

文章编号: 2095-2163(2021)12-0143-06

中图分类号: TP391

文献标志码: A

# 基于 CEEMD 与 GWO-SVM 算法的配电网高阻接地故障选线方法

韩祥民, 刘晓波, 徐邦贤, 邱 知, 唐 辉

(贵州大学 电气工程学院, 贵阳 550025)

**摘 要:** 针对配电网高阻接地故障选线准确率低的问题, 提出一种基于 CEEMD 与 GWO-SVM 的高阻接地故障选线方法。首先使用互补型集合经验模态分解(CEEMD), 对原始数据进行多频段分解, 得到消除混频信号冗余特征的本征模态分量, 将含较多信息的前3个高频分量叠加为线路的特征频段; 结合差分进化算法的交叉变异操作, 对灰狼算法(GWO)进行改进, 用其优化支持向量机(SVM)参数获取, 得到 CEEMD 与 DE-GWO-SVM 相结合的综合故障选线模型。结果表明, 该预测模型比其它智能算法基准模型选线精度高, 且在高阻接地故障中具有优越性。

**关键词:** 高阻接地系统; 故障选线; CEEMD; DE-GWO-SVM 模型

## Resonant grounding fault line selection method based on CEEMD and GWO-SVM

HAN Xiangmin, LIU Xiaobo, XU Bangxian, QIU Zhi, TANG Hui

(College of Electrical Engineering, Guizhou University, Guiyang 550025, China)

**[Abstract]** Aiming at the low accuracy of high resistance grounding fault line selection in distribution network, a high resistance grounding fault line selection method based on CEEMD and GWO-SVM is proposed. Firstly, the complementary set empirical mode decomposition is used to decompose the original data in multiple frequency bands to obtain the intrinsic mode components that eliminate the redundant characteristics of the mixing signal, and the first three high-frequency components with more information are superimposed on the characteristic frequency band of the most line. Secondly, combined with the cross mutation operation of differential evolution algorithm, grey wolf optimizer is improved, and the parameters of support vector machine are optimized to obtain a comprehensive fault line selection model combining CEEMD and DE-GWO-SVM. The results show that the prediction model has higher line selection accuracy than other intelligent algorithm, and has advantages in high resistance grounding fault.

**[Key words]** high resistance grounding system; fault line selection; CEEMD; DE-GWO-SVM model

## 0 引言

谐振接地方式运行的配电网一旦发生单相高阻接地故障, 故障电流幅值小, 且含有大量不同频率的谐波分量, 在缆线混合线路特征复杂, 同时伴有燃弧现象<sup>[1-2]</sup>, 导致选线难度大。此外, 故障发生时输电网仍保持三相对称, 并在故障未切除情况下继续运行 1~2 h<sup>[3]</sup>。因此, 只有在故障发生时快速找到并排除故障, 才能提高电力系统的经济、稳定性。

由于故障暂态分量幅值比稳态幅值陡度大, 故障特征信息丰富, 故国内外主要基于暂态分量进行故障线路选择<sup>[4-5]</sup>。文献[6]使用 EMD 提取暂态特征, 结合 FIR 滤波进行故障选线, 但这种方法在高阻接地情况时容易出现模态混叠导致选线误判; 文献

[7]使用粒子群优化 SVM, 实现故障特征分类, 但其依赖于小波基函数的选择, 对不同的故障条件自适应差。一些研究采用混沌算法, 通过比较线路的相轨迹图来判断故障线路<sup>[8]</sup>, 但这种算法需要人为鉴定混沌相图的差异, 可能会出现误判。也有一些研究采用小波奇异熵结合支持向量机进行故障选线<sup>[9]</sup>, 支持向量机的分类效果依赖于惩罚因子、核函数等参数的预设, 设置不当则会使选线结果不理想。文献[10]使用遗传算法(GA), 并利用评价函数来判断 SVM 模型的故障诊断性能是否得到提升, 但是 GA 编码存在规则表示不准确、计算复杂度高等问题, 导致模型的训练速度较慢、性能受影响。也有文献使用粒子群算法(PSO)优化 SVM 进行故障状态识别<sup>[11]</sup>, 但是随着迭代的进行, 粒子种群的

