

DOI:10.13296/j.1001-1609.hva.2016.09.015

基于 EMD-SVD-KELM 与参数优选的励磁涌流辨识

施恂山¹, 马宏忠¹, 夏东升¹, 许洪华², 陈冰冰², 李 勇²

(1. 河海大学能源与电气学院, 南京 211100; 2. 江苏省电力公司南京供电公司, 南京 210008)

摘要: 针对变压器差动保护装置易受励磁涌流误动作问题, 提出了基于 EMD-SVD-KELM 与参数优选的励磁涌流辨识方法。首先, 以经验模态分解(EMD)和奇异值分解(SVD)为工具, 对励磁涌流和故障电流信号进行预处理, 提取出识别特征量, 并作为后续核函数极限学习机(KELM)学习输入量; 然后, 因学习机性能受参数 C 和 γ 影响较大, 以均分训练样本所得多个模型的平均准确率作为适应度评价函数, 为 KELM 参数优选提供评价标准。通过 EMTDC 仿真计算生成训练样本和测试样本, 利用多种优化算法对 KELM 进行训练和测试。最终, 试验结果表明, 与网格搜索(GS)、遗传算法(GA)、粒子群算法(PSO)相比, 改进粒子群算法(IPSO)能够更加迅速地搜索到最优参数, 同时学习后的 IPSO-KELM 模型能够正确识别涌流和故障电流, 验证了文中所提方法的正确性和可行性。

关键词: 励磁涌流; 故障电流; 经验模态分解(EMD); 奇异值分解(SVD); 核函数极限学习机(KELM); 改进粒子群算法(IPSO)

Identification of Inrush Current Based on EMD-SVD-KELM and Parameter Optimization

SHI Xunshan¹, MA Hongzhong¹, XIA Dongsheng¹, XU Honghua², CHEN Bingbing², LI Yong²

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. Nanjing Power Supply Company, State Grid Jiangsu Electric Power Company, Nanjing 210008, China)

Abstract: Aiming at the issue that transformer differential protection devices are easily making a fault operation by inrush current, an identification technique of inrush current based on EMD-SVD-KELM and parameter optimization is presented. Firstly, with the help of empirical mode decomposition(EMD) and singular value decomposition(SVD), inrush current and fault current signals are preprocessed to extract feature quantities for identification. These feature quantities can be as learning inputs of the following extreme learning machine with kernel(KELM). Then, parameter C and γ have a greater impact on learning machine performance, so average accuracy rate of multiple models resulting from average training samples can be fitness function to provide evaluation criteria for the parameter optimization of KELM. EMTDC is used to generate the training samples and testing samples. Simultaneously, KELM is trained and tested by various optimization algorithms. Finally experimental results show that comparing with grid search(GS), genetic algorithm(GA) and particle swarm optimization(PSO), improved particle swarm optimization(IPSO) is better to quickly search optimal parameters. Meanwhile the trained IPSO-KELM model can properly identify inrush current and fault current, which verify correctness and feasibility of the proposed method in this paper.

Key words: inrush current; fault current; empirical mode decomposition(EMD); singular value decomposition(SVD); extreme learning machine with kernel(KELM); improved particle swarm optimization(IPSO)

收稿日期:2016-02-12; 修回日期:2016-04-14

基金项目:国家自然科学基金项目资助(51577050)。

Project Supported by National Natural Science Foundation of China(51577050).

0 引言

目前,电流差动保护是作为变压器保护的主要形式,但是,合闸励磁涌流却一直影响着大型变压器的保护^[1],为了减小其误动作和拒动概率,正确有效地识别励磁涌流和内部故障电流成为了国内外学者研究的热点问题。常用判别方法^[2-3]大多基于涌流的波形特征,如:相对于内部故障电流,涌流二次谐波含量较大、波形中出现间断角以及涌流波形畸变严重等,但这些方法在实际应用中都或多或少存在一些难以解决的缺陷。

励磁涌流辨识属于模式识别的范畴。文[4]提出利用小波变换对差动电流预处理,提取能量谱作为神经网络特征输入量,训练后的网络能够正确区分励磁涌流和故障电流,但小波变换中小波基和分解尺度的选择还无统一遵循的原则,且小波分解存在能量泄漏^[5];文[6]提出了自适应小波神经网络励磁涌流识别方法,经测试,该方法识别率较高,但对训练样本数量要求较高,当实际样本数量有限时,该方法准确度将受到限制。

