

# 基于WOA-SVM的智能变电站二次系统故障参数映射模型

郑翔<sup>1</sup>, 杜奇伟<sup>2</sup>, 阮黎翔<sup>3</sup>, 王海园<sup>1</sup>, 周坤<sup>4</sup>, 王义波<sup>4</sup>

(1. 国网浙江省电力有限公司衢州供电公司, 浙江 衢州 324100;

2. 国网浙江省电力有限公司, 杭州 310007;

3. 国网浙江省电力有限公司电力科学研究院, 杭州 310014;

4. 武汉凯默电气有限公司, 武汉 430223)

**摘要:** 目前通过人工分析大量运行信息难以快速精确定位智能变电站二次系统故障, 无法适应智能电网高可靠性运行要求。为此, 提出一种智能变电站二次系统故障参数映射模型。首先根据特征信息建立故障定位推理知识库, 对故障类型进行编码。然后基于智能变电站的历史运行数据构建模型训练集, 引入多分类器对SVM(支持向量机)算法进行改进, 用WOA(鲸鱼优化算法)优化其参数, 以设备状态为输入, 二次系统故障类型为输出, 建立了智能变电站二次系统设备参数与运行状态之间的映射关系。最后以实际数据作为测试集对所提模型进行检验, 证明了此故障参数映射模型的有效性。

**关键词:** 智能变电站; 二次系统; 故障参数映射; 鲸鱼优化算法; 支持向量机

**DOI:** 10.19585/j.zjdl.202401005

开放科学(资源服务)标识码(OSID):



## A WOA-based fault parameter mapping model for the secondary systems of intelligent substations

ZHENG Xiang<sup>1</sup>, DU Qiwei<sup>2</sup>, RUAN Lixiang<sup>3</sup>, WANG Haiyuan<sup>1</sup>, ZHOU Kun<sup>4</sup>, WANG Yibo<sup>4</sup>

(1. State Grid Quzhou Power Supply Company, Quzhou, Zhejiang 324100, China;

2. State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310007, China;

3. State Grid Zhejiang Electric Power Co., Ltd. Research Institute, Hangzhou 310014, China;

4. Wuhan Kemov Electric Co., Ltd, Wuhan 430223, China)

**Abstract:** Currently, it is challenging to rapidly and precisely locate faults in the secondary systems of intelligent substations through manual analysis of extensive operational data, making it inadequate for meeting the high reliability requirements of smart grids. To address this issue, a fault parameter mapping model for the secondary systems of intelligent substations is proposed. Firstly, a knowledge base for fault localization reasoning is established based on characteristic information to encode fault types. Subsequently, utilizing historical operational data from intelligent substations, a training set for the model is constructed. The support vector machine (SVM) is enhanced by introducing a multi-classifier approach, and its parameters are optimized using the whale optimization algorithm (WOA). By taking equipment status as input and secondary system fault types as output, a mapping relationship is established between the parameters of secondary system equipment of intelligent substations and the operational state. Finally, the proposed model is validated using actual data as a test set, demonstrating the effectiveness of the proposed model.

**Keywords:** intelligent substation; secondary system; fault parameter mapping; WOA; SVM

## 0 引言

智能化将是未来电网的重要特点, 智能变电

站二次系统的正常运行关系到电网的安全稳定<sup>[1]</sup>。智能变电站通常指符合DL/T 860标准, 设备具有较高智能性和互操作性的变电站。一方面, 智能变电站从根本上解决了常规变电站中存在的诸多问题, 包括由电缆老化、切换压板等引起的故障等。另一方面, 相对与传统变电站, 智能变电站

模型数据繁多, 设备状态信息相比常规变电站总量更为庞大, 包含了大量的软压板、虚回路、光纤回路、安全操作、保护运行状态等运行信息。二次系统运行异常时, 可以利用设备故障、告警等信息进行故障定位。但大量复杂冗余信息导致运维检修人员难以快速准确地分析诊断设备的故障原因, 并进行针对性的消缺。因此, 亟须解决如何根据二次系统状态信息进行快速准确的故障诊断<sup>[2-4]</sup>。

