

# 改进支持向量机在电力变压器故障诊断中的应用研究

邱海枫<sup>1</sup>, 苏宁<sup>1</sup>, 田松林<sup>2</sup>

(1. 深圳供电局有限公司, 广东 深圳 518048;

2. 南方电网深圳数字电网研究院有限公司, 广东 深圳 518034)

**摘要:** 针对电力变压器故障诊断中状态量判断指标过于绝对、智能算法准确率受参数影响等问题, 在分析电力变压器故障的基础上, 提出将支持向量机(Support Vector Machine, SVM)和细菌觅食算法(Bacterial Foraging Algorithm, BFA)相结合用于电力变压器的故障诊断方法。通过细菌觅食算法的寻优能力找到最优的支持向量机惩罚因子和核参数, 提高了故障诊断能力。通过仿真和实例进行对比分析, 验证了该方法的优越性。结果表明, 相比于粒子群优化, 细菌觅食算法具有更好的寻优能力。基于 BFA-SVM 的故障诊断模型, 相比于改进前, 具有更高的准确性、鲁棒性和寻优能力, 故障诊断准确率相比于粒子群优化提高了 7.50%, 具有一定的实用价值。

**关键词:** 电力变压器; 故障诊断; 支持向量机; 细菌觅食算法; 最优参数

**DOI:** 10.19753/j.issn1001-4390.2022.11.007

中图分类号: TM41

文献标识码: B

文章编号: 1001-4390(2022)11-0048-06

## Research on the application of improved support vector machine in power transformer fault diagnosis

Qiu Haifeng<sup>1</sup>, Su Ning<sup>1</sup>, Tian Songlin<sup>2</sup>

(1. Shenzhen Power Supply Bureau Co., Ltd., Shenzhen 518048, Guangdong, China.

2. CSG Shenzhen Digital Grid Research Institute Co., Ltd., Shenzhen 518034, Guangdong, China)

**Abstract:** Aiming at the problems that the judgment index of state quantity is too absolute and the accuracy of intelligent algorithm is affected by parameters in power transformer fault diagnosis. Based on the analysis of power transformer fault, a method combining support vector machine (SVM) and bacterial foraging algorithm (BFA) is proposed for power transformer fault diagnosis. Through the optimization ability of bacterial foraging algorithm, the optimal penalty factor and kernel parameters of support vector machine are found to improve the ability of fault diagnosis. The superiority of this method is verified by simulation and example. The results show that, compared with particle swarm optimization, bacterial foraging algorithm has better optimization ability, the fault diagnosis model based on BFA-SVM has higher accuracy, robustness and optimization ability than before improvement, compared with particle swarm optimization, the accuracy of fault diagnosis is improved by 7.50%, which has certain practical value.

**Keywords:** power transformer, fault diagnosis, support vector machine, bacterial foraging algorithm, optimal parameters

### 0 引言

随着全球环保意识的普及,我国力争到 2030 年实现碳达峰,到 2060 年实现碳中和,这一目标促进了智能电网的发展。智能变电站是智能电网的基础,而变压器作为变电站的核心部件,其所处的环境和独特

负荷往往导致故障较多<sup>[1]</sup>。故障不仅会影响供电的可靠性,而且会造成严重的经济损失<sup>[2]</sup>。对变压器进行故障诊断,可以及时发现潜在的故障,早期进行维护,具有十分重要的意义<sup>[3]</sup>。因此,对变压器故障进行准确的判断是保证电力变压器稳定、安全运行的关键。

目前,国内外许多研究者对电力变压器故障诊断方法进行了大量的研究,提出了主要气体法<sup>[4]</sup>、IEC

基金项目: 中国南方电网有限公司科技项目(090000 HA42190008)

