

DOI: 10.13382/j.jemi.B2104179

瞬时特征下极限学习机在接地故障诊断中的应用*

王毅¹ 李曙¹ 李松浓² 李杰² 杨芾藜³ 郑可³

(1. 重庆邮电大学通信与信息工程学院 重庆 400065; 2. 国网重庆市电力公司电力科学研究院 重庆 400014;

3. 国网重庆市电力公司营销服务中心 重庆 400014)

摘要:为消除小电流系统下接地故障诊断准确性受系统中性点接地方式、故障类型以及故障位置等因素的影响,分析了系统各类单相接地故障下的零序电流,提出了一种基于改进的希尔伯特-黄变换和极限学习机的接地故障检测方法。首先用小波变换对信号进行多频带划分,再根据对地电容的充放电特性筛选出的特征频带并进行希尔伯特-黄变换,得到各条线路零序电流的瞬时能量特征,最后利用灰狼算法和粒子群算法对极限学习机进行多层次优化,得到同时具有故障类型识别和选线功能的分类器。设计一款基于数字故障指示器采集和主站数据处理的故障检测系统。经测试,该方法能准确判断故障类型并完成选线,准确度达到90%以上。

关键词:单相接地故障;故障类型识别;故障选线;希尔伯特黄变换;极限学习机;灰狼算法

中图分类号: TM77 **文献标识码:** A **国家标准学科分类代码:** 510.4010

Application of ground fault diagnosis based on extreme learning machine under instantaneous characteristics

Wang Yi¹ Li Shu¹ Li Songnong² Li Jie² Yang Fuli³ Zheng Ke³

(1. Communication and Information Engineering College, Chongqing University of Posts and Telecommunications,

Chongqing 400065, China; 2. Chongqing Electric Power Research Institute, Chongqing 400014, China;

3. Postdoctoral Workstation of the Chongqing Electric Power Corporation, Chongqing 400014, China)

Abstract: In order to eliminate the influence of grounding mode, fault type and fault location on the accuracy of ground fault diagnosis in low current system. By analyzing the zero sequence current of all kinds of single-phase ground faults in this system, a single-phase ground fault detection method was proposed on the basis of the improved Hilbert-Huang transform (HHT) and Extreme learning machine (ELM). This method firstly used wavelet transform (WT) for multiband signal. Then HHT was performed on the characteristic signal that was selected by the charging and discharging characteristics of the ground capacitance to obtain the instantaneous energy of the zero sequence current of each line. Finally, gray wolf optimization (GWO) and particle swarm optimization (PSO) were used to optimize the ELM model to obtain the GWO-PSO-ELM model with fault type recognition and line selection functions. A fault detection system based on digital fault indicator (DFI) acquisition platform and master station data processor is designed. The test results show that this method can accurately judge the fault type and complete line selection, and the accuracy reaches more than 90%.

Keywords: single-phase ground fault; fault type identification; fault line selection; Hilbert-Huang transform; extreme learning machine; grey wolf optimizer

0 引言

我国的中压配电网大多数为小电流接地系统。在小

电流接地系统发生单相接地故障的时候,其故障电流主要来源于对地电容电流,这种小电流一般对设备损害较小,另外三相电压由于继续保持对称性,使得该系统不易跳闸,能带故障继续运行。但是长期的过电压会对系统

的绝缘水平提出不小的挑战,再加上配电网结构日益复杂,频发的单相接地故障已成为最大的安全隐患^[1]。由于故障电流较小,各国对于系统故障的准确辨识迄今为止尚未得到很好的解决。确定故障类型并正确选线,有利于供电部门及时获取故障信息并进行处理。

现阶段单相接地故障选线和定位依然是国内外研究的重点,但是故障类型往往反映了故障发生的原因,准确的故障识别是快速采取针对性抢修措施和制定隐患治理及故障防范措施的基础。同时,故障识别也是正确选线的前提,两者是相辅相成的。近年来,越来越多的人投入到故障类型识别的研究。文献[2]根据故障分量均方根及欧氏距离,用决策树和支持向量机将故障分为单相接地、两相接地和多相短路故障;文献[3-4]分析了接地故障的伏安特性,计算稳定时刻过渡电阻,区分了电弧接地、金属接地和高阻接地故障;文献[5]从多个层次对故障类型进行了更为细致的分类和定义,设计了具有4层递进关系的接地故障分类流程;文献[6]提取了录波数据的时频和电弧特征,对不同原因的故障进行了识别;此外文献[7-8]还将机器学习用于这类非稳态故障,构造了具有良好辨识能力的分类器。

以上研究在单相接地故障检测中有一定成效,但各类因素导致故障类型划分没有统一标准,部分故障特征并不能对故障识别产生实质上的影响,这对已经确定的判别流程或者模型造成了不小的干扰,同时由于消弧线圈的补偿作用,谐振接地系统的故障检测一直尚未得到很好解决。