研究人员根据智能变电站的特点提出了一些对其进行状态监测和故障定位的方法<sup>[5-6]</sup>。从马尔科夫链的概念出发, 文献[7]评估了智能变电站二次系统的可靠性, 所得结果可为二次系统的状态检修提供参考; 文献[8]则从邻接矩阵的角度出发分析了智能变电站二次系统的结构, 从而探究了二次系统组网方式和智能变电站整体可靠性之间的关系; 文献[9]针对智能变电站二次回路信息数字化, 在人工经验指导下安措容易出错的问题, 提出了一种自动生成方法。以上研究为智能变电站二次系统的状态监测和故障诊断提供了一些思路和方法, 如将神经网络、贝叶斯理论、机器学习<sup>[10]</sup>、云计算等与智能变电站的故障诊断相结合。然而神经网络<sup>[11-12]</sup>在存在噪声时会受到很大影响, 且存在计算量大、容易陷入局部最优和过拟合等问题。贝叶斯理论和机器学习能实现较好的分类效果, 然而由于这种方法要求样本的特征属性具有较低的相关性, 往往与实际不符, 因此大大限制了其泛用性。引入云计算环境提供了一种提高数据处理效率的方法, 但是对 Hadoop 平台配置的硬件环境有一定要求<sup>[13]</sup>。

本文提出了一种智能变电站二次系统故障参数映射模型, 根据变电站二次设备不同模块故障时的故障特征信息建立故障定位知识推理库, 使用高维空间去噪方法计算数据离散度对信息进行筛选, 定义信息编码方法, 对智能变电站设备状态和故障类型进行编码后, 以智能变电站设备状态为输入, 以智能变电站二次系统故障类型为输出, 采用 WOA(鲸鱼优化算法)优化 SVM(支持向量机)模型, 建立了智能变电站设备状态与故障类型之间的映射关系。所提模型可以将所选特征参数的范围映射到相应的故障类型, 根据监测的二

次设备状态信息实现故障定位与诊断。

## 1 智能变电站故障参数映射

相对于传统变电站, 符合 DL/T 860 标准的智能变电站的一个重要特点是其模型的标准化和信息的网络共享, 智能变电站的结构为三层两网, 如图 1 所示。

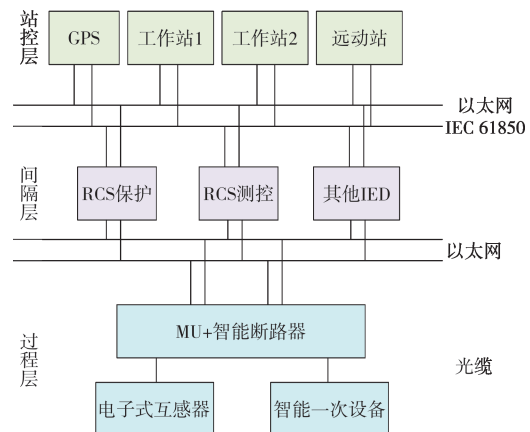


图 1 智能变电站的分层结构

Fig.1 Hierarchical structure diagram of smart substation

过程层主要完成本间隔电气量测量、设备状态检测和控制命令执行; 间隔层采集本间隔过程层的实时数据, 实现一次设备的保护与控制; 站控层汇总全站的实时数据, 将数据传送远方调度控制中心, 同时接受远方控制命令。

本文根据所获取的设备状态参数, 建立相应的故障映射模型, 将设备状态参数和故障类型进行一一对应, 达到快速定位智能变电站故障类别的目的。映射关系定义为:

$$y_i = f(x_{i1}, x_{i2}, \dots, x_{iN}) \quad (1)$$

式中:  $x_i$  表示第  $i$  个设备状态量参数;  $N$  为映射中输入参数的个数;  $f$  为智能变电站状态到故障类型的映射;  $y_i$  为故障类型, 可以根据故障对象进行划分。

根据变电站二次设备不同故障下的特征信息建立故障定位知识推理库, 将故障对象定为 MU(合并单元)、智能终端和保护装置, 二次系统状态信息包括设备运行信息、采样值和 GOOSE 信息。故障类型编号及相应故障信息如表 1 所示。

表1 故障类型编号及部分定位推理知识库  
Table 1 Fault type numbers and the knowledge base for fault localization reasoning