**基金项目:** 国家自然科学基金(51867005)。

**作者简介:** 韩祥民(1997-), 男, 硕士研究生, 主要研究方向: 电力系统故障定位与诊断; 刘晓波(1964-)女, 硕士, 副教授, 主要研究方向: 电力系统保护与控制。

收稿日期: 2021-09-16

多样性会逐渐降低,出现早熟收敛现象,且算法的性能受参数取值的影响较大。

综上所述,上述算法大都考虑不够全面,故障选线的智能算法在可靠性和准确性方面存在一定不足。本文使用的 CEEMD 特征提取方法有效抑制模态混叠现象,准确提取高阻接地的故障特征。其次,通过改进灰狼算法优化 SVM,提高了选线模型的训练速度和鲁棒性,通过 CEEMD 与改进 SVM 的结合准确选出故障线路。

## 1 理论基础

### 1.1 CEEMD 方法原理

由于集合经验模态分解 (EEMD) 分解的本征模态存在一定程度的混叠现象,文献提出的互补型集合经验模态,分解 (CEEMD) 添加极性互补的白噪声<sup>[12]</sup>,很好的消除重构信号中的残余噪声,抑制了模态混叠。CEEMD 主要分为以下步骤:

**Step 1** 在原始信号  $S(t)$  成对添加极性相反的标准白噪声  $n_i(t)$  和  $-n_i(t)$ , 即:

$$\begin{cases} S_i^+(t) = S_i(t) + a_i n_i(t) \\ S_i^-(t) = S_i(t) - a_i n_i(t) \end{cases} \quad (1)$$

式中,  $a_i$  与  $Ne$  为  $n_i(t)$  的幅值和取对数,  $i = \{1, 2, \dots, Ne\}$ ; 幅值设定为  $S(t)$  标准差的 0.2 倍; 对数取 50 对<sup>[14]</sup>。

**Step 2** 用 EMD 算法分解  $S_i^+(t)$  和  $S_i^-(t)$ , 得到 IMF 序列  $I_i^+(t)$  和  $I_i^-(t)$ , 即:

$$\begin{cases} S_i^+(t) \xrightarrow{\text{EMD}} I_j^+(t) \\ S_i^-(t) \xrightarrow{\text{EMD}} I_j^-(t) \end{cases} \quad (2)$$

式中,  $j = \{1, 2, \dots, m\}$ ,  $m$  为 EMD 分解的 IMF 个数。

将 EMD 分解得到的  $I_i^+(t)$  和  $I_j^-(t)$  求取平均得到最终的 IMF 序列  $I_j(t)$ :

$$I_j(t) = 0.5(I_j^+(t) + I_j^-(t)) \quad (3)$$

**Step 3** 对剩余分量  $r(t)$  进行优化处理:

$$r(t) = S(t) - \sum_{j=1}^{m-1} I_j(t) \quad (4)$$

式中,  $r(t)$  为  $S(t)$  与上述分解重构信号之差, 判断  $r(t)$  与重构信号的正交指数, 若正交指标达不到收敛条件, 则对  $r(t)$  再进行 CEEMD 分解。

### 1.2 支持向量机回归算法原理

支持向量机回归算法 (Support Vector Machine, SVM)<sup>[13,14]</sup> 是一种兼具稀疏性和稳定性的新型分类器, 适用于小样本数据的分类。本文先用 CEEMD 提取零序电流特征后, 对提取特征进一步融合处理,

得到分类样本; 使用支持向量机对其进行分类, 提升了模型对小样本的泛化能力。

对于线性二分类问题, 输入样本数据以及分类标记表示为:

$$X = \{X_1, X_2, \dots, X_n\}, Y = \{1, -1\} \quad (5)$$

式中,  $X$  为特征空间,  $Y$  为标记值 (表示正类和负类)。为使超平面与任意最近点的几何距离最大化, 限制条件可以表示为:

$$\begin{aligned} W^T X + b &= 0 \\ y_i (W^T X + b) &\geq 1 \end{aligned} \quad (6)$$

式中,  $W$  为超平面的法向量,  $b$  为超平面的偏移量。

满足上述条件的两类边界样本向量称为支持向量。将样本分为两类: 满足  $W^T X + b > 1$  的样本向量属于正类; 满足  $W^T X + b \leq 1$  的样本向量属于负类。

