

DOI:10.3969/j.issn.2097-0706.2023.03.001

基于 HHO-SVM 的电力线路故障检测分类系统

Power line fault detection and classification system based on HHO-SVM

魏伟¹,高赐威²,宋梦²,明昊²

WEI Wei¹,GAO Ciwei²,SONG Meng²,MING Hao²

(1.东南大学 软件学院,江苏 苏州 215123; 2.东南大学 电气学院,南京 210096)

(1. School of Software Engineering, Southeast University, Suzhou 215123, China; 2. School of Electrical Engineering, Southeast University, Nanjing 210096, China)

摘要:为实现电力线路故障的准确检测分类,设计并实现了基于人工智能的电力故障检测分类系统,核心模块以经典机器学习算法支持向量机(SVM)为基础模型,为提高模型的准确率,结合哈里斯鹰优化(HHO)算法进行参数寻优。试验结果表明,得到最优参数的SVM在2个公开数据集上均获得了高准确率。该系统不仅实现了电力线路故障检测分类的高精确度,还可实现电力线路故障数据集数据上传、分析和处理等功能,处理流程可视且简洁。

关键词:电力线路;故障;检测分类;人工智能;支持向量机;哈里斯鹰优化算法

中图分类号:TM 721

文献标志码:A

文章编号:2097-0706(2023)03-0001-08

Abstract: In order to accurately detect power line faults and make proper classification, a power fault detection and classification system based on artificial intelligence is designed and implemented. Its core module works based on the support vector machine (SVM), a classical machine learning algorithm. To improve the accuracy of the model, its parameters are optimized by Harris hawks optimization (HHO). And the experimental results show that the SVM with the optimal parameters offers high accuracy for two open data sets. The system not only realizes the accurate power line fault detection and fault classification, but also streamlines and visualizes the upload, analysis and processing functions for fault data sets.

Keywords: power line; fault; detection and classification; AI; support vector machine; Harris hawks optimization

0 引言

大容量发电厂和不同地理分布的电网需要在尽可能短的时间内进行故障检测,尤其是易受破坏和干扰电力线路上的故障,更应该被正确地检测和分类并在较短时间内清除,保障设备稳定运行。一种有效和可靠的识别方法应该在各种系统运行调节模式和不同的电网参数下表现得令人满意,而人工神经网络具有出色的归一化和泛化能力、抗噪声能力、鲁棒性和容错性,因此,基于人工智能的故障检测方法可以更好地适应电力系统参数变化带来的影响。

近年来,人工智能中的机器学习和深度学习以其在特征提取与模式识别方面的独特优势被广泛应用于众多领域。支持向量机(Support Vector Machine, SVM)是机器学习中最经典和应用最广泛

的算法之一,较好地实现了结构风险最小化。由于其可以解决小样本、非线性和高纬度信息的问题,已有不少研究将其应用到电力线路故障识别和分类中。文献[1]以电力线路的有功功率、无功功率、电流和电压作为故障判断依据,使用SVM针对不同的故障类型分别建立训练模型,通过测试样本的验证,基本实现了电力线路智能化诊断功能。文献[2]提出基于多源信息融合与SVM的电力线路故障根因辨识方法,利用实际故障样本分别建立了基于内部电气特征、外部环境特征和综合特征的辨识模型并进行分析对比,使得模型获得最优的故障根因辨识性能。在SVM模型的应用中,超参数的调优一直是提高模型准确率的关键步骤。群体优化算法是模拟生物界群体行为的智能算法,如本文使用的哈里斯鹰优化(Harris Hawks Optimization, HHO)算法,可作为一种新型有效的寻优方法应用于SVM的参数选择。

群体优化算法不仅可用于电气应用中的数学

基金项目:国家自然科学基金项目(52207081)

National Natural Science Foundation of China(52207081)

模型求解^[3-4]和传统模型参数寻优^[5],还可用于深度学习模型的参数寻优^[6]和机器学习模型参数寻优。HHO算法是2019年Heidar等提出的一种新型群体优化算法。近年来一些研究将HHO算法与SVM模型相结合,来解决工程上的问题。文献[7]采用HHO算法来优化选择支持向量回归(Support Vector Regression, SVR)模型的控制参数,进行年径流预报。文献[8]构建了多种基于HHO算法的水文预报模型。对于深度学习模型,文献[9]采用HHO算法对经典反向传播(Back Propagation, BP)神经网络的权值、阈值进行优化。将BP神经网络训练过程中的误差作为适应度函数,并利用鸢尾花数据构建BP神经网络的训练集及测试集。测试结果表明,HHO算法能够有效地优化权值及阈值并降低训练误差。文献[10]针对神经网络遇到的局部最优解问题和模糊聚类学习能力不足问题,基于相同的特征组合和在小样本量上具有良好分类能力的SVM模型,提出使用HHO-SVM进行变压器故障诊断及故障识别。对于其他机器学习模型,HHO算法也有相关的应用研究。文献[11]为了提高核极限学习机(Kernel Based Extreme Learning Machine, KELM)的分类正确率,采用HHO算法对惩罚系数、宽度参数进行优化。