针对以上问题,为筛选关键特征建立简单高效的分类网络,同时实现故障识别和选线,提出一种基于改进希尔伯特-黄变换(Hilbert-Huang transform, HHT)的特征提取方法,并结合经灰狼算法(gray wolf optimizer, GWO)和粒子群算法(particle swarm optimizer, PSO)优化的极限学习机(extreme learning machine, ELM)进行分类,识别出故障类型和发生故障的线路。搭建接地故障检测系统,通过带有通信功能的数字故障指示器(digital fault indicator, DFI)完成信号采集,并送入主站系统实现数据处理,最终得到检测结果并验证故障诊断方法的可行性。

1 单相接地故障特征分析

1.1 故障类型分析

一般根据故障是否需要进行人工修复将接地故障分为瞬时性接地故障和永久性接地故障。而永久性接地故障往往是造成系统故障进一步恶化的原因,因此本文对该类故障进行重点考察。

配电网的永久性接地故障主要包括低阻(金属)性接地故障、高阻性接地故障、稳定电弧接地故障和间歇电

弧接地故障等类型^[5]。

1.2 故障选线判据

现阶段单相接地选线技术不断发展,最常见的故障选线方法大致分为稳态特征法和暂态特征法两种。稳态方法有零序电流比幅比相法,有功无功法和多次谐波法,暂态方法有能量法、首半波法、小波选线法^[9]和经验模态法^[10-11]。本文主要的研究对象为零序电流,因为谐振接地系统在发生单相接地故障时故障电流较小,且零序电流可能出现极性反转,因此稳态特征法具有较大的局限性。由于暂态零序分量远大于稳态过程,同时暂态过程的高频分量不受补偿电流的影响,暂态特征法成为了接地故障检测的首选。以一个三线路系统为例,当线路1发生不同类型接地故障时,各个线路的零序电流如图1所示。

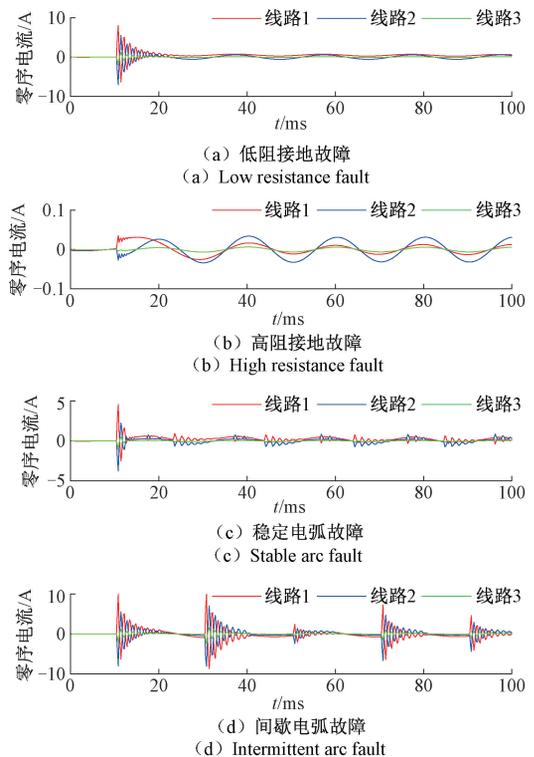


图1 线路1发生单相接地故障的各线路零序电流
Fig. 1 The zero sequence current of each line when a single-phase ground fault occurs in line 1

2 基于 WT-HHT 的特征提取

2.1 传统的 HHT

希尔伯特(Hilbert)变换在很多领域都有广泛应用,但缺点是只能处理由单一频率成分构成的信号。因此HHT方法引入经验模式分解(empirical mode decomposition, EMD),将信号分解成具有实际物理意义的多个单频固有模式分量(intrinsic mode function, IMF),

此时再进行 Hilbert 变换得到瞬时信号将为后续的故障识别和选线提供特征^[12]。

EMD 过程往往是一个筛选过程,需要满足如下两个条件:1)极值点的数目与零点的数目相同或者相差为 1;2)上极值和下极值包络的局部均值为 0。直到获得所有时间频率逐次递减的 IMF 分量。

信号 $X(t)$ 的 Hilbert 变换公式如下:

$$Y(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{X(\tau)}{t - \tau} d\tau \quad (1)$$

$Z(t)$ 称为 $X(t)$ 的解析信号, $X(t)$ 和 $Y(t)$ 构成其实部和虚部:

$$\begin{cases} Z(t) = X(t) + jY(t) = \alpha(t)e^{j\theta(t)} \\ \alpha(t) = \sqrt{X^2(t) + Y^2(t)} \\ \theta(t) = \arctan \frac{Y(t)}{X(t)} \end{cases} \quad (2)$$

同时定义瞬时频率为 $\omega(t) = d\theta(t)/dt$, 然后对每一个 IMF 分量用 Hilbert 变换进行谱分析,得到的 Hilbert 时频谱,简称为 Hilbert 谱:

$$H(\omega, t) = \text{Re} \left[\sum_{i=1}^n \alpha_i(t) \exp(j \int \omega_i(t) dt) \right] \quad (3)$$

在时域和频域上分别对 $H(\omega, t)$ 进而积分还可以得到 Hilbert 边际谱和瞬时能量谱:

$$\begin{cases} H(\omega) = \int_{-\infty}^{+\infty} H(\omega, t) dt \\ E(t) = \int_{\omega} H^2(\omega, t) d\omega \end{cases} \quad (4)$$