三比值法<sup>[5]</sup>和大卫三角法<sup>[6]</sup>等经典变压器故障诊断方法。随着机器学习的不断发展,支持向量机<sup>[7]</sup>、贝叶斯网络<sup>[8]</sup>、极限学习机<sup>[9]</sup>等一些智能算法在智能变压器故障诊断成为主流方法。在文献[10]中,提出了一种基于分步机器学习的电力变压器故障诊断模型。结果表明,与单一学习模型相比,该模型不仅具有更高的精度,而且具有更高的效率,可以有效地弥补单一学习的不足。在文献[11]中,提出了一种经验小波变换与改进卷积神经网络相结合的变压器故障智能诊断方法。结果表明,该诊断模型能有效地识别变压器的故障状态,对 110 kV 变压器五种典型故障的平均诊断准确率均在 94 % 以上。在文献[12]中,提出了一种结合蝗虫优化算法和 BP 神经网络的变压器故障智能诊断方法。结果表明,相比于传统故障诊断方法,改进后的方法不仅保持了网络的学习速度和全局搜索能力,而且在训练时间和诊断准确率方面都有一定的提升。在文献[13]中,提出了一种变压器故障诊断方法,该方法将深度置信网络与改进的模糊 C-均值聚类相结合。结果表明,与现有的变压器故障诊断方法相比,该方法具有更高的诊断准确率,诊断准确率为 93.3 %,能够较准确地识别各种变压器故障。在实际应用中,上述方法可以解决传统方法繁琐的步骤和诊断绝对化问题,但需要进一步优化训练精度和提高适应性。

在此基础上,提出了一种结合 SVM<sup>[14]</sup>和 BFA<sup>[15]</sup>用于电力变压器故障诊断。通过 BFA 的寻优能力找到最优的 SVM 的惩罚因子和核参数,提高 SVM 的故障诊断能力。通过仿真和实例进行了对比分析。

### 1 电力变压器故障分类

由于电力变压器结构的复杂性,在运行过程发生故障时,涉及的部位不同,具体故障类型的分类也不同<sup>[16]</sup>。常用的分类方法包括按回路分类、按变压器主体结构分类、按故障位置分类、按故障易发区分类等,具体分类方法如图 1 所示。

根据故障的机理和性质,可将内部故障分为两类:热性故障和电性故障,这是文中采用的主要故障分类方法。热性故障是由变压器内部局部过热引起的,根据程度的不同,过热分为低温(小于 300 ℃)、中温(介于 300 ℃和 700 ℃)、高温(大于 700 ℃)。电性故障是指绝缘材料在强电场力作用下分解产生各种特征气体或直接引起介质击穿的高能量密度故障<sup>[17]</sup>。根据程度的不同,分为局部放电、低能放电、高能放电。

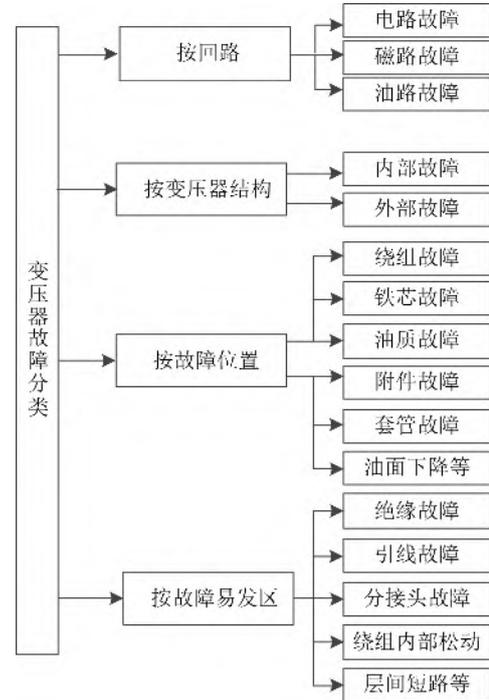


图 1 电力变压器故障

Fig. 1 Power transformer fault

在现场运行条件下,热性故障和电性故障基本上是由变压器绝缘劣化引起的,故障进一步加剧了绝缘材料的劣化。因此,相关人员应采取科学有效的管理方法对运行中的变压器进行维护,及时准确地发现各种潜在障碍,延长变压器的使用寿命。