1 基于HHO-SVM的电力故障检测分类系统整体设计

1.1 系统架构设计

系统整体按照前后端分离的模式开发,前后端系统分别部署在电力公司内网不同的服务器上,前端系统作为用户交互友好的界面接口负责渲染数据分析处理和训练的页面,后端系统提供具体的业务接口和数据存储功能。前后端大大降低了耦合性,也降低了未来系统升级或维护的成本。系统整体架构如图1所示。

电力故障检测分类人员获得数据后,在前端用户界面(User Interface, UI)进行可视化的分析、处理和训练。系统基于Vue脚手架搭建,使用Node包管理器(Node Package Manager, NPM)管理依赖包,并且最终作为独立的前端部署在Nginx服务器上。

前后端开发过程中通过在Vue服务器启动文件中配置代理服务器来解决前后端的跨域交互问题,而在部署到Nginx服务器上时通过配置服务器的配置文件利用其反向代理来实现跨域。

后端业务层基于Python的经典Web框架Django来搭建,是所有功能的具体逻辑实现。

数据存储层采用NoSQL数据库MongoDB,以键

值对的形式存储用户所使用的数据集,这种文档结构的存储方式可以使操作人员更便捷地获取数据。

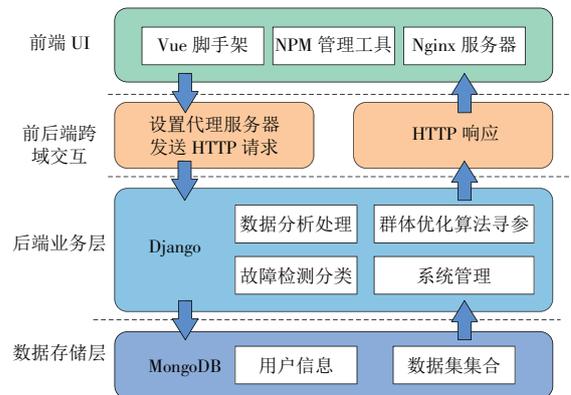


图1 基于HHO-SVM的电力故障检测分类系统整体架构
Fig. 1 Overall architecture of the power line fault detection and classification system based on HHO-SVM

1.2 系统功能设计

根据实际应用背景,基于机器学习人工智能和Web系统开发技术设计了集数据分析、数据处理、群体优化算法寻参、电力线路故障检测和分类功能于一体的电力故障检测分类系统,系统整体功能设计如图2所示。

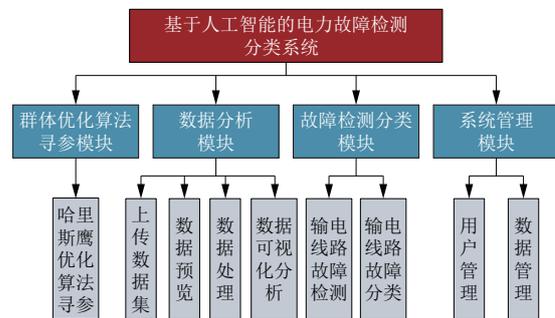


图2 系统功能设计

Fig. 2 Function design of the system

数据分析模块主要进行数据集的上传,搜集好的电力故障数据集可以.csv等格式添加到当前用户对的数据集集合。上传成功后用户可进行数据预览和归一化等一系列经典的机器学习数据预处理操作,并且可对数据集进行统计学上的可视化分析,生成几种不同的图表显示在网页上。

群体优化算法寻参模块使用HHO算法对所选模型进行参数寻优,可对不同的数据集和应用场景寻找模型的一组最优参数并保存迭代过程的适应度曲线。

系统中的故障检测分类模块分别对应2种泛化场景,即二分类问题和多分类问题,使用HHO算法对SVM超参数进行寻优之后,可对新输入的待分类样本进行准确分类并显示可视化的分类结果。

系统管理模块包括用户管理和数据管理,前者主要包括用户的系统权限管理和个人账户管理,后者是用户对应的数据管理。

2 基于群体优化的电力线路故障检测分类

由上一节系统功能介绍可以看出,群体优化算法寻参模块和故障检测分类模块为该系统的重点,本章对检测分类方法和群体优化寻参进行详细介绍。

2.1 基于SVM的电力线路故障检测方法

2.1.1 SVM应用可行性分析

SVM原理的核心是间隔、对偶和核技巧,本质是在特征空间上寻找超平面的最大间隔分类器,对于电力线路故障检测这种二分类问题有很强的适用性,可以根据寻找到的最优超平面将故障样本和正常样本分开并使间隔最大化,离超平面最近的样本点为支持向量,其工作原理如图3所示。