2.2 基于 WT 改进的 HHT

根据研究,若待分析的信号频带太宽,EMD 分解时常伴随着模态混叠现象^[13],而且 IMF 分量的低频部分本身就存在一些不足以反映故障特征的虚假分量,会对故障识别造成干扰。同时这些包含故障信息的高频成分往往能量较低,很难分离。

提前确定特征频带可以有效改善对信号的分析能力,但在实际电网中,信号的频谱受中性点接地方式、故障相角、过渡电阻大小和故障点距离影响较大。不同原因引起的线路故障使得特征频带漂移不定,只分析某一特定频段实现所有故障的分类辨识,辨识结果可能与实际情况具有较大偏差。

相比于传统的带通滤波器,小波变换 (wavelet transform, WT) 可以将信号的频带进行多层划分,在合适的频段上进行 EMD 和 Hilbert 变换可以使同一类故障在不同条件下拥有最为突出的特征。对于特征频带的选取,小电流接地系统的暂态电流集中在 300~3 000 Hz,此时消弧线圈的阻抗远大于线路对地容抗,一般忽略^[14],因此故障电流主要包含各线路非故障相的电容充电信号,故障相的电容放电信号和工频分量,其中充电信号占

主导,所以故障信号暂态能量主要集中在电容充电频段。本文选取 db5 小波对信号进行 5 层分解,采样频率设为 5 000 Hz,由奈奎斯特采样定理可知各分量所含的频带为:

$$\begin{cases} A_i(n) = [0, 2^{-(i+1)} f_s] \\ D_i(n) = [2^{-(i+1)} f_s, 2^{-i} f_s] \end{cases} \quad (5)$$

式中: f_s 为采样频率; $A_i(n)$ 为低频分量; $D_i(n)$ 为高频分量。

通过分析图 2 所示各类故障零序电流的瞬时频率谱,发现随着零序电流方向的变化,线路对地电容一直处于充放电的交替状态,且放电过程故障暂态分量的频率普遍大于充电过程。因此在筛选特征频带时,先根据暂态分量频率主成分的最大和最小值划分充放电区,再将充电区瞬时频率的平均值作为中心频率,最后将充电中心频率对应的小波频段作为特征频带,结果如表 1 所示,故障信号的频率主要集中在 D2 和 D3 分量上,对应的频带分别是 625~1 250 Hz 和 312.5~625 Hz。

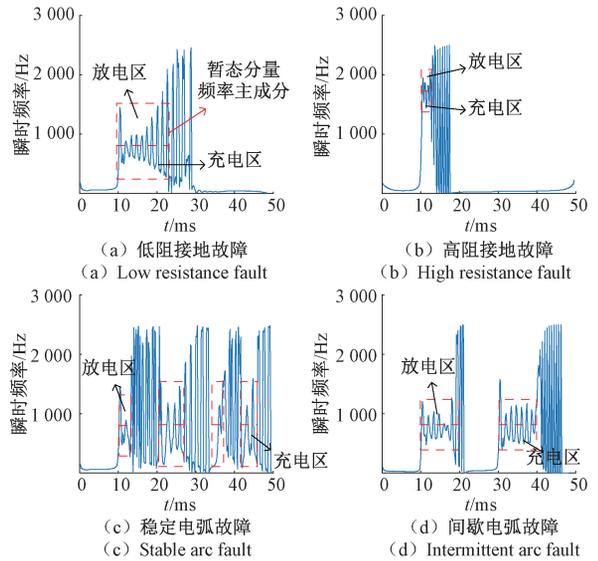


图 2 各类单相接地故障下零序电流的瞬时频率
Fig. 2 Instantaneous frequency of zero sequence current under various single-phase ground faults

表 1 特征频带筛选结果

Table 1 The results of characteristic frequency band selection

接地故障类型	暂态分量主频段/Hz	充电中心频率/Hz	小波频段筛选
低阻接地故障	[305, 1 717]	634. 7	D2
高阻接地故障	[870, 2 050]	1 098. 4	D2
稳定电弧故障	[88, 1 726]	510. 2	D3
间歇电弧故障	[289, 1 577]	618. 1	D3

2.3 特征向量的选取

能量法是故障选线的常用方法^[15],而 HHT 方法得到的又是信号的时间-频率-能量分布,因此可以将瞬时能量作为特征函数。

由于电弧型故障具有燃弧的间歇性,为了在一定时间裕度内筛选各种故障的特征,将故障发生前后零序电流的 2.5 个周期作为特征函数。根据图 1 所示,不同类型单相接地故障暂态过程持续时间均不同,且故障线路的暂态幅值大于非故障线路。因此利用瞬时能量的幅值大小和时间分布可同时达成故障识别和选线的目标。为实现后续神经网络的分类,取 3 条线路共 15 个半周期的归一化平均瞬时能量作为特征向量,部分数据如表 2 所示。

表 2 线路 1 发生单相接地故障各线路半周期的归一化平均瞬时能量

Table 2 The normalized mean instantaneous energy of half period of each line when a single-phase ground fault occurs in line 1