对于线性不可分问题, SVM 将低维空间样本进行非线性映射, 使其可以完成复杂的分类、回归和其它任务。作为决策边界的超平面如下式:

$$W^T \varphi(X) + b = 0 \quad (7)$$

式中,  $\varphi$  为映射函数。映射函数的内积通常定义为核函数。

## 2 改进灰狼算法

### 2.1 差分进化算法

差分进化算法 (differential evolution, DE) 是一种具有优良组织、高适应和学习能力的启发式并行搜索技术, 具有收敛快、控制参数设置简单等优点<sup>[15-16]</sup>。DE 算法通过识别种群中个体间差异性, 再放大差异特征, 形成不同特征种群。算法基本原理如下:

随机产生  $N$  个个体构成算法的初始种群, 设置如下:

$$x_{i,k}(0) = i_k + \text{rand}() \cdot (u_k - l_k), k = 1, 2, \dots, N \quad (8)$$

其中,  $x_k$  为初始种群;  $\text{rand}()$  表示 0 ~ 1 之间均匀分布的随机数;  $u_k$  和  $l_k$  分别代表搜索上界、下界。

每一代搜索过程中, DE 算法种群中的个体通过变异操作, 在当前种群中的每一个个体  $x_i(g)$  都会生成一个新个体  $t_i(g)$ ,  $g$  表示种群中个体的进化代数。本文选取变异机制如下:

$$t_i(g) = x_{r1}(g) + F \cdot [x_{r2}(g) - x_{r3}(g)] \quad (9)$$

式中,  $F$  表示 DE 算法的缩放比例因子。

变异操作之后进行交叉操作, 本文采用二项交叉法。DE 算法的交叉公式如下:

$$v_{i,j}(g) = \begin{cases} t_{i,j}(g), & r < cr \text{ 或 } j = rnd \\ x_{i,j}(g), & \text{其他} \end{cases} \quad (10)$$

式中,  $rnd$  表示均匀分布的整数,  $cr$  表示交叉概率因子。先对每一个变量都生成一个  $0 \sim 1$  之间均匀分布的随机数  $r$ , 如果满足  $r < cr$  的条件, 接受目标个体的对应分量, 否则保留当前个体的对应分量。

最后进行贪婪选择操作, 即从测试个体  $x_i(g)$  和当前个体  $v_i(g)$  两者中选择较好的个体进入下一代搜索。DE 算法的贪婪公式如下:

$$x_i(g+1) = \begin{cases} v_i(g), & f[v_i(g)] \leq f[x_i(g)] \\ x_i(g), & \text{其他} \end{cases} \quad (11)$$

通过贪婪选择机制, 可以确保下一代种群中的个体优于当前种群个体, 提高种群的平均性能, 使其逐步达到最优解。标准差分进化算法流程如下:

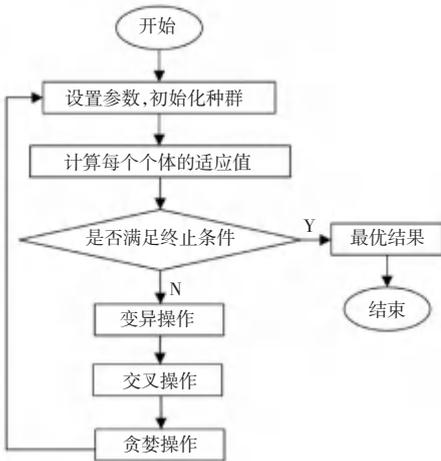


图 1 DE 算法流程图

Fig. 1 DE algorithm flow chart

## 2.2 灰狼算法

灰狼优化 (Grey Wolf Optimizer, GWO) 算法, 是学习自然界灰狼种群觅食的仿生学算法<sup>[17]</sup>, 具有效率高、收敛快的特点, 具备强大的全局搜索能力。但也存在新代种群缺乏多样性, 陷入局部最优解的不足。GWO 的计算过程主要分为包围猎物和狩猎两个步骤。