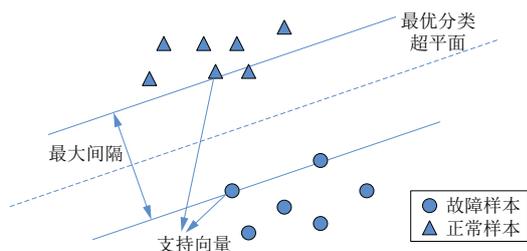


图3 SVM分类
Fig. 3 SVM classification

对于电力线路故障分类这种多分类问题,SVM有2种方法:一种是对每类样本训练可以检测该样本的二分类器,称为一对多策略;另一种是对每2类样本训练一个二分类器,称为一对一策略。使用Sklearn框架中的SVC类可以根据情况自动选择2种策略。

针对分类或回归模型,低维样本空间有时无法进行线性计算,所以与常见的降维简化计算方法不同,SVM通过上升到高维空间转化为线性问题进行处理。例如,二维空间无法线性化时可转化为三维空间的线性可分问题,如图4所示。

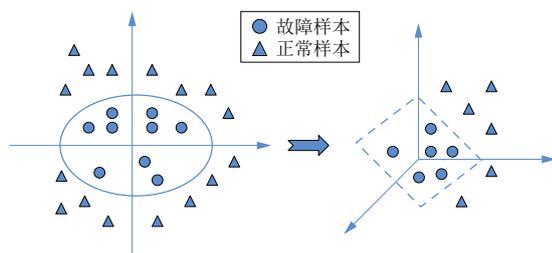


图4 升维分类
Fig. 4 Ascending dimension classification

对于非线性分类问题,使用不同核函数将特征映射到更高维的空间,基于对偶理论计算超平面,在高维上解决维度爆炸问题。径向基核函数(又称高斯核函数)具有较宽的收敛域,可以适用于任意分布的样本^[12],所以核函数选择是一个非常重要的步骤,本文试验所选择的核函数为径向基核函数(Radical Basis Kernel Function, RBF),其公式为

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left[-\frac{|\mathbf{x}_i - \mathbf{x}_j|^2}{\sigma^2}\right], \quad (1)$$

式中: σ 为径向基半径; \mathbf{x}_i 和 \mathbf{x}_j 为特征向量。

2.1.2 基于SVM的电力线路故障检测分类流程

对数据集进行分析并选择归一化方法,一般有最大值最小值归一化和标准归一化2种方法。对故障检测分类数据集的特征值使用标准归一化方法进行归一化,如式(2)所示。标准归一化处理后的数据符合均值为0,标准差为1的标准正态分布。由于标准差考虑到了所有样本数据,所以受离群值的影响较小。最大值最小值归一化方法如式(3)所示。该方法能将数据归一化为0~1,但当异常值特别大时最大值和最小值差距比较大,一旦数据中有一个离群值(特别大的值),做完归一化后就会出现这个离群值特别趋近于1,而其他值特别趋近于0的情况,所以一般不选择这种方法。

$$x' = \frac{x - \mu}{\delta}, \quad (2)$$

式中: x 为原样本数据; x' 为归一化处理后的数据; μ 为所有样本的均值; δ 为所有样本数据的标准差。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (3)$$

式中: x_{\max} 和 x_{\min} 分别为样本最大值和最小值。

数据预处理完成后随机划分80%为训练集,20%为测试集,最后使用Sklearn框架中的SVC类创建模型,参数不特意指定而是直接使用其默认值。

2.2 基于HHO的SVM参数寻优方法

HHO算法的主要灵感来源于哈里斯鹰的鹰群在自然界中的合作行为和突袭的追猎风格^[13]。在这种智能策略中,几只鹰从不同的方向合作突袭猎物,并且可以根据场景的动态模式和猎物的逃跑行为展开相应的追逐模式。通过在数学上模拟这种动态模式和行为,开发出一种优化算法并在一些基准问题和实际工程问题上测试,验证结果表明,与遗传算法(Genetic Algorithm, GA)、粒子群优化(Particle Swarm Optimization, PSO)算法等其他成熟的优化算法相比,HHO算法在探索能力和跳出局部最优解方面显示出更大潜力。

HHO算法的流程可以分为3个阶段。

(1)探索阶段。当兔子的逃逸能量绝对值大于1时,此时认为猎物体力充沛,哈里斯鹰群大范围飞行寻找猎物,针对发现和未发现猎物2种情况生成一个随机数 q ,根据 q 选择不同策略更新第 t 次迭代的位置 $X(t)$ 得到下一次迭代的位置 $X(t+1)$ ^[14]。

当 $q \geq 0.5$ 时,任何一只鹰都没有发现猎物位置,随机选择个体飞行来更新自身位置

$$X(t+1) = X_{rd}(t) - r_1 |X_{rd}(t) - 2r_2 X(t)|, \quad (4)$$

式中: $X_{rd}(t)$ 为第 t 次迭代中从当前种群随机选取的鹰的位置; r_1, r_2 为(0,1)中的随机数。

当 $q < 0.5$ 时,哈里斯鹰发现目标,在其附近盘旋并更新位置

$$(X_{rb}(t) - X_m(t)) - r_3 [L_b + r_4 (U_b - L_b)], \quad (5)$$

式中: $X_m(t)$ 和 $X_{rb}(t)$ 为第 t 次迭代的种群平均位置和猎物兔子的位置; r_3, r_4 为(0,1)中的随机数; L_b, U_b 分别为位置的下界和上界。