## 2 故障诊断模型

### 2.1 建立诊断模型

电力变压器通常有单一放电或热故障,对 350 例电力变压器故障情况进行统计分析,发现有过热和放电同时发生的情况,约占总故障量的 10 % 左右。因此,设置 7 种故障代码,1 表示正常状态,故障编码见表 1。

表 1 故障编码

Tab. 1 Fault code

故障类型	编码
局部放电	2
低能放电	3
高能放电	4
低温过热	5
中温过热	6
高温过热	7
混合	8

内部故障与油中气体含量相关,以 C<sub>2</sub>H<sub>2</sub>、C<sub>2</sub>H<sub>4</sub>、

$C_2H_6$ 、 $H_2$  和  $CH_4$  为特征量,作为输入,对输入数据进行处理,如式(1)所示<sup>[18]</sup>:

$$\begin{cases} x_{i1}^* = x_{i1} / (\sum_{j=1}^5 x_{ij}) \\ x_{ij}^* = x_{ij} / (\sum_{j=2}^5 x_{ij}), j = 2, 3, \dots, 5 \end{cases} \quad (1)$$

式中  $x_{i1} \dots x_{i5}$  为氢、甲烷、乙烯、乙烷和乙炔的气体含量;  $x_{i1}^*$  为氢占总氢烃的百分比;  $x_{i2}^* \dots x_{i5}^*$  为甲烷、乙烯、乙烷和乙炔分别占总碳氢化合物的百分比。

文中的 SVM 故障模型核函数采用 RBF 径向基函数,通过式(1)进行归一化为评价指标输入,以表 1 中的故障代码为输出,图 2 为诊断模型。

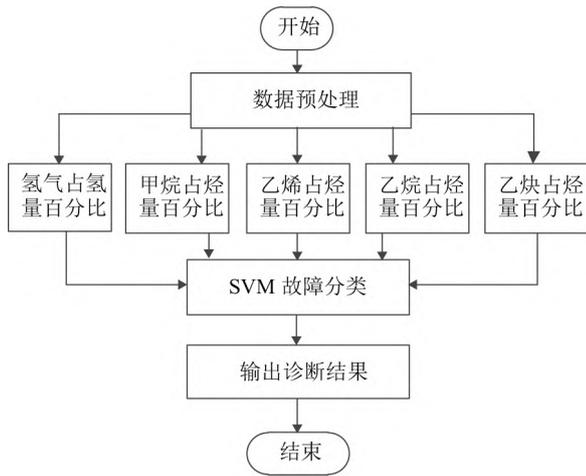


图 2 诊断模型

Fig. 2 Diagnostic model

## 2.2 支持向量机

支持向量机是由 Vapnik 等为了解决小样本、非线性问题提出的机器学习方法,得到了广泛的应用(状态评估、故障诊断等)<sup>[19]</sup>。

设置一个可分样本  $X = \{x_i, y_i\}, i = 1, 2, \dots, l$ , 其中  $x_i \in R^n, n$  为样本空间的维数;  $y_i \in \{-1, +1\}$  为样本类别标记。如果存在最优超平面,可以将两类样本区分开,间隔达到最大。最优超平面如式(2)所示<sup>[20]</sup>:

$$\omega x + b = 0 \quad (2)$$

式中  $\omega$  为权重向量;  $b$  为偏差值。

通过式(3)所示约束条件进行求解。

$$\begin{cases} \text{Obj. min } L(\omega) = \frac{1}{2} \|\omega\|^2 \\ \text{s. t. } y_i(\omega x + b) \geq 1 \end{cases} \quad (3)$$

对于线性不可分样本,最优超平面通过式(4)中的约束进行求解<sup>[21]</sup>:

$$\begin{cases} \text{Obj. min } L(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \xi_i^u \\ \text{s. t. } y_i(\omega x_i + b) - 1 + \xi_i \geq 0 \end{cases} \quad (4)$$