灰狼种群等级由上至下分为领导狼  $\alpha$ 、围捕、狩猎狼  $\beta$  和  $\delta$ 、 $\omega$  狼。在 GWO 算法中, 狩猎行为由  $\alpha$  狼带领,  $\beta$  狼和  $\delta$  狼协助,  $\omega$  狼跟随。 $\omega$  搜索遵循随机驱动机制, 可以用下面的公式进行数学模拟:

$$\begin{cases} \vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \\ \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \\ \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \end{cases} \quad (12)$$

式中,  $\vec{X}_\alpha, \vec{X}_\beta, \vec{X}_\delta$  为前 3 位最优解;  $\vec{X}$  为  $\omega$  狼的当前位置;  $\vec{C}_1, \vec{C}_2, \vec{C}_3$  为狩猎系数。 $\omega$  狼搜索最终位置向量由下式决定:

$$\vec{X}(i) = \frac{1}{3} [(\vec{X}_\alpha - \vec{A}_1 \vec{D}_\alpha) + (\vec{X}_\beta - \vec{A}_2 \vec{D}_\beta) + (\vec{X}_\delta - \vec{A}_3 \vec{D}_\delta)] \quad (13)$$

式中,  $\vec{A}_1, \vec{A}_2, \vec{A}_3$  表示任意系数向量。

### 2.3 差分进化改进灰狼算法位置更新原则

综合以上两种算法的优缺点, 提出一种更为高效的差分进化灰狼混合优化算法 (MGWO) 来提高全局搜索能力。在 GWO 算法中引入 DE 非线性控制调整策略以及位置更新规则, 提升算法的勘探与开发性能, 避免局部最优停滞现象的发生。新改进的位置更新规则如下所示:

$$\vec{X}(i) = \vec{c}_1 \cdot \vec{X}_c + F \cdot \vec{c}_2 \cdot (\vec{X}_a - \vec{X}_b) \quad (14)$$

式中,  $\vec{c}_1, \vec{c}_2$  为随机向量,  $F$  为缩放因子。

改进算法流程如下:

- (1) 设置变量的维度与求解范围, 初始化灰狼种群。
- (2) 计算灰狼种群的适应度值, 创建一头人工狼, 用于记录迭代过程中最优灰狼个体的位置。
- (3) 对灰狼种群的适应度值进行排序, 将适应度值最大的前 3 个个体直接选为  $\alpha$ 、 $\beta$  和  $\delta$  狼。判断  $\alpha$  狼与人工狼适应度值, 取值较高的个体作为最优灰狼个体。

(4) 初始化随机参数  $\vec{A}_1, \vec{A}_2, \vec{A}_3$  与  $\vec{c}_1, \vec{c}_2$  的值。

(5) 遍历种群及变量维度, 根据式 (14) 来计算适应度, 更新下一代的待定灰狼种群。

(6) 利用  $\alpha$ 、 $\beta$  和  $\delta$  狼的位置获得变异灰狼种群。

(7) 遍历种群及变量维度, 对待定灰狼种群和变异种群执行交叉操作, 获得中间种群。

(8) 遍历种群, 对待定灰狼种群和中间种群执行选择操作, 更新下一代灰狼种群。

(9) 判断算法是否达到迭代的终止条件; 如果达到终止条件, 则搜索结束, 并输出人工狼及其对应的适应度值作为最优解和最优适应度值。否则, 返回到步骤 (5) 继续迭代。

MGWO 算法的流程如图 2 所示:

利用 DE 算法的交叉混合对狼群进行交叉操作, 产生新的杂交灰狼个体, 并对其位置进行更新, 选出新的  $\alpha$  狼、 $\beta$  狼和  $\delta$  狼。最后通过基于贪婪算法