(2)从探索到开发的过渡阶段。根据猎物逃逸的能力,从探索转移到开发,并且选择不同的策略进行突袭。式(6)模拟了猎物逃跑过程中的能量降低。

$$E = 2E_0 \left(1 - \frac{t}{T}\right), \quad (6)$$

式中: E 为猎物逃逸能量; T 为最大迭代次数; E_0 为(-1,1)之间的随机数。

在迭代过程中,逃逸能量呈下降趋势,当 $|E| \geq 1$ 时,鹰群处于探索阶段,当 $|E| < 1$ 时,猎物能量较低,算法由探索阶段过渡到开发阶段,尝试利用解的邻域解决问题。

(3)开发阶段。面对前一阶段检测到的目标猎物,采用4种策略来突袭。假设 r 是猎物成功逃脱的概率。

1)当 $|E| \geq 0.5$ 和 $r \geq 0.5$ 时,在兔子仍有足够能量的情况下进行软围攻,位置更新为

$$X(t+1) = X_{rb}(t) - X(t) - E |JX_{rb}(t) - X(t)|, \quad (7)$$

式中: J 为(0,2)中的一个随机数,表示兔子在逃跑过程中的随机跳跃强度。

2)当 $|E| < 0.5$ 和 $r \geq 0.5$ 时,在猎物疲惫且逃逸能量低的情况下进行硬围攻,位置更新为

$$X(t+1) = X_{rb}(t) - E |X_{rb}(t) - X(t)|. \quad (8)$$

3)当 $|E| \geq 0.5$ 和 $r < 0.5$ 时,兔子有足够能量可以逃脱,此时进行渐进式俯冲软围攻

$$X(t+1) = \begin{cases} Y & F(Y) < F(X(t)) \\ Z & F(Z) < F(X(t)) \end{cases}, \quad (9)$$

式中: Y 和 Z 分别为根据式(10)和式(11)计算的临

时位置; F 为适应度函数。

$$Y = X_{rb}(t) - E |JX_{rb}(t) - X(t)|. \quad (10)$$

首先计算其适应度 $F(Y)$ 并与当前位置适应度 $F(X(t))$ 比较大小,效果更好则更新适应度,效果不好则基于Levy规则^[15]按式(11)进行更新。

$$Z = Y + SL(D), \quad (11)$$

式中: S 为 D 维随机向量; $L(x)$ 为Levy飞行函数。

按同样方法计算其适应度 $F(Z)$,与当前位置适应度比较并更新。

4)当 $|E| < 0.5$ 和 $r \geq 0.5$ 时,兔子没有足够的能量逃跑,突袭前会形成一个坚固的包围以捕捉并杀死猎物,即进行渐进式快速俯冲硬围攻,所以其计算公式与步骤3)的公式基本一致,只需把式(10)中的 $X(t)$ 改为式(5)中的 $X_m(t)$ 即可。

基于HHO-SVM的电力线路故障检测分类流程如图5所示。

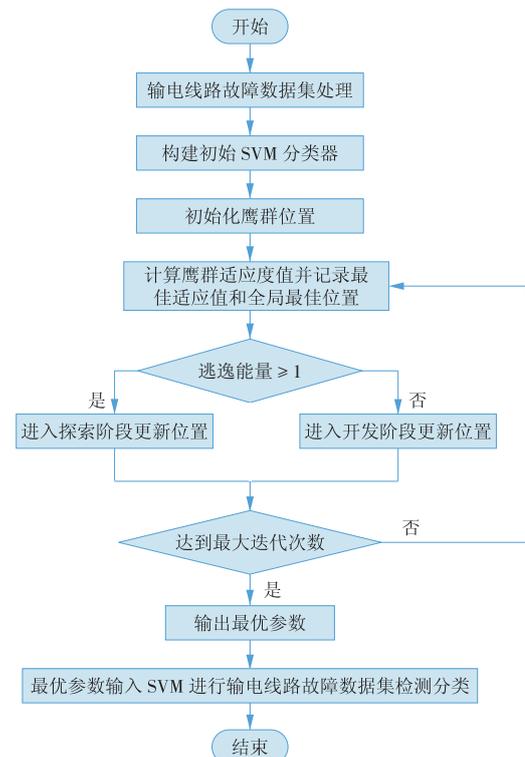


图5 基于HHO-SVM的电力线路故障检测分类流程
Fig. 5 Working process of the power line fault detection and classification system based on HHO-SVM

假设最优个体极值为 P_{best} ,最优全局极值为 G_{best} ,使用HHO对SVM的惩罚参数 c 和核函数参数 g 进行寻优,该过程可以简单分为以下3个步骤。

(1)设置位置上下界,对应2维可行解 $[c, g]$;在位置边界范围内进行种群的随机初始化,计算每个个体的适应值并存储在各自的 P_{best} 中;记录所有 P_{best} 中适应值最小的个体的位置,并将其适应值作为 G_{best} 。