故障类型	线路编号	半周期的归一化平均瞬时能量				
		1	2	3	4	5
低阻 接地 故障	1	0.138	1	0.001	1.1×10^{-5}	2.9×10^{-4}
	2	0.012	0.086	1.3×10^{-4}	0	6.3×10^{-6}
	3	0.068	0.501	8.1×10^{-4}	5.1×10^{-6}	1.4×10^{-4}
高阻 接地 故障	1	0.699	1	2.9×10^{-6}	2.4×10^{-5}	2.9×10^{-4}
	2	0.065	0.103	1.4×10^{-6}	0	6.5×10^{-5}
	3	0.330	0.336	1.7×10^{-4}	9.4×10^{-6}	3.0×10^{-4}
稳定 电弧 故障	1	0.148	1	0.122	0.044	0.107
	2	0.010	0.090	0.007	0	0.004
	3	0.067	0.478	0.058	0.019	0.053
间歇 电弧 故障	1	0.012	0.120	1	0.008	0.756
	2	4.3×10^{-4}	0.010	0.082	0	0.060
	3	0.006	0.059	0.509	0.003	0.389

3 基于 GWO 与 PSO 联合优化的 ELM

极限学习机是一种改进的前馈神经网络,与传统的分类器相比,它结构简单,学习速度极快且准确度高,简单的参数调整算法使其拥有很强的可移植性,能对电力系统故障进行及时响应。隐含层节点参数将随机生成,在训练过程中不用反复迭代,只要知道输入与输出矩阵即可求出使误差函数最小的输出权重。但是由于 ELM 的初始化参数随机生成,同时需要提前设置较多的隐含层神经元个数以达到较好的输出结果,会使得隐含层神经元冗余,降低算法的识别能力。

3.1 PSO-ELM

许多研究者在改进 ELM 时都引入各类智能算法^[16],本文采用改进的粒子群算法对隐含层输入权重和阈值进行寻优,该方法可以提高 ELM 的分类准确率,同

时该方法避免了优化过程中的局部最优并提高了 PSO 的收敛速度。具体步骤如下。

1) 初始化粒子群。假设群体规模为 M ,定义个体的位置 $G_M = [\tau_1, \tau_2, \dots, \tau_D, b_1, b_2, \dots, b_L]$ 和速度 $V_M = [v_1, v_2, \dots, v_{(D+1) \times L}]$,其权值 $\tau_i = [\tau_{i1}, \tau_{i2}, \dots, \tau_{iL}]$,阈值为 b_i ; L 为隐含层节点数; D 为输入向量维数,该优化问题是在一个 $(D+1) \times L$ 维空间进行寻优。然后确定此时的个体极值 p_{best} 、全局极值 g_{best} 和对应的种群编号。

2) 计算粒子的适应度。对于 N 个不同的随机训练样本 (x_j, t_j) ,训练神经网络:

$$\sum_{i=1}^L \beta_i g_i(\omega_i \cdot x_j + b_i) = t_j \quad (6)$$

式中: $i=1, 2, \dots, L; j=1, 2, \dots, N; x_j = [x_{j1}, x_{j2}, \dots, x_{jD}]^T$; $t_j = [t_{j1}, t_{j2}, \dots, t_{jK}]^T$, K 为输出向量维数; x_j 和 t_j 分别表示训练样本的输入与期望输出; $g(x)$ 为隐含层的激活函数; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{iK}]$ 为隐含层第 i 个结点与 K 个输出节点的连接权值,为要求解的量。而 ω_i 是向量 $[\tau_1, \tau_2, \dots, \tau_D]$ 重新构成的向量。将式(6)表示为矩阵形式:

$$H\beta = T \quad (7)$$

其中,隐含层的输出矩阵:

$$H(\omega_i, b_i, x_j) = \begin{bmatrix} g_1(\omega_1 \cdot x_1 + b_1) & \dots & g_L(\omega_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ g_1(\omega_1 \cdot x_N + b_1) & \dots & g_L(\omega_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \quad (8)$$

期望输出矩阵 T 为 t_j 构成的 $N \times K$ 维矩阵;输出权重 β 是可以由广义逆运算得到的 $L \times K$ 维矩阵。

3) 计算每个粒子的适应度。记录每次迭代种群中的个体极值 p_{best} 和全局极值 g_{best} 。这里将预测输出与期望输出之间的均方误差作为粒子的适应度 F :

$$F_{MSE} = \frac{1}{N} \sum_{i=1}^N (t'_i - y'_i)^2 \quad (9)$$

式中: t'_i 为每个粒子对应的第 i 个样本的标量预测值; y'_i 为该样本的标量期望值。

4) 更新粒子的位置 G_M 和速度 V_M :

$$\begin{cases} V_M = w \cdot V_M + c_1 r_1 (p_{best} - G_M) + c_2 r_2 (g_{best} - G_M) \\ G_M = G_M + V_M \end{cases} \quad (10)$$