故障编号	故障类型	特征信息
1	合并单元主DSP故障	合并单元采样异常, 保护闭锁等
2	合并单元 I/O 模块(线路 MU→线路/母线保护)故障	保护SV总告警, MU/保护/测控 SV中断, 保护闭锁等
3	合并单元 I/O 模块(线路 MU↔交换机)故障	
4	合并单元 I/O 模块(母线 MU→线路 MU)故障	
5	纵联通道故障	
6	线路保护 CPU 插件故障	CPU X 异常, 内存自检出错, 保护闭锁等
7	线路保护 I/O 插件(MU→线路保护)或 SV 插件故障	保护SV/GOOSE总告警, 智能终端 GOOSE总告警, 保护SV/GOOSE中断, 保护闭锁, 重合闸闭锁等
8	线路保护 I/O 插件(线路保护↔智能终端)故障	
9	线路保护 I/O 插件(交换机→线路保护)故障	
10	线路保护 GOOSE 插件故障	
11	智能终端 I/O 板(线路/母线保护↔智能终端)故障	合并单元/测控/智能终端/保护 GOOSE通信中断, 合并单元/智能终端/保护 GOOSE总告警等
12	智能终端 I/O 板(智能终端↔交换机)故障	

## 2 故障参数映射模型建立

### 2.1 改进的SVM算法

SVM是一种二分类算法, 通过寻找最优超平面实现最优分类。离超平面最近的两个点到超平面的距离之和最大的超平面即为最优超平面。在这个过程中, 离超平面最近的两个点起到了决定性作用, 被称为支持向量。在进行非线性分类时, 往往将待分类对象映射到高维空间去, 使其线性可分类。自SVM提出以来, 由于其泛化能力强等优点得到了十分广泛的应用<sup>[14-16]</sup>, 然而由于智能变电站中的故障类型识别不是二分类, 而是多分类问题, 且其效果与SVM算法自身的参数取值大小有较大关系。为了使SVM适用于本文情况并实现较好的效果, 引入分类器并使用WOA优化SVM参数。

每一个分类器可以完成一次二分类, 引入  $t(t-1)/2$  个分类器即可完成一次  $t$  分类。以完成一次第  $m$  类和第  $n$  类间的二分类为例:

$$\begin{cases} \min_{\omega, b} \frac{1}{2} (\omega^m)^T (\omega^m) + C \sum_{i=1}^k (\xi_i^m), \xi_i^m \geq 0 \\ (\omega^m)^T \varphi(x_i) + b^m \geq 1 - \xi_i^m, y_i = m \\ (\omega^m)^T \varphi(x_i) + b^m \geq -1 + \xi_i^m, y_i = n \end{cases} \quad (2)$$

式中:  $\varphi$  为从原始空间到  $N$  维特征空间的映射;  $x_i = (x_{i1}, x_{i2}, \dots, x_{iN})$ ,  $\omega^m = [\omega_1^m, \omega_2^m, \dots, \omega_N^m]^T$  分别为输入和权重向量;  $C$  为正则化常数;  $\xi_i^m$  为松弛变量;  $b^m$  为超平面阈值。

核函数能够将原始样本映射到高维特征空间, 根据样本数据的特征, 需要选择不同的核函数。考虑到样本数据的非线性, 此处使用径向基函数:

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2} \quad (3)$$

式中:  $\gamma$  为核参数, 且  $\gamma > 0$ 。

由于  $\gamma$  和  $C$  对SVM算法的分类效果有较大影响, 为了确定较为合适的参数值, 采用WOA进行参数寻优。

### 2.2 WOA

WOA得益于自然界中鲸鱼的捕食行为, 其具体步骤主要包括群体搜索、包围猎物、追捕和攻击。通过模拟鲸鱼捕食行为的算法步骤, 在每次迭代中对每条鲸鱼位置、最优鲸鱼位置和相应适应度函数值进行更新, 每次迭代中鲸鱼可能会向最优鲸鱼位置收缩、螺旋游动或者远离从而进行探索, 最终的最佳位置即为WOA得出的最优解。算法具有简练易于实现、对目标函数要求低、全局搜索能力强、不容易陷入局部最优解等优点<sup>[17-18]</sup>。