(2)根据式(4)—(11)迭代更新个体的位置,当前迭代个体的适应值若比之前迭代计算的适应值更小则更新 P_{best} 和个体历史最佳位置。比较最小 P_{best} 和 G_{best} ,取较小的值为 G_{best} 。

(3)迭代达到最大迭代次数时便输出最优结果,包括 SVM 最优分类结果和其对应的 2 个参数。

3 案例应用和分析

用基于 Vue2.0 的桌面端组件库 Element-UI 搭建系统界面,图 6 为 2 个系统功能界面示例,分别展示了数据分析中的上传数据集界面、群体优化算法寻参中的 HHO 算法配置和运行界面。



a 上传数据集界面(截图)
a Data set upload interface (screenshot)



b HHO 算法配置及运行界面(截图)
b Configuration and operation interface of HHO (screenshot)

图 6 系统功能界面(截图)

Fig. 6 System functional interface (screenshot)

3.1 数据集分析

3.1.1 电力线路故障检测数据集

检测数据集含 12 001 条数据,每行包括三相电力系统的 3 个电流值 I_a, I_b, I_c 和 3 个电压值 V_a, V_b, V_c 共 6 个特征值和 1 个故障标签值(0 或 1)。其中正常样本有 6 505 条数据,标签为 0,故障样本有 5 496 条数据,标签为 1。

核密度曲线类似于概率密度曲线,其曲线下的面积是 1,实质是一种对直方图的抽象,可直观展示样本值的数值分布。电流核密度分布如图 7 所示。

由图 7 可以看出,0 两侧的数据占比最多,绝对值大的数据相对少且总体对称。电压 V_a, V_b, V_c 也是如此,其数据采用标么值的形式记录,如图 8 所示。由图 7、图 8 可见,2 种特征数据均呈正态分布,并且

最大值最小值之间差距较大,所以可以采用标准归一化的方法。

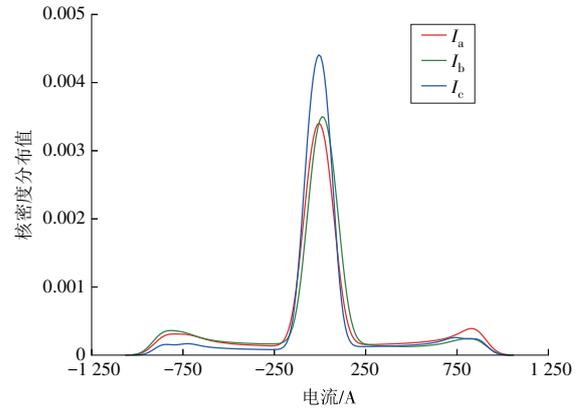


图 7 电流核密度分布

Fig. 7 Kernel density of the line current

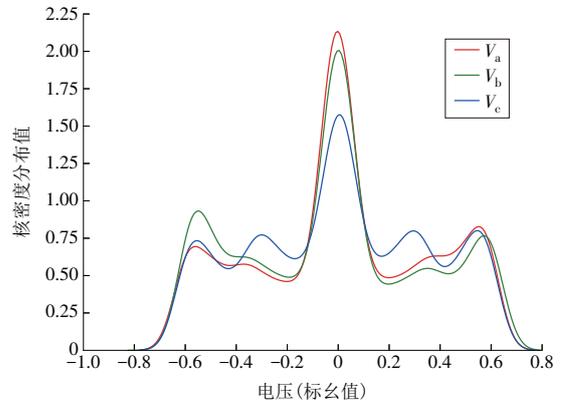


图 8 电压核密度分布

Fig. 8 Kernel density of the line voltage

样本的三相电流和电压的关系如图 9 所示。由图 9 可见,正常情况下(即标签为 0)电流值范围较窄,电压标么值范围为 -0.7~0.7。异常数据在电流特征上表现出很强的异常性和随机性,电压标么值范围为 -0.6~0.6。

3.1.2 电力线路故障分类数据集

分类数据集含 7 861 条数据,每行包括与检测数据集相同的 6 个特征值,还包括人为定义的 G, C, B, A 共 4 个值为 0 或 1 的故障标签值,其分类和数量见表 1。

为了方便训练模型,将 G, C, B, A 对应的 4 列换成 1 列,用 0~5 来代替 6 类数据的标签。

3.2 电力线路故障检测分类结果

3.2.1 传统 SVM 方法

故障检测最终准确率为 97.80%,如图 10 所示,故障分类最终准确率为 81.24%,如图 11 所示。由图 10 可以看到,使用默认参数的 SVC 在二分类的故障检测数据集上表现良好,只在预测标签为 0 的样本时会有少许误差。由图 11 可以看出,在多分类的故障分类数据集上准确率远远不如前者,每类标签