式中: w 为惯性权重; c_1 和 c_2 是学习因子; r_1 和 r_2 是均匀分布在 $[0, 1]$ 的随机数。传统 PSO 的学习因子是固定的,但是 c_1 和 c_2 假如在迭代过程一直保持较大的值会影响个体和全局搜索能力,因此这里对其定义如下:

$$c_i = c_{is} - (c_{is} - c_{in}) \frac{t}{t_{max}} \quad (11)$$

式中: c_{is} 和 c_{in} 分别表示上一次学习因子和当前学习因子; t 和 t_{max} 表示当前迭代次数和最大迭代次数。

5) 如果达到目标误差或者最大迭代次数将结束优

化,否则返回步骤 3)继续迭代。最后得到优化后的权值和阈值 G_{best} ,并可以计算输出层权重矩阵 β_{best} 。

3.2 GWO 优化的 PSO-ELM

实际在使用 ELM 前,需要确定隐含层节点,过多的隐含层神经元会直接增加结构和模型的复杂度,冗余的神经元还会降低算法的泛化能力,因此为解决这个问题,将 GWO 植入到 PSO-ELM 算法中。GWO 于 2014 年提出,是一种模拟狼群捕食行为的智能算法,它具有操作简单、调节参数少、全局搜索能力强等优点。而且被证明 GWO 相比传统的智能算法,效率更高^[17]。GWO 起始于狼群的狩猎技巧,通过一群具有等级制度的灰狼,逐渐接近并包围猎物,最终完成对潜在猎物(最优解)的捕获^[18]。对于 ELM 隐含层神经元个数的优化具体步骤如下。

1) 初始化狼群,并确定社会等级。对于含有 N 匹狼的总群,位置定义如下 $X = [x_1, x_2, \dots, x_N]^T$, x_i 是代表隐含层节点的随机正整数,同时设置最大迭代次数 M 和 X 的上下界。根据适应度高低确定社会等级从高到低的 α 、 β 、 δ 和 ω 狼,记录拥有最高等级的灰狼位置 x_α 、 x_β 和 x_δ 。此时适应函数 $F(x_i)$ 依然可以用式(9)中预测输出与期望输出之间的均方误差来表示。

2) 跟踪包围猎物。灰狼搜索猎物时会逐渐靠近并包围它,而等级最高个体 x_α 、 x_β 和 x_δ 将作为当次迭代的最优种群,指导位置的更新:

$$\begin{cases} D_{pi}(t) = |C \cdot x_p(t) - x_i(t)| \\ x_{pi}(t+1) = x_p(t) - A \cdot D_{pi}(t) \\ a(t) = 2 - 2t/M \end{cases} \quad (12)$$

式中: t 为当前迭代的次数; A 和 C 是系数因子,其中 $A = 2ar_1 - a$; $C = 2r_2$; a 是从 2 线性递减到 0 的收敛因子, r_1 和 r_2 是 $[0, 1]$ 的随机向量; x_p 表示全局的最优解,分别代表了 x_α 、 x_β 和 x_δ ; $D_{pi}(t)$ 表示个体分别到 α 、 β 和 δ 狼的距离; x_{pi} 为第 i 个个体在最优个体指导下的更新值,分别代表了 $x_{\alpha i}$ 、 $x_{\beta i}$ 和 $x_{\delta i}$ 。

3) 狩猎过程。由于系数 A 的取值范围由 $[-2, 2]$ 逐渐变为 0,使得灰狼由分散到集中地搜索某个区域的猎物,此时灰狼的位置为三次指导下更新位置的平均值:

$$x_i(t+1) = \frac{x_{\alpha i}(t+1) + x_{\beta i}(t+1) + x_{\delta i}(t+1)}{3} \quad (13)$$

4) 更新完所有的个体即算完成对这 N 个隐含层神经元的 1 次遍历,当满足结束条件时退出,此时头狼 α 在整个种群里拥有高地位,它将决定隐含层节点数 $I_{best} = x_\alpha$ 。

5) 在已知最优隐含层节点数条件下,完成 PSO-ELM 训练,得到最终的分类器。

4 小电流接地故障检测系统设计

4.1 系统总体结构

电力系统自动化的发展日益成熟,具备通信功能的故障指示器不仅可以翻牌告警,还可以将采集到的故障信息及时发送给主站进行处理。RTDS 仿真系统克服了实验条件的限制,操作简单并且可靠性高,广泛应用于电力系统动态仿真模拟领域。其主要由软件和硬件两部分组成,软件上使用 PSCAD/EMTDC 电磁暂态仿真软件,可以方便用户搭建电力仿真系统,计算分析仿真结果,而硬件部分由电力系统实时仿真器和功率放大器组成,能对外提供产品测试接口。

已搭建拥有 3 条馈线的 10 kV 小电流接地系统,如图 3 所示。在各线路上的故障指示器先通过短距离无线传输模式将电流信号传给汇集单元,汇集单元则将录波数据汇总成零序电流,并利用移动通信网络完成数据在云端的上传,最终主站进行数据访问并集中完成故障诊断。

