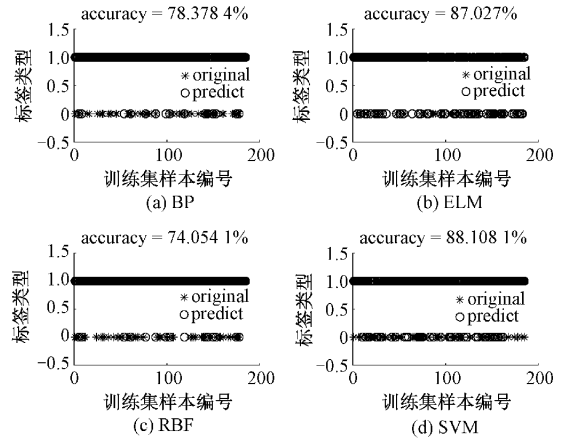


图 7 多模型诊断结果图

分析图 7 可以看出来 SVM 模型的准确率达到到了 88.1081%,SVM 模型的诊断效果最好和性能更好。故可以得到文中选用的 SVM 模型较其他模型具有更好的效果的结论。

3) 不同优化算法对 SVM 模型的影响

常用的寻优算法有 GWO、PSO 等,文中把 ISSA 算法和 SSA 算法、PSO 算法、GWO 优化算法进行比较。

为进一步比较 ISSA 寻优算法的性能,设置每个算法的种群数量为 50,迭代次数为 100。把数据样本的训练集以 5 折交叉验证的方式,即将数据样本随机分为 5 份,其中 4 份为训练样本,1 份为验证样本,将训练完的 SVM 模型对验证样本进行故障诊断,以验证样本的分类结果准确率为适应度函数,比较各优化算法的适应度函数收敛情况,做各适应度函数对比图,如图 8 所示。

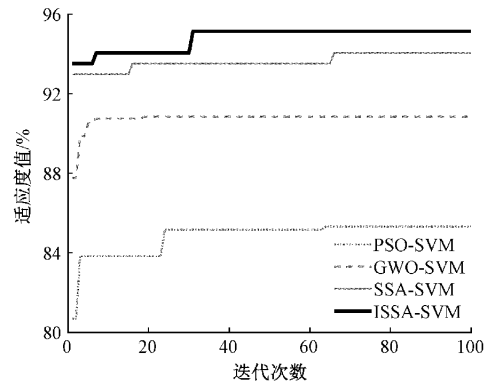


图 8 各寻优算法的适应度曲线图

据图 8 可知,ISSA 算法的适应度函数最高,寻优效果最好;与之对比的 PSO 算法的收敛速度最慢,且准确率最低,即搜索能力较弱。综上所述,ISSA 算法迭代收敛速度最快,容易较快地找到全局最优解,能够很好的克服早熟现象,有着更强的局部搜索能力和全局搜索能力。

4) 各算法寻优对比

由于 SVM 分类模型的超参数对模型影响显著,因此

利用ISSA算法优化SVM的惩罚因子 C 和核函数参数 g ,并将结果与SSA、GWO、PSO算法相比较,诊断对比结果如表3所示。

表3 各算法对比准确率表

分类模型	准确率/%
ISSA-SVM	95.135 1
SSA-SVM	94.054 1
GWO-SVM	90.810 8
PSO-SVM	84.868 9

综合以上表来看,文中使用的ISSA-SVM模型比SSA-SVM模型、GWO-SVM模型、PSO-SVM模型预测的准确率高,所以文中所使用的ISSA-SVM方法效果最佳。

4 结 论

为了提高充电桩故障诊断准确率,本文提出一种基于ISSA-SVM的故障诊断方法。

对比现有的ELM、BP、RBF和SVM模型,SVM分类模型准确率最高,其中准确率达到了88.1081%。

在优化SVM模型时,ISSA、SSA、GWO和PSO算法的准确率对比,ISSA算法效果最好,准确率到达95.1351%。

不同降维算法中,MDS的降维效果明显比KPCA、PCA好,实例结果表明,在采用ISSA-SVM模型的情况下,文中所使用的数据预处理方法比其他预处理方法的准确率都高。

综上所述,文中提出的充电桩故障诊断方法在准确率上有明显优势,具有一定的应用前景和市场。

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.
- [2] ZANG B B, GAO H, YANG X Y, et al. Fault diagnosis of charging facilities based on improved RNN[J]. Journal of Physics: Conference Series, 2022, 2301(1): 012008.
- [3] 郑鑫,石纯,田锦绣,等. 基于ISSA-SVM的煤矿变压器

器故障诊断方法[J]. 机电工程技术, 2022, 51(7): 31-34, 49.

- [4] 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.
- [5] 吴丹,甄昊涵,雷挺,等. 基于CNN和LSTM混合网络的电动汽车充电桩运行状态预测方法[J]. 电机与控制应用, 2022, 49(2): 83-89.
- [6] 李慧,徐海亮,王浩,等. 基于改进鲸鱼算法优化支持向量机的故障诊断的研究与应用[J]. 科学技术与工程, 2022, 22(13): 5284-5290.
- [7] 单亚峰,段金凤,付华,等. 基于SSA-AdaBoost-SVM的变压器故障诊断[J]. 控制工程, 2022, 29(2): 280-286.
- [8] 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.
- [9] 李黄曼,张勇,张瑶. 基于ISSA优化SVM的变压器故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(3): 123-129.
- [10] 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.
- [11] 张伟康,刘升,任春慧. 混合策略改进的麻雀搜索算法[J]. 计算机工程与应用, 2021, 57(24): 74-82.
- [12] 段玉先,刘昌云. 基于Sobol序列和纵横交叉策略的麻雀搜索算法[J]. 计算机应用, 2022, 42(1): 36-43.
- [13] 汪峰,周凤星,严保康. 基于特征量融合和支持向量机的滚动轴承故障诊断[J]. 科学技术与工程, 2022, 22(6): 2351-2356.
- [14] 毛清华,张强. 融合柯西变异和反向学习的改进麻雀算法[J]. 计算机科学与探索, 2021, 15(6): 1155-1164.
- [15] 李鹏,丁倩雯. 基于麻雀算法优化的OSTU分割算法[J]. 电子测量技术, 2021, 44(19): 148-154.

作者简介

何柳,硕士研究生,主要研究方向为智能故障诊断。

E-mail: 3024473073@qq.com

张梅(通信作者),硕士,副教授,主要研究方向为智能检测与故障诊断,图像处理研究。