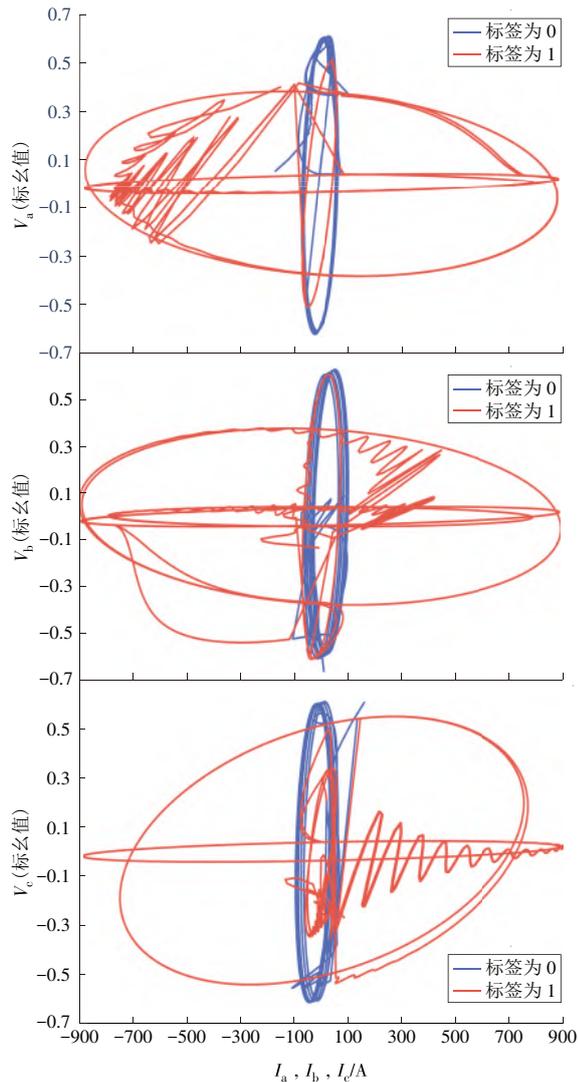


图9 三相电流和电压的关系

Fig. 9 Relationship between three-phase current and voltage

表 1 故障标签分类和数量

Table 1 Fault label, classification and quantity

G C B A	故障类型	样本数	说明
0 0 0 0	No fault	2 365	无故障
1 0 0 1	LG fault	1 129	A 相和接地之间故障
0 1 1 0	LL fault	1 004	C 相和 B 相之间故障
1 0 1 1	LLG fault	1 134	A 相、B 相和接地之间故障
0 1 1 1	LLL fault	1 096	所有三相之间故障
1 1 1 1	LLLG fault	1 133	三相之间对称故障

都有误差,尤其是标签为 4 和 5 的时候,因此需要对 SVM 进行参数寻优,从整体上改善模型的预测准确度。

3.2.2 HHO-SVM 方法

故障检测试验获得的超参数 $c=1\ 000, g=100$, 对应的 SVM 分类混淆矩阵如图 12 所示。由图 12 可以看到,只有 3 个样本分类错误,相较于之前 72 个样本分类错误,准确率有了明显的提升。

故障分类试验获得的超参数 $c=1\ 000, g=$

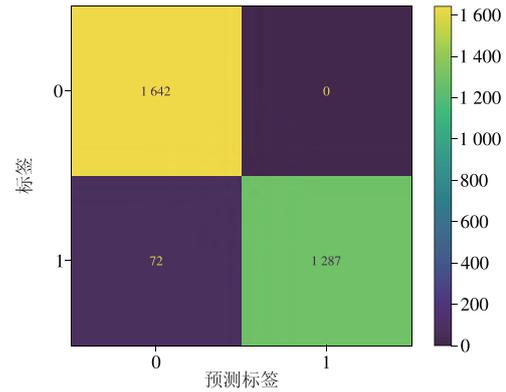


图 10 故障检测混淆矩阵

Fig. 10 Fault detection confusion matrix

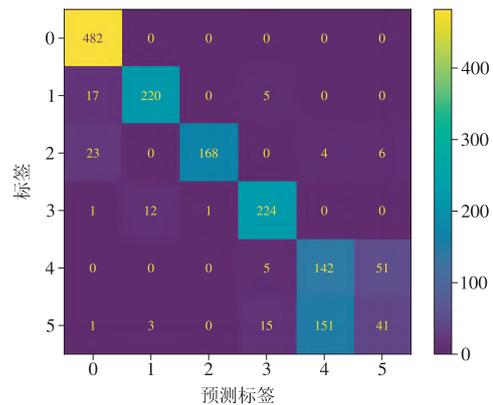


图 11 故障分类混淆矩阵

Fig. 11 Fault classification confusion matrix

13.662 602 82, 试验的参数寻优对准确率提升效果显著,由原来的 81.24% 提升到 99.00% 以上,至少提升了 18 个百分点, SVM 分类混淆矩阵如图 13 所示。