式中  $C$  为控制误差的惩罚程度;  $\xi_i$  为松弛变量。

引入拉格朗日函数和拉格朗日乘子  $\alpha_i$ , 式(4)转化为对偶问题,如式(5)所示<sup>[22]</sup>:

$$\begin{cases} \text{Obj. max } \omega(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \langle x_i \cdot x_j \rangle \\ \text{s. t. } \sum_{i=1}^l \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \end{cases} \quad (5)$$

由 KKT 条件求解式(5)得到最优解,如式(6)所示<sup>[23]</sup>:

$$\omega^* = \sum_{i=1}^l y_i \alpha_i^* x_i \quad (6)$$

式中  $\alpha_i^*$  为支持向量。

通过定义核函数  $K(x_i, x_j)$ , 最优分类函数如式(7)所示:

$$f(x) = \text{sgn}(\sum_{i=1}^l \alpha_i^* y_i K(x_i, x) + b) \quad (7)$$

主要将 RBF 核函数用于支持向量机的研究。RBF 核函数如式(8)所示<sup>[24]</sup>:

$$K(x_i, x_j) = \exp(-g \|x_i - x_j\|)^2 \quad (8)$$

式中  $g$  为核参数。

支持向量机模型的性能依赖于惩罚参数  $C$  和核函数的参数  $g$  的选择,参数的质量对算法的准确性有着显著的影响<sup>[25]</sup>。因此,选择 BFA 对 SVM 进行优化,以保证算法选择的参数是模型的最优参数。

## 2.3 改进支持向量机

BFA 算法是由 K. M. Passino 等人提出的一种新的仿生算法<sup>[26]</sup>。通过趋化性、复制性和迁徙性三个动作实现优化。该算法由于具有群智能算法的并行搜索和易跳出局部极值等优点,应用广泛。

通过 BFA 的寻优能力找到最优的 SVM 的惩罚因子  $C$  和核参数  $g$ ,使模型具有最强大的诊断能力。优化过程如下:

步骤 1: 对样本进行预处理,划分训练集和测试集;

步骤 2: 对 BFA 算法进行初始化,设置迁徙概率、迁徙操作次数、趋化操作次数等参数<sup>[27]</sup>;

步骤 3: 将  $\{C, g\}$  作为个体的位置坐标。初始种群细菌  $s$  个,单个细菌的位置是随机的;

步骤 4: 以单个细菌个体的位置  $\{C, g\}$  作为算法参数,样本  $k$ -折交叉验证的准确性  $\overline{C}_i$  作为第  $i$  个细菌

的适应度函数,如式(9)所示<sup>[28]</sup>:

$$F(i, j, k, l) = \bar{C}_r = \frac{1}{k} \sum_{t=1}^k \left( \frac{l'_t}{l} \times 100\% \right) \quad (9)$$

式中  $l'$  和  $l'_t$  分别为第  $t$  个验证集样本数和正确分类数。

如式(10)所示,目标函数为  $k$ -交叉验证准确性最大,约束条件为  $\{C, g\}$  的取值范围<sup>[29]</sup>。

$$\begin{cases} \text{Obj. } F(i, j, k, l) = \max \bar{C}_r(C, g) \\ \text{s. t. } C_{\min} \leq C \leq C_{\max} \\ \text{s. t. } g_{\min} \leq g \leq g_{\max} \end{cases} \quad (10)$$