群体搜索阶段, 每头鲸鱼的位置代表可能的一个解, 每条鲸鱼的位置如下式:

$$Z = (z_1, z_2, \dots, z_n) \quad (4)$$

式中:  $z_i$  表示鲸鱼的第  $i$  个位置坐标;  $n$  表示坐标的维数。

模拟鲸鱼相对最优鲸鱼位置游动的数学方程为:

$$\vec{D} = \left| \vec{C} \vec{Z}^*(t) - \vec{Z}(t) \right| \quad (5)$$

$$\vec{Z}(t+1) = \vec{Z}(t) - \vec{A} \cdot \vec{D} \quad (6)$$

式中:  $t$  表示当前迭代次数;  $\vec{D}$  为计算中的过程量;  $\vec{Z}(t)$  为解的位置向量;  $\vec{Z}^*$  是其中的最优解, 其值随着迭代过程中更优解的出现而更新。

$\vec{A}$  和  $\vec{C}$  为系数向量, 其计算如下:

$$\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a} \quad (7)$$

$$\vec{C} = 2 \cdot \vec{r} \quad (8)$$

式中:  $\vec{a}$  在算法进行过程中减小到 0;  $\vec{r}$  为取值在  $[0, 1]$  区间的随机向量。

模拟鲸鱼沿着螺旋形路径游动的数学表达式为:

$$\vec{Z}(t+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{Z}^*(t) \quad (9)$$

式中:  $b$  为对数螺旋形常数;  $l$  为  $-1$  到  $1$  之间的随机数。随机数和对鲸鱼多种捕食行为的模拟使得 WOA 具有较强的全局搜索能力。

### 2.3 数据预处理

数据预处理是故障参数映射模型建立的重要工作, 主要包括对信息的筛选和编码, 以及对数据的降维。

#### 2.3.1 信息筛选

信息筛选的目的主要是消除特殊条件下得到的数据及噪声。一方面, 极端数据所发生的环境与正常环境不同, 用这些数据对模型进行训练或检验并不合适, 如受网络风暴影响得到的数据; 另一方面, 噪声具有与离散点等效的特征, 当数据集中存在噪声时, 可能会使计算结果与实际值之间存在显著差异, 从而也会对 SVM 模型的效果产生影响。

针对极端数据, 可以直接舍弃以消除影响。针对噪声, 则采用一种高维空间去噪的方法去除异常值<sup>[19]</sup>, 具体做法如下。

定义样本集中的样本为  $o$ 、 $x_p$ 、 $x_q$ , 用  $d(x_p, x_q)$  表示样本  $x_p$  和样本  $x_q$  之间的距离。

定义  $k\text{-dist}(x_p)$  为符合下列要求的  $d(o, x_p)$  的值: 样本集  $S$  中至少有  $k$  个样本  $o'$  满足  $d(x_p, o') \leq d(x_p, o)$ , 且样本集  $S$  中最多有  $(k-1)$  个样本  $o'$  满足  $d(x_p, o') < d(x_p, o)$ 。

定义  $N_k(x_p)$  为符合下列要求的样本集: 样本  $x_p$  与数据集  $S$  中任一样本之间的距离小于  $k\text{-dist}(x_p)$  的值, 且  $N_k(x_p) = \{x_q \in S \setminus \{x_p\}, d(x_p, x_q) \leq k\text{-dist}(x_p)\}$ 。

定义样本  $x_p$  的局部密度为其自身的  $k\text{-dist}(x_p)$  平均数的倒数, 即:

$$e_k(x_p) = \frac{1}{\text{avg}(k - \text{dist}(x_q))} \quad (10)$$

其中,  $x_q \in N_k(x_p)$ 。

定义样本  $x_p$  的离群系数  $F_k(x_p)$  为:

$$F_k(x_p) = \frac{\text{avg}\{e_k(x_q)\}}{e_k(x_p)} \quad (11)$$

其中,  $x_q \in N_k(x_p)$ 。  $F_k(x_p)$  反映了最近  $k$  点的离散化程度。

为了达到降噪的目的, 分别计算每个样本  $x_p$  的  $F_k(x_p)$  值, 以样本  $x_p$  的  $F_k(x_p)$  值作为判断样本  $x_p$  是否为噪声的判据。如果  $F_k(x_p)$  值高于阈值, 则认为该样本有极大可能是噪声, 并将其从数据集中移除。通过这种降噪方式处理之后的数据集可以使分类模型实现更好的效果<sup>[20]</sup>。