的选择操作,对狼群个体位置进行更新,反复迭代更新,直到从中选出最优目标函数值输出。该混合算法既提高了全局搜索能力,又能有效避免早熟停滞、陷入局部最优的缺陷。

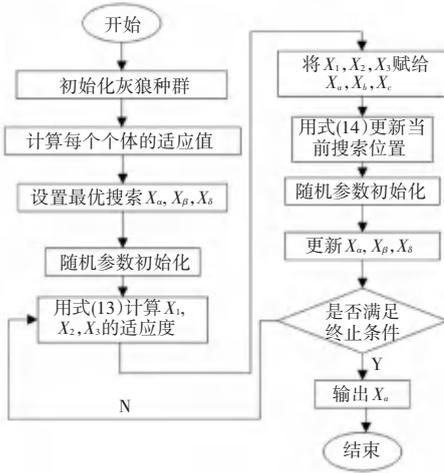


图 2 MGWO 算法流程图

Fig. 2 MGWO algorithm flow chart

图 3 为 Griewank 函数在区间  $[-100, 100]$  的波形图,由图可知该函数存在一个全局最小值。

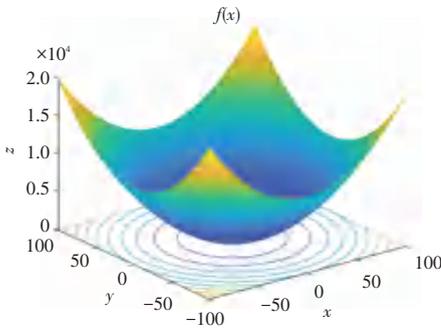


图 3 测试函数图像

Fig. 3 Test function image

图 4 展示了 MGWO 算法、GWO 算法、PSO 算法和飞蛾优化算法 (MFO) 对 Griewank 函数寻优的进化曲线。由图可见, MGWO 算法的进化曲线在迭代前期有着明显的变化率,收敛性能最佳。

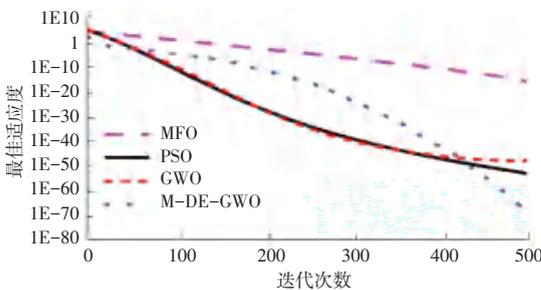


图 4 各类优化算法适应度曲线

Fig. 4 Fitness curves of optimization algorithms

表 1 记录了函数经各算法 30 次测试后取得的最佳、平均、最差适应度值以及均方误差。由此可知, MGWO 算法的最佳、平均以及最差适应度值均优于 GWO 算法、PSO 算法和 MFO 算法,并且能收敛至全局最优解,具有很强的收敛能力、较快的收敛速度。

表 1 各算法的测试结果

Tab. 1 Test results of each algorithm

测试结果	MFO	PSO	GWO	M-DE-GWO
Best	9.27E-19	1.66E-51	6.06E-56	7.64E-75
Average	1.84E-16	1.89E-48	2.45E-53	1.51E-69
Worst	3.87E-17	5.98E-49	5.87E-54	1.51E-70
MES	5.22E-17	6.16E-49	6.88E-54	3.50E-70

### 2.4 CEEMD-GWO-SVM 选线模型

文中建立的故障选线模型如图 5 所示。将线路终端采集到的零序电流进行 CEEMD 分解,得到高频故障特征,再将故障特征数据集用来训练测试 DE-GWO-SVM 选线模型。具体步骤如下:

**步骤 1** 配电网发生高阻接地故障时,采集暂态零序电流,取故障后数据进行分析。

**步骤 2** 采用 CEEMD 方法,对每条线路的暂态零序电流进行分解,得到各阶 IMF。

**步骤 3** 将高频分量占比较高的 IMF 相加,求得各线路的特征频段。

**步骤 4** 将各线路的特征频段输入训练后的 DE-GWO-SVM 模型,判断出故障线路。

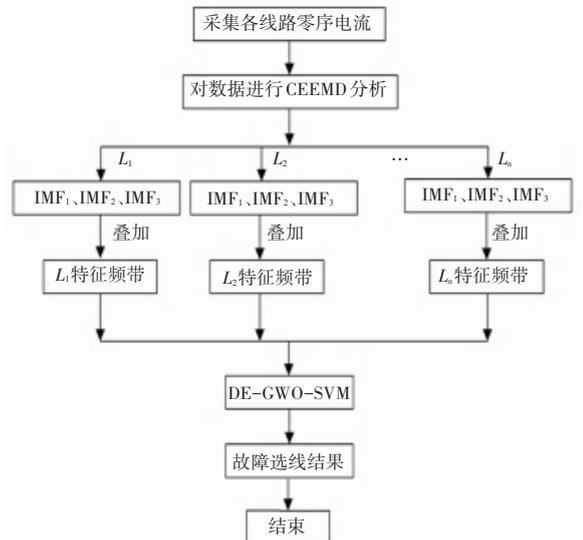


图 5 模型的基本结构

Fig. 5 Basic structure of the model

### 3 仿真实例

#### 3.1 模型搭建

本文采用中国西部某 110 kV 变电站 10 kV 侧 #1 段母线及其 6 回馈线实际参数及负荷水平, 基于 MATLAB 仿真平台建立模型, 搭建含有 6 条出线的 10 kV 配电网高阻接地故障模型, 如图 6 所示。采样率为 100 kHz。

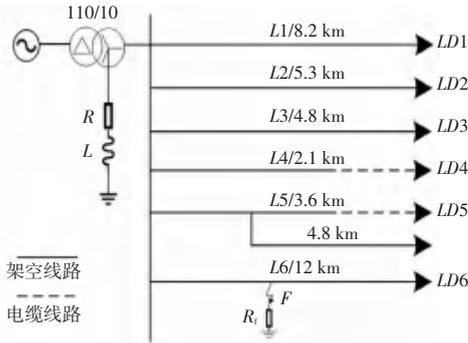


图 6 模型的基本结构

Fig.6 Basic structure of the model

根据图 6 随机选择参数, 当馈线 6 在故障合闸角为  $30^\circ$ , 故障电阻为  $1\ 500\ \Omega$ , 在距离线路首端 6 km 处, A 相发生单相接地故障时, 检测母线的馈线零序电流。图 7 为各出线的零序电流曲线。

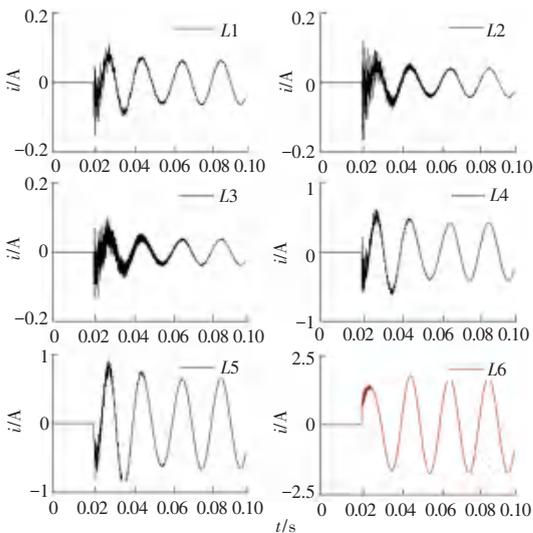
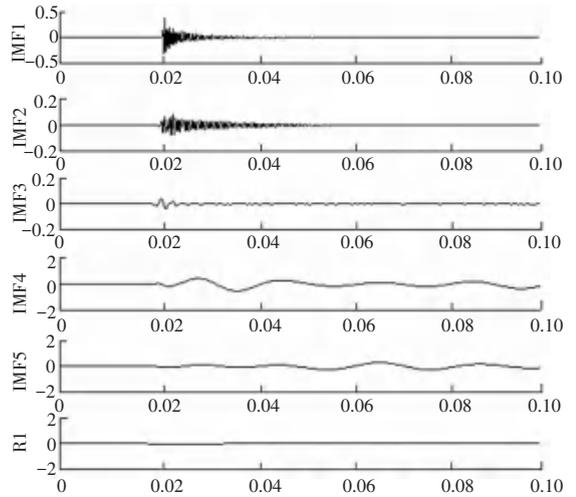