步骤 5: 求解目标函数,进行 BFA 操作,得到目标函数最优值,即最优的  $\{C, g\}$ 。

步骤 6: 对测试样本进行故障诊断,输出诊断结果。基于 BFA-SVM 的故障诊断流程图如图 3 所示。

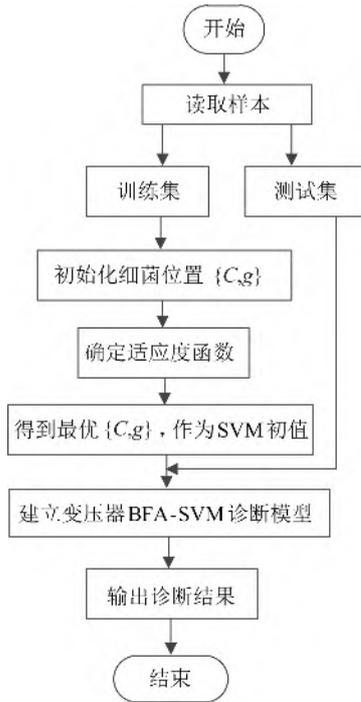


图 3 故障诊断流程

Fig. 3 Fault diagnosis process

### 3 结果与分析

#### 3.1 仿真参数

为了保证模型的效率和准确性,利用 MATLAB r2018a 计算并优化支持向量机的参数<sup>[30]</sup>。在对样本进行预处理后,使用 libsvm 3.22 工具箱对样本进行训练和测试,以获得模型的最优参数。最后,利用 IBM SPSS modeler 14.1 建立了支持向量机分类模型,并利用训练参数和优化参数进行分类。电力变压器故障诊

断与验证。

细菌觅食算法的参数为:种群 50、趋化操作次数 10、迁移操作次数 2、迁移概率 0.25、复制操作次数 44、折叠数  $k = 10$ 。从南方电网公司故障统计数据库中收集了 320 组电力变压器故障数据。240 组训练数据(每个类别 30 组)和 80 组测试数据(每个类别 10 组)。

#### 3.2 仿真分析

为了证明 BFA 算法具有较好的优化能力,在同一样本下分别采用 BFA 算法和 PSO 算法优化 SVM 参数。优化过程如图 4 和图 5 所示,参数优化结果如表 2 所示。

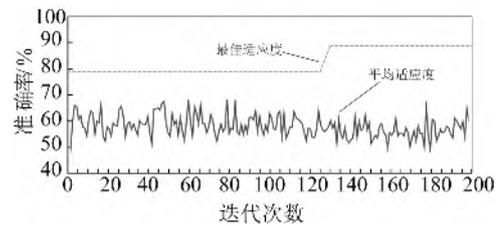


图 4 PSO-SVM 寻优方法

Fig. 4 PSO-SVM optimization method

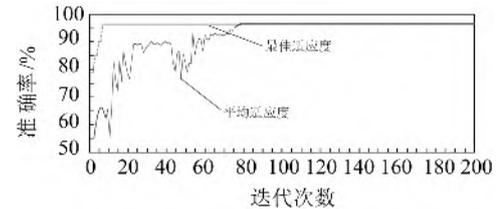


图 5 BFA-SVM 寻优方法

Fig. 5 BFA-SVM optimization method

表 2 不同算法参数优化结果

Tab. 2 Optimization results of different algorithm parameters

方法	PSO-SVM	BFA-SVM
$C$	11.053 2	5.793 2
$\gamma$	1.523 1	0.851 2
迭代次数	123	7
准确率	88.75 %	96.25 %

从图 4、图 5 和表 2 可以看出,BFA 的收敛速度比 PSO 快得多。文中模型对测试集进行诊断准确率为 96.25 %。PSO-SVM 模型对测试集进行诊断准确率为 88.75 %。因此,BFA 算法相比于 PSO 算法具有一定的优势。

由图 5 的优化过程可以看出。由于算法开始时初始菌群较大,可以快速找到最优适应度,但在优化过程中初始菌群分布较广,且菌群个体间存在明显差异,平

均适应度差异很大,在首次复制(10 次迭代前) 50 % 的不相容个体死亡,剩余适应度较好的被复制。因此,菌群的适应度得到了显著提高。使波动不那么明显,慢慢趋于平缓。迁徙操作,40 次迭代后,细菌位置发生变化,跳出局部极值。在经过趋化和复制操作,达到最优适应度。

为了证明基于 BFA-SVM 的电力变压器故障诊断模型比未改进前的 SVM 电力变压器故障诊断模型具有更好的分类性能,图 6 所示优化前模型的诊断结果。图 7 所示优化后模型的诊断结果。