#### 2.3.2 信息编码

对经过筛选后的信息进行编码, 让信息与数字编码一一对应, 使得计算机能够处理并进行建模。

以智能变电站设备或装置的状态为输入信号, 0 表示正常状态, 1 表示非正常状态。以对 1 号智能终端装置闭锁状态和 2 号合并单元装置闭锁状态进行编码为例, 可以定义智能终端装置闭锁正常的编码为 0, 合并单元同步异常的编码为 1, 则 1 号智能终端装置闭锁正常, 2 号合并单元同步正常可以编码为 (0, 0)。同理可以对其他设备的状态进行编码, 最后可以得到一个包含了各设备状态的输入向量。

对智能变电站可能发生的故障进行分类和编码, 根据故障装置和故障类别进行较为详细的编码, 为每一种故障类型定义一个编码, 使得编码形式的模型输出结果与故障类型相对应。编码参考案例如图 2 所示。

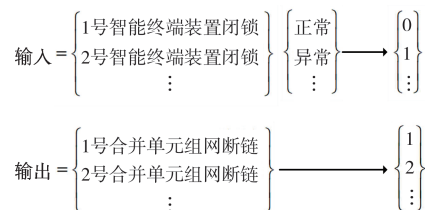


图 2 编码参考案例

Fig.2 The reference case for encoding

编码后,输入为一个代表智能变电站二次系统设备状态的向量,向量中的每一位对应着每种特定设备的状态;通过模型的映射关系可以得到对应的一种故障类型输出,输出的形式为一个数字。

通过信息编码将变电站状态信息转化为数字形式的编码,通过PCA(主成分分析法)进行降维,提高建模速度和准确性。

### 2.3.3 数据降维

由于所采集的信息涉及多个设备、多种状态,包含了一些与故障信息无关的状态量,如果不对数据进行预处理,将极大影响模型的速度和效果。因此,选择PCA进行降维。

PCA会构造一组低维度的新变量替换原始变量,为了在转换过程中尽量降低信息的损失同时使维度尽可能低,要求新变量之间没有相关性,且新变量可以通过线性组合还原原变量。

设新变量为 $\beta=(q_1, q_2, \dots, q_r)^T$ ,原始变量为 $\alpha=(p_1, p_2, \dots, p_s)^T$ ,其中 $r < s$ ,且能够找到系数使得如下关系式成立:

$$\begin{cases} q_1 = a_{11}p_1 + a_{12}p_2 + \dots + a_{1s}p_s \\ q_2 = a_{21}p_1 + a_{22}p_2 + \dots + a_{2s}p_s \\ \vdots \\ q_r = a_{r1}p_1 + a_{r2}p_2 + \dots + a_{rs}p_s \end{cases} \quad (12)$$

用矩阵表示为:

$$\beta = A\alpha, A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1s} \\ a_{21} & a_{22} & \dots & a_{2s} \\ \vdots & \vdots & \ddots & \vdots \\ a_{r1} & a_{r2} & \dots & a_{rs} \end{bmatrix} \quad (13)$$

因此,根据系数矩阵 $A$ 可以实现对原始变量的降维。

## 3 二次系统故障参数映射总体流程

采用本方法进行智能变电站二次系统故障参数映射总体流程如图3所示。

训练集数据来源于智能变电站历史运行数据,故障状态由专家数据库的诊断结果得到。测试集的数据则来源于实测数据及实际故障情况。

WOA优化的SVM的步骤如图4所示,其中,适应度值为SVM对测试集的二次系统故障识别准确度。

模型用文字形式可以简述为:

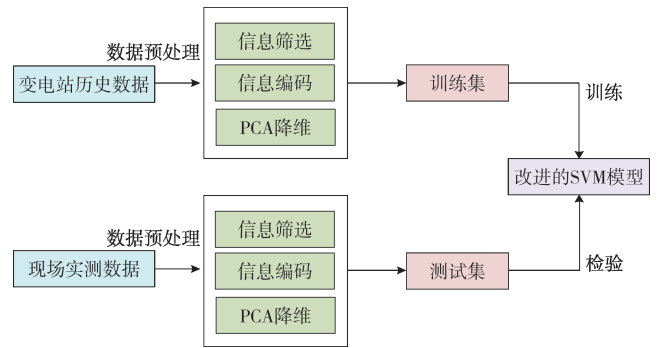


图3 二次系统故障参数映射总体流程  
Fig.3 Flowchart of fault parameter mapping of the secondary system