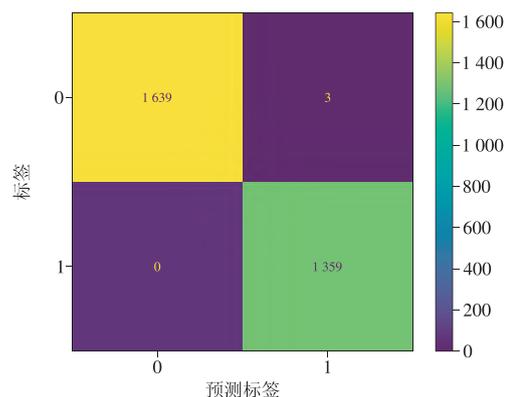


图 12 HHO 优化后的故障检测混淆矩阵

Fig. 12 HHO-optimized fault detection confusion matrix

3.3 改进方法试验结果对比分析

使用 HHO 方法过程中对应的电力故障检测和分类试验的适应度曲线如图 14 所示。由图 14 可以看到,电力故障分类数据试验准确率相对电力故障检测准确率要低,即分类任务难度大些,而组合算法对电力故障检测和分类的效果都有所提升。

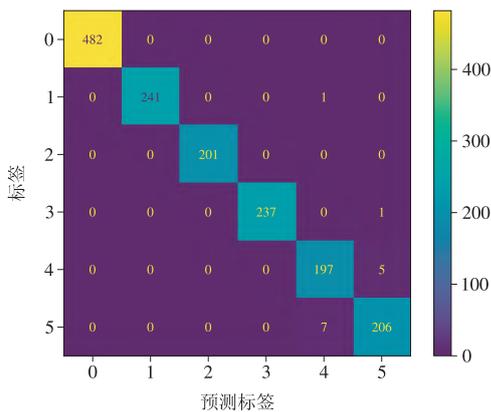


图 13 HHO 优化后的故障分类混淆矩阵

Fig. 13 HHO-optimized fault classification confusion matrix

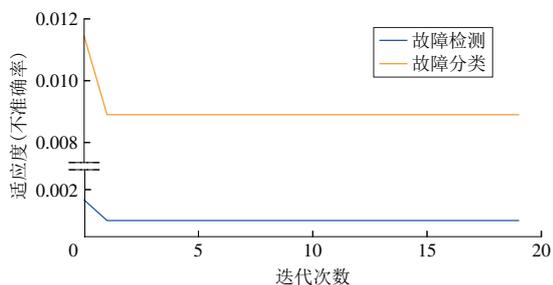


图 14 故障检测和分类试验的适应度曲线

Fig. 14 Fitness curve of the fault detection and classification experiment

4 结束语

本文针对使用 SVM 进行检测分类难以确定电力线路故障的问题,结合 HHO 群体优化算法,对 SVM 的 2 个关键参数——惩罚因子和核函数参数进行寻优,在此基础上设计并实现了一个通用的电力故障检测分类系统。实际应用案例表明,组合算法有效提高了 SVM 在 2 种数据集下的准确率,均达到 99% 以上。

基于人工智能的电力故障检测分类系统实现了电力故障检测分类的智能化和可视化,简化了电力故障数据集处理和检测分类的流程。但目前系统的应用场景和可支持的模型还较少,后续可添加新的电力故障数据集以及决策树等更多样的模型,群体优化算法也可以添加其他经典的基础算法和改进算法。

参考文献:

[1] 齐金定,孙涛,单岩,等.基于支持向量机算法的输电线路故障诊断研究[J].计算机与网络,2019,45(23):68-71.
 QI Jinding, SUN Tao, SHAN Yan, et al. Research on transmission line fault diagnosis based on support vector machine algorithm [J]. Computer and Network, 2019, 45

(23): 68-71.
 [2] 黄景林.多源信息融合的输电线路故障辨识研究[D].广州:广东工业大学,2021.
 HUANG Jinglin. Research on transmission line fault identification based on multi-source information fusion [D]. Guangzhou: Guangdong University of Technology, 2021.
 [3] 颜庆国,杨斌,许高杰,等.基于自适应粒子群算法的楼宇智能用电策略[J].电力需求侧管理,2016,18(4):1-5.
 YAN Qingguo, YANG Bin, XU Gaojie, et al. A strategy for intelligent power utilization in building based on adaptive PSO [J]. Power Demand Side Management, 2016, 18(4): 1-5.
 [4] 孟安波,王鹏,丁伟锋,等.基于强化学习及纵横交叉粒子群算法的电网最优潮流计算[J].华电技术,2021,43(8):74-82.
 MENG Anbo, WANG Peng, DING Weifeng, et al. Optimal power flow calculation of power grid based on reinforcement learning and crisscross PSO algorithm particle swarm optimization [J]. Huadian Technology, 2021, 43(8): 74-82.
 [5] 杨首晖,陈传彬,王雪晶,等.基于小波变换和季节性 Holt-Winters 模型的短期负荷预测方法[J].电力需求侧管理,2021,23(5):70-75.
 YANG Shouhui, CHEN Chuanbin, WANG Xuejing, et al. A short-term load prediction method based on the wavelet transform and seasonal Holt-Winters model [J]. Power Demand Side Management, 2021, 23(5): 70-75.
 [6] 钱荣荣,谭涛.基于改进卷积深度信念网络的风电机组行星齿轮箱故障诊断方法[J].电力需求侧管理,2022,24(2):27-33.
 QIAN Rongrong, TAN Tao. Fault diagnosis method of planetary gearbox based on improved convolutional deep belief network [J]. Power Demand Side Management, 2022, 24(2): 27-33.
 [7] 韩晓育,郭颖奎.耦合 LASSO 回归的 HHO-LSVR 中长期径流预报模型[J].水文,2021,41(3):69-74.
 HAN Xiaoyu, GUO Yingkui. HHO-LSVR medium and long-term runoff forecasting model coupled with LASSO regression [J]. Hydrology, 2021, 41(3): 69-74.
 [8] 张洁铭. HHO 算法在东湾流域水文预报中的应用[D].郑州:华北水利水电大学,2021.
 ZHANG Jieming. Application of HHO algorithm in hydrological prediction of Dongwan Basin [D]. Zhengzhou: North China University of Water Resources and Electric Power, 2021.
 [9] 吴丁杰,温立书.一种基于哈里斯鹰算法改进的 BP 神经网络[J].网络安全技术与应用,2022(1):38-40.
 WU Dingjie, WEN Lishu. An improved BP neural network based on Harris hawks algorithm [J]. Network Security Technology and Application, 2022(1): 38-40.
 [10] 朱楚昱,李川,李英娜.基于特征优选和 HHO-SVM 的变