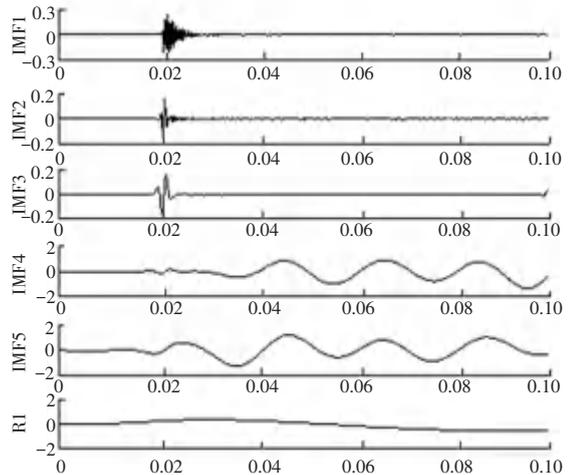
图 7 各馈线零序电流波形

Fig. 7 Zero sequence current waveform of each feeder

如图 7 所示, 故障线路 L6 的首半波暂态零序电流波形较正常线路有较大的差异, 故可进一步通过 CEEMD 提取并放大其故障特征。对其中线缆混合线路 L4 和故障架空线路 L6 的故障零序电流进行 CEEMD 分解, 分解结果如图 8 所示。



(a) 正常线路 L4 零序电流分解



(b) 故障线路 L6 零序电流分解

图 8 部分馈线零序电流分解图

Fig. 8 Diagram of zero sequence current of some feeders

#### 3.2 改进 GWO-SVM 选线模型测试

按照 3.1 节中的仿真模型, 分别模拟接地电阻为  $1000\ \Omega$ 、 $1500\ \Omega$ 、 $2000\ \Omega$  等 3 种高阻接地情况; 初始故障角取  $0^\circ$ 、 $30^\circ$ 、 $60^\circ$ 、 $90^\circ$  共 4 种不同角度; 故障发生位置取距离母线 10%、30%、50%、70%、90% 共 5 个位置; 6 条馈线共  $6 \times 3 \times 4 \times 5 = 360$  初始组样本。提取零序电流值进行 CEEMD 变换后, 再提取特征向量。分别采用 CEEMD-MGWO-SVM、EEMD-PSO-SVM 和 GWO-SVM 这 3 种分类模型, 基于上述样本集, 选择每条出线的 50 组故障作为训练集, 剩余 10 组作为测试集, 出线 1 故障时即为第 1 种分类结果, 以此类推, 出线 6 故障时为第 6 种分类结果。3 种分类模型的测试结果分别如图 9、图 10 和图 11 所示。

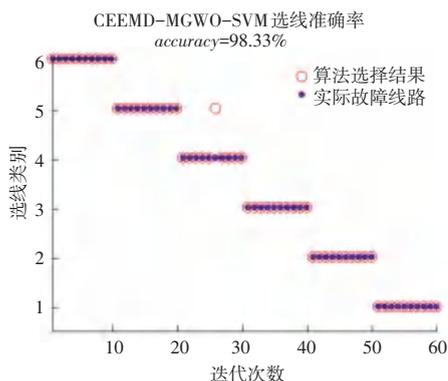


图9 CEEMD-MGWO-SVM 选线结果

Fig. 9 CEEMD-MGWO-SVM exploded line selection results

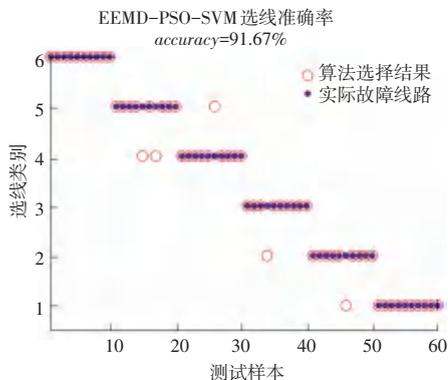


图10 EEMD-PSO-SVM 选线结果

Fig. 10 EEMD-PSO-SVM exploded line selection results

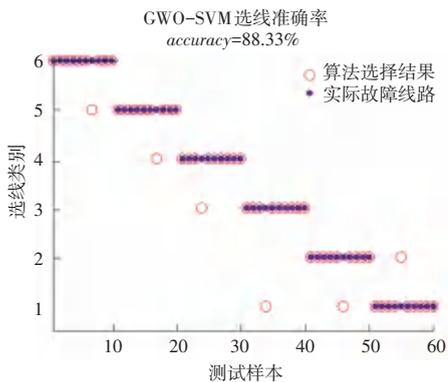


图11 GWO-SVM 选线结果

Fig. 11 GWO-SVM exploded line selection results

通过对比图9~图11的结果可见,本文改进算法的选线准确率为98.33%,仅在缆线混合线路L4出现一次误判,故障选线准确度高于其它结合SVM算法模型。

## 4 结束语

本文提出了一种基于CEEMD分解的改进GWO优化SVM故障选线模型。通过建立6条馈线的谐振接地系统模型,设置各种类型的故障情况,获取零序电流信号,并通过CEEMD提取特征向量的