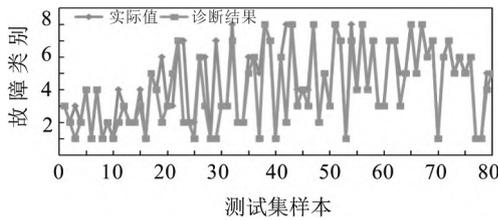


图 6 SVM 模型测试集诊断结果

Fig. 6 Diagnosis results of SVM model test set

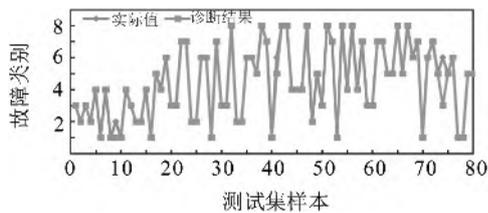


图 7 文中模型测试集诊断结果

Fig. 7 Diagnosis results of the model test set proposed in this paper

由图 6 可以看出,未改进前 SVM 模型参数  $C$  和  $g$  是系统设置的默认值。结果表明,该诊断模型在测试集的分类结果中有 17 个错误,准确率为 78.75 %。

由图 7 可以看出,基于 BFA-SVM 诊断模型,测试集的诊断结果表明,该模型分类结果仅错误了 3 个,准确率为 96.25 %。

以上仿真结果表明,基于 BFA-SVM 的故障诊断模型相比于改进前具有更好的分类功能、准确性、鲁棒性和寻优能力等。

### 3.3 实例分析

变电站中电力变压器发生短路故障(型号为 sfz11-31500/110),对变压器油进行色谱分析。采用本文故障诊断模型判断,诊断故障代码为 4(高能放电),色谱数据见表 3。

为了确保变压器的安全运行,将变压器送回工厂

进行维护。研究发现,短路冲击会造成变压器内产生高能放电,导致铜外露和绝缘烧损。在低压 C 相存在绕组和铁心融化现象。表明绕组在铁心处有高能放电。文中建立模型诊断结果与变压器的实际情况相符。

表 3 色谱数据

Tab. 3 Chromatogram data

气体	理论值/( $\mu\text{L/L}$ )	上部油门/( $\mu\text{L/L}$ )	下部油门/( $\mu\text{L/L}$ )
氢气	1 5 872	634	600
乙烷	19.5	11.0	10.7
乙烯	372	136	138
甲烷	458	139	139
乙炔	799	194	196

### 4 结束语

文章提出将 SVM 和 BFA 结合用于电力变压器故障诊断。采用 BFA 优化 SVM 的惩罚因子和核参数,提高了 SVM 的故障诊断能力。结果表明,BFA 在选择 SVM 的最优参数方面优于 PSO,故障诊断从优化前的 88.75 % 提高到优化后的 96.25 %。所提模型具有优良的分类能力、良好的鲁棒性和较强的寻优能力。由于目前实验室硬件和数据规模的影响,故障诊断模型还处于初级阶段。基于此,模型的持续改进将是下一步的重点。

### 参考文献

[1] 张鑫,徐遵义,何慧茹,等. 基于 RBM 和 SVM 的风电机组叶片开裂故障预测[J]. 电力系统保护与控制,2020,48(15): 134-140.  
Zhang Xin, Xu Zunyi, He Huiru, et al. Wind turbine blade cracking fault prediction based on RBM and SVM[J]. Power System Protection and Control, 2020, 48(15): 134-140.

[2] 盛四清,张晶晶,陈玉良. 基于改进二进制蝙蝠算法的独立型微网容量优化配置[J]. 电力建设,2017,38(11): 121-128.  
Sheng Siqing, Zhang Jingjing, Chen Yuliang. Optimal allocation of independent microgrid capacity based on improved binary bat algorithm[J]. Power Construction, 2017, 38(11): 121-128.

[3] 徐耀松,张原. 基于改进 VMD-MSE 方法的输电线路故障特征分析及分类[J]. 电子测量与仪器学报,2019,33(6): 89-95.  
Xu Yaosong, Zhang Yuan. Analysis and classification of transmission line fault characteristics based on improved vmd-mse method[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(6): 89-95.