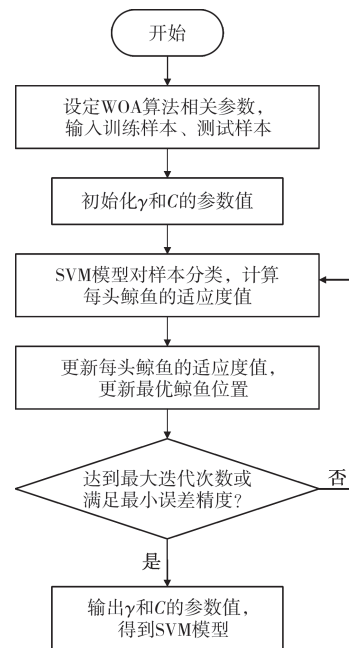


图4 WOA优化SVM的步骤  
Fig.4 Procedure of SVM optimization using WOA

1)训练模型:根据已有数据构建训练集,根据训练集建立二次系统故障参数映射模型,主要包括数据预处理、WOA参数寻优和SVM训练。输入训练集对SVM模型进行训练,SVM模型的两个参数 $\gamma$ 和 $C$ 通过WOA寻优确定。根据WOA参数寻优结果,本文中改进SVM模型的 $\gamma$ 参数和 $C$ 参数分别为1.899 4和0.01。

2)检验模型:对实测智能变电站状态数据进行预处理后构建测试集,根据故障参数映射模型输出的结果和二次系统实际故障状态的比较,检验模型的有效性和准确性。

### 4 模型检验结果及分析

为了验证 WOA 对改进 SVM 模型进行参数优化后, 对分类结果产生的影响, 分别用 10%、20%、30%、40%、50%、60% 和 70% 的样本训练集对模型进行训练, 计算每次训练后模型的分类准确率, 并对比优化前后的模型分类效果, 如图 5 所示。从图 5 可以看出, 使用 WOA 对改进的 SVM 模型进行参数优化后, 改善了模型的分类效果。

使用本模型对某 220 kV 智能变电站进行故障诊断。采用智能变电站设备状态量作为输入量, 故障类别作为输出量, 经过数据预处理后形成训练集。通过 WOA 进行参数寻优, 经过训练, 适应度曲线如图 6 所示。




图 5 WOA 对模型分类效果的影响

Fig.5 Influence of WOA on model classification effect




图 6 故障参数映射模型适应度曲线

Fig.6 Fitness curve of the fault parameter mapping model

为进一步证明本文所提方法的有效性, 将本文方法与目前几种常用的二次设备故障诊断方法进行对比, 分别是 BPNN(反向传播神经网络)、

RNN(循环神经网络)、PSO(粒子群优化算法)-SVM、SSA(麻雀搜索算法)-SVM 与 AdaBoost(自适应增强学习算法)-SVM。其中, PSO、SSA、AdaBoost 的迭代次数均设为 120 次, 初始个体数目为 40, 惩罚系数和核函数参数的范围为 [0, 500]; BPNN 和 RNN 输入层和输出层的神经元个数分别为 32 和 12, 中间三个隐藏层的神经元个数分别为 16、64、128, 学习率取 0.01, 激活函数除了输出层是 Softmax, 其余都是 Relu; PSO 算法中全局更新速度设置为 1.2, 粒子位置更新 150 次, 粒子速度限值取 ±15。不同算法的故障诊断结果如图 7—12 所示。




图 7 PSO-SVM 故障诊断结果

Fig.7 PSO-SVM fault diagnosis results




图 8 SSA-SVM 故障诊断结果

Fig.8 SSA-SVM fault diagnosis results

五种算法的故障诊断精度结果如表 2 所示, 本文提出的基于 WOA-SVM 的故障参数映射模型准确率最高, 达到 93.85%, 而 BPNN 深度学习模型的准确率最低, 仅有 80.78%。由此可知, 相比于




图9 AdaBoost-SVM故障诊断结果

Fig.9 AdaBoost-SVM fault diagnosis results




图10 BPNN故障诊断结果

Fig.10 BPNN fault diagnosis results




图11 RNN故障诊断结果

Fig.11 RNN fault diagnosis results

传统的RNN、BPNN、PSO-SVM、SSA-SVM与AdaBoost-SVM，本文所提方法最大可提升分类准确率13.07个百分点，可见基于定位知识推理库融入故障参数映射可有效提高故障诊断定位的