高频频带;当高阻接地故障特征不明显时,经过训练的SVM分类器依然可以进行有效识别。通过与同类分类器对比实验,在本文提出的MGWO-SVM模型训练和测试下,所提方法有更高的选线精度。

本文提出的方法虽然在以配电网实际参数搭建的模型中取得了良好的效果,但对于CEEMD分解的参数确定方面还存在不足,对于实际配电网故障零序电流的特征提取也有待进一步研究。

## 参考文献

- [1] 韩笑, 罗维真, 王春衢. 基于同步挤压小波变换的配电网单相高阻接地故障选线[J]. 科学技术与工程, 2019, 19(15): 150-156.
- [2] 庄胜斌, 缪希仁, 江灏, 等. 基于改进欧氏-动态时间弯曲距离的谐振接地配电网单相高阻接地故障选线方法[J]. 电网技术, 2020, 44(1): 273-281.
- [3] Energy. Norwegian University of Science and Technology (NTNU) Reports Findings in Energy (Co-Simulation of Smart Distribution Network Fault Management and Reconfiguration with LTE Communication)[J]. Energy Weekly News, 2018:
- [4] 李景禄, 曾祥君, 杨廷方, 等. 配电网接地选线方式的研究与探讨[J]. 高电压技术, 2004(2): 22-23.
- [5] XU Yan, LIU Jingyan, FU Yuan. Fault-line selection and fault-type recognition in DC systems based on graph theory[J]. Protection and Control of Modern Power Systems, 2018, 3:
- [6] 闫严. 基于EMD与FIR滤波的小电流接地故障选线方法[J]. 电气技术, 2017(4): 56-60.
- [7] 董爱华, 张小洁. 基于PSO-SVM的小电流接地故障选线方法[J]. 计算机工程与设计, 2015, 36(7): 1886-1890.
- [8] 侯思祖, 郭威. 基于改进EEMD与混沌振子的配电网故障选线[J]. 仪器仪表学报, 2019, 40(4): 77-87.
- [9] 刘天明, 刘建锋, 肖贤贵, 等. 基于小波奇异熵和支持向量机的配电网单相接地选线新方法[J]. 电网与清洁能源, 2017, 33(2): 14-20.
- [10] 松江·卡日, 高文胜, 张紫薇, 等. 基于支持向量机和遗传算法的变压器故障诊断[J]. 清华大学学报(自然科学版), 2018, 58(7): 623-629.
- [11] 时培明, 梁凯, 赵娜, 等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断[J]. 中国机械工程, 2017, 28(9): 1056-1061, 1068.
- [12] 郑近德, 程军圣, 杨宇. 改进的EEMD算法及其应用研究[J]. 振动与冲击, 2013, 32(21): 21-26, 46.
- [13] 崔建明, 刘建明, 廖周宇. 基于SVM算法的文本分类技术研究[J]. 计算机仿真, 2013, 30(2): 299-302, 368.
- [14] 房乐楠, 何腾鹏, 刘宇红. 一种改进型PSO算法在SVM参数寻优中的应用[J]. 电子科技, 2018, 31(6): 17-19, 31.
- [15] 丁青锋, 尹晓宇. 差分进化算法综述[J]. 智能系统学报, 2017, 12(4): 431-442.
- [16] 王凤领. 基于差分进化的加权k-means算法研究[J]. 智能计算机与应用, 2020, 10(6): 238-242.
- [17] 熊晔, 毛剑琳. 面向缓冲区容量有限的多载AGV系统调度研究[J]. 电子科技, 2018, 31(12): 72-77.