[4] 景皓,李璠,卢志刚,等. 基于主从博弈理论的含分布式发电的主动配电网故障恢复方法[J]. 智慧电力,2021,49(5): 77-84.  
Jing Hao, Li Zhen, Lu Zhigang, et al. Active distribution network fault recovery method with distributed generation based on master-slave game theory[J]. Smart Power, 2021, 49(5): 77-84.

- [5] 刘可真, 苟家冀, 骆钊, 等. 基于粒子群优化-长短期记忆网络模型的变压器油中溶解气体浓度预测方法[J]. 电网技术, 2020, 44(7): 2778-2884.  
Liu Kezhen, Gou Jiaji, Luo Zhao, et al. Prediction method of dissolved gas concentration in transformer oil based on particle swarm optimization short-term memory network model[J]. Power Grid Technology, 2020, 44(7): 2778-2884.
- [6] DUVA M. A review of faults detectable by gas-in-oil analysis in transformers[J]. IEEE Electrical Insulation Magazine, 2002, 18(3): 8-17.
- [7] 咸日常, 范慧芳, 李飞, 等. 基于改进 GSA-SVM 模型的电力变压器故障诊断[J]. 智慧电力, 2022, 50(6): 50-56.
- [8] 何宁辉, 朱洪波, 李秀广, 等. 基于贝叶斯网络和假设检验的变压器故障诊断[J]. 电力科学与技术学报, 2021, 36(6): 20-27.
- [9] 王春明, 朱永利. 基于 NSGA2 优化正则极限学习机的变压器油色谱故障诊断[J]. 高压电器, 2020, 56(9): 210-215.
- [10] 谢乐, 衡熙丹, 刘洋, 等. 基于线性判别分析和分步机器学习的变压器故障诊断[J]. 浙江大学学报(工学版), 2020, 54(11): 2266-2272.  
Xie Le, Heng Xidan, Liu Yang, et al. Transformer fault diagnosis based on linear discriminant analysis and step-by-step machine learning[J]. Journal of Zhejiang University(Engineering Edition), 2020, 54(11): 2266-2272.
- [11] 李阳, 路鹏, 朱伯涛, 等. 基于经验小波变换和改进卷积神经网络的变压器故障诊断方法[J]. 电子设计工程, 2021, 29(8): 140-144.  
Li Yang, Lu Peng, Zhu Botao, et al. Transformer fault diagnosis method based on empirical wavelet transform and improved convolutional neural network[J]. Electronic Design Engineering, 2021, 29(8): 140-144.
- [12] 徐新, 蒋波涛, 曹雯. 蝗虫优化神经网络在变压器故障诊断中的应用[J]. 电网与清洁能源, 2021, 37(5): 17-23.  
Xu Xin, Jiang Botao, Cao Wen. Application of locust optimized neural network in transformer fault diagnosis[J]. Power Grid and Clean Energy, 2021, 37(5): 17-23.
- [13] 刘仲民, 翟玉晓, 张鑫, 等. 基于 DBN-IFCM 的变压器故障诊断方法[J]. 高电压技术, 2020, 46(12): 4258-4265.  
Liu Zhongmin, Zhai Yuxiao, Zhang Xin, et al. Transformer fault diagnosis method based on DBN IFCM[J]. High Voltage Technology, 2020, 46(12): 4258-4265.
- [14] 谢国民, 倪乐水. 基于 IABC 优化 SVM 的变压器故障诊断[J]. 电力系统保护与控制, 2020, 48(15): 156-163.
- [15] 金海川, 陈佳雪, 张磊, 等. 基于细菌觅食改进 SVM 的变电站智能检测方法[J]. 自动化与仪器仪表, 2021(11): 52-55.