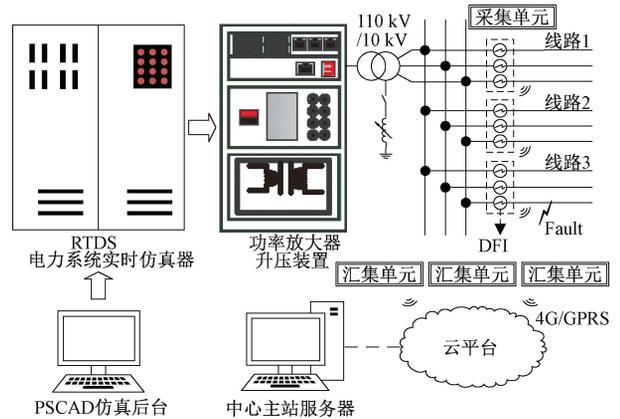


图 3 小电流单相接地故障检测系统

Fig. 3 Detection system of neutral ineffective single-phase ground fault

4.2 系统实现

图 3 中 10 kV 配电线路由两条架空线和一条电缆线混合构成,中性点分别使用不接地和经消弧线圈接地进行仿真。长度分别是 15、10 和 5 km。其线路参数如表 3 所示,消弧线圈电感为过补偿 8% ($L = 2.046 \text{ H}$)。关于电晕型这类非线性故障则通过自定义的“控制论”模型来模拟^[19]。

表 3 电缆线路和架空线路参数

Table 3 Parameters of cable line and overhead line

类型	R_l' ($\Omega \cdot \text{km}^{-1}$)	L_l' ($\text{mH} \cdot \text{km}^{-1}$)	C_l' ($\mu\text{F} \cdot \text{km}^{-1}$)	R_0' ($\Omega \cdot \text{km}^{-1}$)	L_0' ($\text{mH} \cdot \text{km}^{-1}$)	C_0' ($\mu\text{F} \cdot \text{km}^{-1}$)
架空	0.170	1.017	0.115	0.320	3.560	0.006
电缆	0.270	0.255	0.376	2.700	1.109	0.276

本文系统的信号采集单元是基于 ST 公司的 STM32H7 设计的,它综合了高性能与低功耗的特点。其 ADC 高达 16 位分辨率,并支持 3.6 Msp/s 采样率,能很好地满足工程需求。经过调理电路的滤波和电平转换,可以将电流互感器的采样电压调整到 ADC 模块可接受的 0~3.3 V。目前的小电流故障检测技术成熟,一般认为当发生单相接地故障时,其中性点的瞬时电压 U_0 大于额定相电压最大值 U_m 的 15%,此时故障指示器响应,并启动通信模块进行故障上报。汇集单元数据通信是基于 SIM7600CE 设计的,它是一款 4G 芯片,可以将 USART 作为数据通信接口直接与 MCU 相连,并通过 AT 指令完成控制,同时使用 MQTT 协议实现云平台的数据上传。

中心主站服务器在数据处理前需要访问云端数据进行离线训练。当终端收到故障提示后,将完成数据下载并传入主站进行分析,具体流程如图 4 所示。

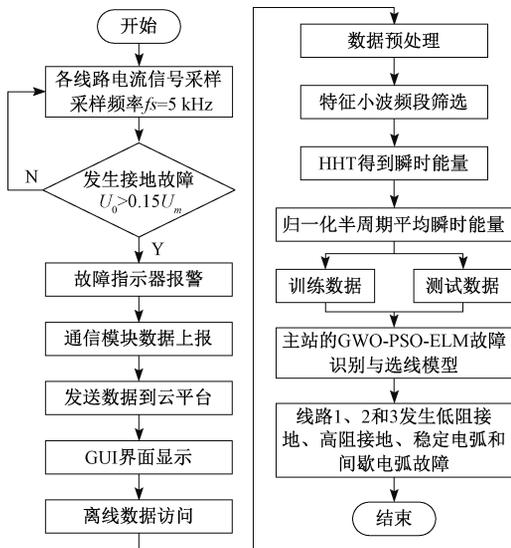


图 4 单相接地故障识别与选线流程

Fig. 4 The process of single-phase ground fault identification and line selection

5 仿真结果分析

5.1 数据集的建立

本文提出的改进 HHT 与 ELM 算法采用 PSCAD 与 MATLAB 的联合仿真。针对不同条件因素,选取中性点非有效性接地系统下不同的故障线路、初始相角、故障距离和过渡电阻,其中电弧类型的故障可以通过改变模型的经验系数 β 、弧隙压降 V_{s0} 和电弧长度 l 来改变其电阻大小^[20]。在实验中,设置 0.29 s 为故障时刻,总仿真时间为 0.5 s,采样频率为 5 kHz,采样时间为 0.2 s,获取由 4 种故障类型和 3 种故障线路所组合得到的 12 种故障录波数据,提取 0.28~0.33 s 时间段共 250 个点作为一组

样本,最终得到 3 500 组样本,并随机生成 2 000 个训练样本和 1 500 个测试样本。

5.2 仿真结果分析

该分类结果形成的混淆矩阵如图 5 所示,可以看到该方法对于 12 种故障情况均有良好的识别效果,其总体准确率高达 94.87%,证明改进的 HHT 和 ELM 对各类情况都有良好的适应性。其中误差相对较大的种类 7、8 和 9 都属于稳定电弧故障,这是因为其虽然在电流过零处呈现高阻态,但是在整个过程中电流幅值一直很大,所以总体上呈现为低阻态,因此特征容易被判断为低阻接地故障。