图12 故障参数映射模型故障诊断结果

Fig.12 Fault diagnosis results of fault parameter mapping model

表2 故障诊断精度对比

Table 2 Comparison of fault diagnosis accuracies

诊断模型	诊断正确率/%
PSO-SVM	89.23
SSA-SVM	84.61
AdaBoost-SVM	86.92
RNN	88.46
BPNN	80.78
本文方法	93.85

精度。

## 5 结论

本文提出了一种故障参数映射方法，能够将模型的输入映射到对应的故障类别，从而完成二次系统的故障检测，结论如下：

1)根据变电站二次设备不同类型故障的特征信息建立故障定位知识推理库，使用高维空间去噪方法计算数据离散度对信息进行筛选，定义信息编码方法，实现了对设备状态及故障类型的数字表达，形成了有效的数据集。

2)用WOA对SVM模型参数进行寻优，与传统的RNN、BPNN、PSO-SVM、SSA-SVM与AdaBoost-SVM方法相比，故障诊断准确率最高可提高13.07个百分点。

本文提出的方法还有进一步优化空间，比如采用其他启发式算法对参数进行寻优、模型选择的理论依据等，可在今后做进一步的研究。

## 参考文献

- [1] XU B A, YIN X, YIN X G, et al. Fault diagnosis of power systems based on temporal constrained fuzzy petri nets[J]. IEEE Access, 2019, 7: 101895-101904.
- [2] 樊陈,倪益民,申洪,等. 中欧智能变电站发展的对比分析[J]. 电力系统自动化, 2015, 39(16): 1-7.  
FAN Chen, NI Yimin, SHEN Hong, et al. Comparative analysis on development of smart substations in China and Europe[J]. Automation of Electric Power Systems, 2015, 39(16): 1-7.
- [3] 袁明哲,邹经鑫,汪良,等. 基于 PSO-SVM 的智能变电站二次系统故障诊断方法[J]. 电力工程技术, 2020, 39(6): 172-176.  
YUAN Mingzhe, ZOU Jingxin, WANG Gen, et al. Fault diagnosis method for secondary system of smart substation based on PSO-SVM[J]. Electric Power Engineering Technology, 2020, 39(6): 172-176.
- [4] 王同文,刘宏君,邵庆祝,等. 智能变电站二次回路智能预警及故障诊断技术研究[J]. 电测与仪表, 2020, 57(8): 59-63.  
WANG Tongwen, LIU Hongjun, SHAO Qingzhu, et al. Research on intelligent early warning and fault diagnosis technology for the secondary loop of smart substation[J]. Electrical Measurement & Instrumentation, 2020, 57(8): 59-63.
- [5] 金逸,刘伟,查显光,等. 智能变电站状态监测技术及应用[J]. 江苏电机工程, 2012, 31(2): 12-15.  
JIN Yi, LIU Wei, ZHA Xianguang, et al. The technology of state monitoring system and its application in smart substation[J]. Jiangsu Electrical Engineering, 2012, 31(2): 12-15.
- [6] YOO H, SHON T. Novel approach for detecting network anomalies for substation automation based on IEC 61850[J]. Multimedia Tools and Applications, 2015, 74(1): 303-318.
- [7] 朱小红,王利平,杨琪,等. 基于 Markov 的智能变电站二次系统间隔层和过程层可靠性评估[J]. 电测与仪表, 2019, 56(8): 73-80.  
ZHU Xiaohong, WANG Liping, YANG Qi, et al. The reliability evaluation of bay level and process level in smart substation secondary system based on Markov[J]. Electrical Measurement & Instrumentation, 2019, 56(8): 73-80.
- [8] 李书山,刘宏君,吴忠福,等. 智能变电站二次系统可靠性建模及分析[J]. 电测与仪表, 2020, 57(21): 61-69.  
LI Shushan, LIU Hongjun, WU Zhongfu, et al. Reliability modeling and analysis of secondary system in smart substation[J]. Electrical Measurement & Instrumentation, 2020, 57(21): 61-69.
- [9] 赵子涵,刘鑫,叶翔,等. 智能变电站二次系统“一键式”安措自动生成方法研究[J]. 电测与仪表, 2019, 56(4): 15-20.  
ZHAO Zihan, LIU Xin, YE Xiang, et al. Research on “one-click” automatic generation method for maintenance safety measures of secondary device in smart substation[J]. Electrical Measurement & Instrumentation, 2019, 56(4): 15-20.
- [10] HUANG S J, LIU X Z. Application of artificial bee colony-based optimization for fault section estimation in power systems[J]. International Journal of Electrical Power & Energy Systems, 2013, 44(1): 210-218.
- [11] 王家林,夏立,吴正国,等. 采用遗传神经网络的电力系统暂态信号分析方法[J]. 高电压技术, 2011, 37(1): 170-175.  
WANG Jialin, XIA Li, WU Zhengguo, et al. Analysis of power system transient signal using genetic algorithm and neural network[J]. High Voltage Engineering, 2011, 37(1): 170-175.
- [12] HONG Y Y, LIAN R C. Optimal sizing of hybrid wind/PV/diesel generation in a stand-alone power system using markov-based genetic algorithm[J]. IEEE Transactions on Power Delivery, 2012, 27(2): 640-647.
- [13] 和定繁,蒋羽鹏,杨珊,等. 云计算环境下基于 C4.5 决策树算法的智能变电站电力设备状态监测方法[J]. 电子设计工程, 2021, 29(8): 135-139.  
HE Dingfan, JIANG Yupeng, YANG Shan, et al. Condition monitoring method of power equipment in intelligent substation based on C4.5 decision tree algorithm in cloud computing environment[J]. Electronic Design Engineering, 2021, 29(8): 135-139.
- [14] 贾嵘,徐其惠,李辉,等. 最小二乘支持向量机多分类法的变压器故障诊断[J]. 高电压技术, 2007, 33(6): 110-113.  
JIA Rong, XU Qihui, LI Hui, et al. Fault diagnosis of transformer using multi-class least squares support vector machine[J]. High Voltage Engineering, 2007, 33(6): 110-113.
- [15] 陈逸枫,张大海,李宇欣,等. 基于 DWT-MOSMA-SVM 的多目标优化短期母线负荷预测[J]. 电力建设, 2023, 44(3): 49-55.  
CHEN Yicong, ZHANG Dahai, LI Yuxin, et al. Multi-objective optimization based on DWT-MOSMA-SVM for short-term bus load forecasting[J]. Electric Power Construction, 2023, 44(3): 49-55.
- [16] 张苏,郭裕钧,张血琴,等. 基于 SVM-RF 的电力线路故障诊断研究[J]. 山东电力技术, 2022, 49(11): 36-43.  
ZHANG Su, GUO Yujun, ZHANG Xueqin, et al. Research on fault diagnosis of transmission line based on SVM-RF method[J]. Shandong Electric Power, 2022, 49