压器故障识别[J].电视技术,2021,45(2):60-66.

ZHU Chuyu, LI Chuan, LI Yingna. Transformer fault recognition based on feature selection and HHO-SVM [J]. Television Technology, 2021, 45(2): 60-66.

[11]吴丁杰,温立书.一种基于哈里斯鹰算法优化的核极限学习机[J].长江信息通信,2021,34(11):45-46.

WU Dingjie, WEN Lishu. A kernel extreme learning machine based on Harris hawk algorithm optimization [J]. Changjiang Information Communication, 2021, 34 (11) : 45-46.

[12]周绍磊,廖剑,史贤俊.RBF-SVM的核参数选择方法及其在故障诊断中的应用[J].电子测量与仪器学报,2014,28(3):240-246.

ZHOU Shaolei, LIAO Jian, SHI Xianjun. Kernel parameter selection of RBF-SVM and its application in fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2014, 28(3) :240-246.

[13]HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris hawks optimization: Algorithm and applications [J]. Future Generation Computer Systems, 2019, 97: 849-872.

[14]刘骏鹏.哈里斯鹰算法的改进及应用研究[D].杭州:浙江

江大学,2021.

LIU Junpeng. Research on improved Harris hawks optimization and its applications [D]. Hangzhou: Zhejiang University, 2021.

[15]YANG X S. Nature-inspired metaheuristic algorithms [M]. United Kingdom: Luniver Press, 2010.

(本文责编:刘芳)

收稿日期:2022-09-26;修回日期:2022-12-12
上网日期:2023-03-25;附录网址:www.iienergy.cn

作者简介:

魏伟(1998),男,在读硕士研究生,从事电力市场、虚拟电厂、机器学习、联邦学习等方面的研究,1346535304@qq.com;

高赐威(1977),男,教授,博士生导师,博士,从事电力市场、需求响应等方面的研究,ciwei.gao@seu.edu.cn;

宋梦(1989),女,副研究员,博士,从事需求响应、虚拟电厂、可交易能源等方面的研究,songmengseu@163.com;

明昊(1990),男,副研究员,硕士生导师,博士,从事电力市场、需求响应、大数据学习等方面的研究,haoming@seu.edu.cn.

征 订 启 事

《综合智慧能源》立足电力能源领域,刊载综合能源系统和智慧能源技术等能源科技前沿信息,传播综合智慧能源领域新技术、新产品、新工艺,服务国家能源安全战略。本刊为月刊,大 16 开本,全年 12 期,每册国内定价 24 元,国外定价 10 美元。为便于读者订阅,已开通线上、线下、电脑端、移动端等多渠道订阅,现明确以下订阅途径,欢迎广大读者订阅。

一、线下订阅

请至中国邮政各营业网点线下咨询订阅,邮发代号:36-254。

二、移动端手机订阅

(1)微信关注“中国邮政微邮局”公众号,点击“微商城”,搜索栏输入“综合智慧能源”,搜索到《综合智慧能源》,即可进行官微订阅。

(2)微信搜索“中国邮政商城”小程序,搜索栏输入“综合智慧能源”,搜索到《综合智慧能源》,即可进行小程序订阅。

三、电脑端在线订阅

登录中国邮政报刊在线订阅网址: BK.11185.CN,搜索栏输入“综合智慧能源”,搜索到《综合智慧能源》,即可进行电脑端在线订阅。

四、电话订阅

通过中国邮政 11185 电话订阅。

五、国外订阅

请联系中国国际图书贸易集团有限公司(北京 399 信箱)订阅,海外发行代号:MO1842。

六、编辑部直接订阅

本刊除邮政发行外自办发行,读者可联系编辑部直接订阅。

联系电话:0371-58501042。联系人:齐老师。

更多订阅方式,请至官网(www.hdpower.net 或 www.iienergy.cn)“期刊订阅”菜单下查询。