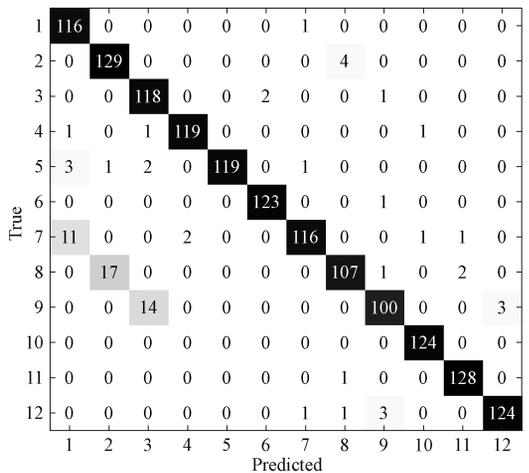


图 5 单相接地故障分类结果混淆矩阵

Fig. 5 A confusion matrix for the classification results of single-phase ground faults

为反映该智能算法的优化效果,提供相同的训练集和测试集,对比各类方法的分类结果。其结果如表 4 所示。可以发现经过 GWO 和 PSO 联合优化的 ELM 跟传统方法相比有更好的分类效果。

表 4 各种智能算法性能对比

Table 4 Parameters of cable line and overhead line

分类算法	准确率/%
BP	92.13
SVM	91.85
PNN	89.73
ELM	88.27
PSO-ELM	93.64
GWO-PSO-ELM	94.87

6 结论

本文提出的 WT-HHT 与 GWO-PSO-ELM 算法,能解决小电流接地系统单相接地故障检测的问题。在 HHT 变换之前使用小波变换很好地降低了带宽,减少了低频

分量 and 虚假 IMF 分量对故障信号的干扰,提取了更有效的故障信息。从故障电流的暂态分量入手,结合故障识别和故障选线的相关知识,将各条线路的瞬时能量作为特征函数,提取了作为分类器后续输入的关键特征。对于 ELM,先使用 GWO 算法对隐含层节点数进行寻优,然后将最佳节点数用于经改进 PSO 算法优化的自适应 ELM。通过测试 DFI 和 RTDS 搭建的接地故障检测系统,证明了该特征提取与分类算法不仅可以进行故障类型识别也可以进行故障选线,而且相比传统算法有更好的准确率。

参考文献

- [1] 徐丙垠,薛永端,冯光,等.配电网接地故障保护若干问题的探讨[J].电力系统自动化,2019,43(20):1-7.
XU B Y, XUE Y D, FENG G, et al. Discussion on several problems of earthing fault protection in distribution network [J]. Automation of Electric Power Systems, 2019, 43(20): 1-7.
- [2] 洪翠,付宇泽,郭谋发,等.改进多分类支持向量机的配电网故障识别方法[J].电子测量与仪器学报,2019,33(1):7-15.
HONG C, FU Y Z, GUO M F, et al. Identification method of distribution network faults based on improved mul-classification support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(1): 7-15.
- [3] 刘隆华,黄洪全,黄启哲,等.基于电弧外特性的故障定位信号发生器优化设计[J].电力系统自动化,2016,40(9):100-105.
LIU L H, HUANG H Q, HUANG Q ZH, et al. Arc characteristics based optimization design of fault location signal generator [J]. Automation of Electric Power Systems, 2016, 40(9): 100-105.
- [4] 王宾,耿建昭,董新洲.配网高阻接地故障伏安特性分析及检测[J].中国电机工程学报,2014,34(22):3815-3823.
WANG B, GENG J ZH, DONG X ZH. Analysis and detection of volt-ampere characteristics for high impedance faults in distribution systems [J]. Proceedings of the CSEE, 2014, 34(22): 3815-3823.
- [5] 杨帆,金鑫,沈煜,等.小电流接地故障多层次分类及其识别模型[J].电力系统自动化,2018,42(15):186-191,273-275.
YANG F, JIN X, SHEN Y, et al. Multilevel classification and identification model for earth faults in non-solidly earthed network [J]. Automation of Electric Power Systems, 2018, 42(15): 186-191,273-275.
- [6] 秦雪,刘亚东,孙鹏,等.基于故障波形时频特征配网故障识别方法研究[J].仪器仪表学报,2017,38(1):41-49.
QIN X, LIU Y D, SUN P, et al. Study on the line fault root-cause identification method in distribution networks based on time-frequency characteristics of fault waveforms [J]. Chinese Journal of Scientific Instrument, 2017, 38(1): 41-49.
- [7] YANG J, GONG L Y, TANG Y F, et al. An improved svm-based cognitive diagnosis algorithm for operation states of distribution grid [J]. Cognitive Computation, 2015, 7(5): 582-593.
- [8] SILVA S, COSTA P, GOUVEA M, et al. High impedance fault detection in power distribution systems using wavelet transform and evolving neural network[J]. Electric Power Systems Research, 2018, 154(jan.): 474-483.
- [9] 张淑清,王佳森,张立国,等.基于 DTCW-ERE 的小电流接地系统故障选线[J].仪器仪表学报,2016,37(3):505-511.
ZHANG SH Q, WANG J S, ZHANG L G, et al. Fault line selection for small current grounding system based on DTCW-ERE [J]. Chinese Journal of Scientific Instrument, 2016, 37(3): 505-511.
- [10] 张淑清,翟欣沛,董璇,等.EMD 及 Duffing 振子在小电流系统故障选线方法中的应用[J].中国电机工程学报,2013,33(10):161-167,5.
ZHANG SH Q, ZHAI X P, DONG X, et al. Application of EMD and Duffing oscillator to fault line detection in un-effectively grounded system [J]. Proceedings of the CSEE, 2013, 33(10): 161-167,5.
- [11] 田书,寿好俊.基于 EEMD 和能量法的谐振接地配电网故障选线研究[J].电子测量技术,2016,39(9):176-181.
TIAN SH, SHOU H J. Study on fault line selection in resonant earthed distribution network based on EEMD and energy [J]. Electronic Measurement Technology, 2016, 39(9): 176-181.
- [12] 田书,寿好俊,尚鹏辉.基于 HHT 的谐振接地配电网暂态量故障选线研究[J].测控技术,2017,36(3):14-19.
TIAN SH, SHOU H J, SHANG P H. Research on transient fault line selection in resonance grounding distribution network based on HHT [J]. Measurement & Control Technology, 2017, 36(3): 14-19.
- [13] 童涛,张新燕,刘博文,等.基于傅里叶同步挤压变换和希尔伯特变换的谐波间谐波检测分析[J].电网技术,2019,43(11):4200-4208.