- (11):36-43.
- [17] CHEN W H. Decentralized fault diagnosis and its hardware implementation for distribution substations[J]. IEEE Transactions on Power Delivery, 2012, 27(2):902-909.
- [18] 赵春华, 胡恒星, 陈保家, 等. 基于深度学习特征提取和 WOA-SVM 状态识别的轴承故障诊断[J]. 振动与冲击, 2019, 38(10):31-37.  
ZHAO Chunhua, HU Hengxing, CHEN Baojia, et al. Bearing fault diagnosis based on the deep learning feature extraction and WOA SVM state recognition[J]. Journal of Vibration and Shock, 2019, 38(10):31-37.
- [19] 安国庆, 史哲文, 马世峰, 等. 基于 RF 特征优选的 WOA-SVM 变压器故障诊断[J]. 高压电器, 2022, 58(2): 171-178.  
AN Guoqing, SHI Zhewen, MA Shifeng, et al. Fault diagnosis of WOA-SVM transformer based on RF feature optimization[J]. High Voltage Apparatus, 2022, 58(2): 171-178.
- [20] XIA X, LIU X F, LOU J C. Smart substation network fault classification based on a hybrid optimization algorithm[J]. International Journal of Electronics and Telecommunications, 2019, 65(4):657-663.
- 
- 收稿日期:** 2023-02-27; **修回日期:** 2023-03-25
- 作者简介:**  
郑翔(1972), 男, 高级工程师, 主要研究方向为电力系统自动化、智能变电站二次系统。  
(本文编辑: 童凯)