- [16] 李鹤健, 徐肖伟, 王科, 等. 基于粒子群优化随机森林的变压器故障诊断模型[J]. 昆明理工大学学报(自然科学版), 2021, 46(3): 94-101.
- [17] SY-Ming Guu, YADVENDRA Singh, SHASHI Kant Mishra. On strong KKT type sufficient optimality conditions for multi objective semi-infinite programming problems with vanishing constraints[J]. Journal of Inequalities and Applications, 2017, 44(1): 1-9.
- [18] 陈勇, 李鹏, 张忠军, 等. 基于 PCA-GA-LSSVM 的输电线路覆冰负荷在线预测模型[J]. 电力系统保护与控制, 2019, 47(10): 110-119.  
Chen Yong, Li Peng, Zhang Zhongjun, et al. On-line ice load forecasting model for transmission lines based on PCA-GA-LSSVM[J]. Power System Protection and Control, 2019, 47(10): 110-119.
- [19] 沈豫, 项康利, 黄夏楠, 等. 基于 XGBoost 算法的短期负荷预测研究[J]. 水利水电技术, 2019, 50(增刊1): 256-261.  
Shen Yu, Xiang Kangli, Huang Xianan, et al. Short term load forecasting based on xgboost algorithm[J]. Water Conservancy and Hydropower Technology, 2019, 50(free issue 1): 256-261.
- [20] 张弘强, 王春红. 基于学习矢量量化(LVQ)神经网络的医学生化分析系统[J]. 自动化技术与应用, 2015, 34(8): 17-21.
- [21] 刘坤, 赵丽萍, 李建萍, 等. 考虑开关状态集调整的含光伏并网配电网动态故障恢复方法[J]. 电力系统保护与控制, 2021, 49(1): 24-31.
- [22] 刘家权, 刘坤, 周金涛, 等. 基于鲁棒优化的电-气互联型主动配电网故障恢复方法[J]. 电力系统保护与控制, 2021, 49(7): 66-74.
- [23] 杨丽君, 高鹏, 王伟浩, 等. 考虑时间尺度的配电网故障恢复方法研究[J]. 太阳能学报, 2021, 42(1): 453-459.
- [24] Kaiyuan Hou, Guanghui Shao, Haiming Wang, et al. Research on practical power system stability analysis algorithm based on modified SVM[J]. Protection and Control of Modern Power Systems, 2018, 3(2): 2-7.
- [25] Garvishkumar K. Patel, Vipul K. Dabhi, Harshadkumar B. Prajapati. Clustering Using a Combination of Particle Swarm Optimization and K-means[J]. Journal of Intelligent Systems, 2017, 12(3): 457-469.
- [26] 张涛, 张东方, 王凌云, 等. 基于改进小生境粒子群算法的主动配电网优化重构[J]. 信阳师范学院学报, 2018, 31(3): 473-478.
- [27] 陈江兴, 梁良, 付俊峰, 等. 基于大数据的智能电网数据调度与快速分发方法研究[J]. 电测与仪表, 2020, 57(6): 88-93.
- [28] 孙茂一, 杨林, 周志通, 等. 基于 SLLE 的电缆附件局部放电模式识别[J]. 电测与仪表, 2019, 56(22): 25-30, 102.
- [29] 王川丰, 施加轮, 姚文杰, 等. 基于风险感知的电力通信网跨层路由优化算法[J]. 电子设计工程, 2020, 28(20): 142-148.
- [30] 杨阳, 汪玉成, 吕玉祥, 等. 基于软件定义的电力通信网络业务感知流量调度机制研究[J]. 自动化与仪器仪表, 2017, 214(8): 146-149.

## 作者简介:



邱海枫(1981—)男,工程师,硕士,研究方向为信息与信号处理、电网企业数字化规划建设、数据资产管理。Email: qqqh8181@163.com

苏宁(1989—)男,工程师,硕士,研究方向为电网企业数字化规划管理、电网企业数据资产管理、电网企业创新管理。

田松林(1988—)男,本科,研究方向为电力信息化。

收稿日期: 2021-12-28; 修回日期: 2022-08-05

(田春雨 编发)