- TONG T, ZHANG X Y, LIU B W, et al. Analysis of harmonic and inter-harmonic detection based on Fourier-based synchrosqueezing transform and Hilbert transform [J]. Power System Technology, 2019, 43(11): 4200-4208.
- [14] 宋金钊, 李永丽, 石峥, 等. 一种新的谐振接地系统单相接地故障选线方法[J]. 电力系统保护与控制, 2017, 45(6): 9-15.
- SONG J ZH, LI Y L, SHI ZH, et al. A fault line selection method for resonant earthed system with high accuracy [J]. Power System Protection and Control, 2017, 45(6): 9-15.
- [15] LI R, YU N H, GONG M, et al. Fault diagnosis algorithm for distribution line based on wavelet singular entropy and wavelet energy entropy[C]. 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2017: 2395-2398.
- [16] 丁阳征, 贾建芳. 改进 PSO 优化 ELM 预测锂离子电池剩余寿命[J]. 电子测量与仪器学报, 2019, 33(2): 72-79.
- DING Y ZH, JIA J F. Improved PSO optimized extreme learning machine predicts remaining useful life of lithium-ion battery [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 72-79.
- [17] BAI Y, CHEN J G, ZHAN ZH CH. Analysis and research of improved grey wolf optimization algorithm [J]. Computer Science and Application, 2017, 7(6): 562-571.
- [18] 陈磊, 詹跃东, 田庆生. 基于改进二进制灰狼优化算法的配网故障定位[J]. 电子测量技术, 2019, 42(1): 1-5.
- CHEN L, ZHAN Y D, TIAN Q SH. Fault location of distribution network based on improved binary gray wolf optimization algorithm [J]. Electronic Measurement Technology, 2019, 42(1): 1-5.
- [19] 李淑蓉, 薛永端, 徐丙垠, 等. 小电流接地故障电弧建模及过电压分析[J]. 电力科学与技术学报, 2019, 34(1): 47-53.
- LI SH R, XUE Y D, XU B Y, et al. Arc modeling and overvoltage analysis in non-solidly earthed networks [J]. Journal of Electric Power Science and Technology, 2019, 34(1): 47-53.
- [20] 俞小勇, 秦丽文, 欧阳健娜. 间歇性电弧接地故障建模分析[J]. 南方电网技术, 2019, 13(12): 67-73.
- YU X Y, QIN L W, OUYANG J N. Modeling analysis of intermittent arc grounding fault [J]. Southern Power System Technology, 2019, 13(12): 67-73.

作者简介



王毅, 2004 年于电子科技大学获得学士学位, 2009 年于北京邮电大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为智能电网、电力物联网。

E-mail: wangyi81@cqupt.edu.cn

Wang Yi received his B. Sc. degree in 2004 from University of Electronic Science and Technology of China, received his M. Sc. and Ph. D. degree in 2009 from Beijing University of Posts and Telecommunications. Now he is an associate professor in Chongqing University of Posts and Telecommunications. His main research interests include smart grid and IOTIPS.



李曙, 2018 年于湖北经济学院获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为配电故障监测与诊断。

E-mail: leeshu077@163.com

Li Shu received his B. Sc. degree in 2018 from Hubei University of Economics. Now he is a M. Sc. candidate in Chongqing University of Posts and Telecommunications. His main research interests include power distribution fault monitoring and diagnosis.