经验模态分解(empirical mode decomposition, EMD)是一种自适应的时频分析方法,以原信号为对象,自动生成基函数,作为滤波器,提取出信号中固有模态函数。奇异谱熵专注于挖掘信号本质特征,不受信号幅值大小的影响,具有一定的抗噪声干扰能力,是提取励磁涌流和故障电流特征的有效方法。结合核函数极限学习机(extreme learning machine with kernel, KELM)具有结构简单、训练时间短、泛化性能稳定等优点,文中提出了一种基于 EMD-SVD-KELM 与参数优选的励磁涌流辨识方法。试验结果显示,该方法能够对励磁涌流和内部故障电流快速正确区分。

1 基于 EMD-SVD 的特征向量提取

1.1 EMD 算法

EMD 方法^[7]的实质是通过特征时间尺度来识别信号中所内含的固有模态函数(intrinsic mode function, IMF)。电流信号 $s(t)$, 其初始值 $u_0(t)$, 令 $i=1$, 分解步骤如下:

- 1) 找出电流信号 $s(t)$ 中所有局部极大值和局部极小值;
- 2) 利用三次样条函数对极值点进行插值, 得到上、下包络线 $e_{\max}(t)$ 和 $e_{\min}(t)$;
- 3) 计算包络均值线 $u(t)=[e_{\max}(t)+e_{\min}(t)]/2$;
- 4) 提取细节 $c(t)=s(t)-u(t)$;
- 5) 判断 $c(t)$ 是否满足式(1), 若满足, 则令 $c_i(t)=$

$c(t)$, 转入 6); 若不满足, 则令 $s(t)=c(t)$, 重复执行 1)~5);

$$S_D=[\sum |c_{i-1}(t)-c_i(t)|^2]/\sum c_{i-1}(t)^2<\alpha。 \quad (1)$$

终止条件采用限定标准差准则, α 是 0.2~0.3 之间任意值^[8]。

6) $u_i(t)=s(t)-c_i(t)$;

7) 判断 $u_i(t)$ 是否为单调函数, 如果是则循环结束, 否则令 $s(t)=u_i(t)$, 转到 1)。

当分解完成后, 令 $r_i(t)=u_i(t)$, 则原始信号 $s(t)$ 分解为

$$s(t)=\sum_{k=1}^n c_k(t)+r_n(t)。 \quad (2)$$

1.2 相空间重构

设第 k 个 IMF 分量 $C_k=\{c_k(t), t=1, 2, \dots, N\}$, 将 C_k 加窗, 长度为 M , 得到 $c_k(1), c_k(2), \dots, c_k(M)$, 然后右移 1 步, 得到 $c_k(2), c_k(3), \dots, c_k(M+1)$, 依次类推, 该时间序列被分为 $(N-M+1)$ 个窗口, 以此数据构造轨迹矩阵 A_k

$$A_k=\begin{bmatrix} c_k(1) & c_k(2) & \cdots & c_k(M) \\ c_k(2) & c_k(3) & \cdots & c_k(M+1) \\ \vdots & \vdots & \vdots & \vdots \\ c_k(N-M+1) & c_k(N-M+2) & \cdots & c_k(N) \end{bmatrix}。 \quad (3)$$

1.3 奇异谱熵

对轨迹矩阵 A_k 进行奇异值分解(singular value decomposition, SVD), 得到奇异值 $\lambda_k^m (m=1, 2, \dots, m_0)$, ($m_0=\min(N-M+1, M)$)。根据信息熵理论^[9], 定义其奇异谱熵为

$$E_k=-\sum_{m=1}^{m_0} p_k^m \ln p_k^m。 \quad (4)$$

式(4)中, $p_k^m=\lambda_k^m/\sum_{m=1}^{m_0} \lambda_k^m$ 表示第 m 个奇异值在整个奇异值的比重。

1.4 特征向量的提取

特征向量提取的具体步骤为:

1) 对待分析的电流信号首先进行经验模态分解, 得到 n 个 IMF 分量; 然后对每个 IMF 分量进行相空间重构。文中采样频率为 5 000 Hz, 数据分析点数为 300, 进行 100 维相空间重构, 得到 n 个 201×100 维的矩阵 A_k 。

2) 对每个矩阵 A_k 进行奇异值分解, 则能够得到 100 个奇异值。

3) 依据式(4), 对每个 IMF 分量的奇异值进行奇异谱熵运算, 然后将所有奇异谱熵值组合, 得到特征向量 E 。

$$E=[E_{1r}, E_{2r}, \dots, E_{nr}]。 \quad (5)$$

2 核函数极限学习机

KELM 是基于基本极限学习机(extreme learning machine, ELM)理论衍生出来的, 与常用 BP 神经网络和支持向量机相比, 其在网络学习速度和泛化能力上相对更强^[7,10]。

在说明 KELM 之前, 首先说明基本 ELM 算法的神经网络构建机制(相关定理和详细的理论证明见文[11-12]), 其神经网络函数可表示为

$$H\beta = T. \quad (6)$$

$$\text{式(6)中: } H = \begin{bmatrix} g(\omega_1 x_1 + b_1) & \cdots & g(\omega_K x_1 + b_K) \\ \vdots & \cdots & \vdots \\ g(\omega_1 x_N + b_1) & \cdots & g(\omega_K x_N + b_K) \end{bmatrix}_{N \times K}. \text{ 其中}$$

H 为极限学习机的隐含层输出矩阵; β 为隐含层与输出层连接权重; T 为输出向量。

当隐含层节点数确定后, 输入权重 ω_i 和偏置 b_i 随机选择确定, 即 H 得到确定表达式。 β 通常取其最小二乘解, 计算方法为

$$\beta = H^{-1}T = H^T(HH^T)^{-1}T = H^T(I/C + HH^T)^{-1}T. \quad (7)$$

式(7)中: H^{-1} 为 H 矩阵的广义逆矩阵^[13]; 根据岭回归理论, 通过增加正常数 C , 求得结果更加稳定并具有更好的泛化能力^[14]。

对于 KELM 算法, 其通过引入核函数来获得更好的泛化精度, 对应的输出为

$$f(x) = h(x)H^T(I/C + HH^T)^{-1}T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T (I/C + \psi_{ELM})^{-1}T. \quad (8)$$

式(8)中: $\psi_{ELM(i,j)} = \exp(-\gamma \|x_i - x_j\|^2)$, $\psi_{ELM(i,j)}$ 为核函数, 通常选择高斯核函数; N 为样本数。

核函数中的参数 γ 与广义逆矩阵中的参数 C , 对网络训练速度和泛化能力影响较大, 通常凭经验或多次尝试后才能确定。但这样费时费力, 且确定的参数也不一定是最优结果, 因此, 文中拟采用收敛速度快, 算法相对简单的粒子群算法对参数进行优选。

3 改进粒子群算法及诊断流程

3.1 改进粒子群算法

粒子群算法^[15]是一种通过模拟鸟群起飞时信息相互交互过程(学习和模仿)的智能优化算法。该算法的计算公式为:

$$V_{id}^{t+1} = \varphi V_{id}^t + c_1 \text{rand}_1(P_{id}^t - X_{id}^t) + c_2 \text{rand}_2(P_{gd}^t - X_{id}^t); \quad (9)$$

$$X_{id}^{t+1} = X_{id}^t + V_{id}^{t+1}. \quad (10)$$

式(9)、(10)中: t 为当前迭代次数; V_{id}^t 为第 t 次迭代中粒子 i 在 d 维的速度; ω 为惯性权重, 其值大小

影响粒子全局和局部搜索能力, 通常取在 $[0.8, 1.2]$; c_1, c_2 为加速度因子, 分别控制飞向最优个体和群体的距离, 设置为 2.5; X_{id}^t 为第 t 次迭代中粒子 i 在 d 维的位置; P_{id}^t, P_{gd}^t 分别为第 t 次迭代中粒子 i 和整个群体 d 维的最佳位置; $\text{rand}_1, \text{rand}_2$ 为分布于 $[0, 1]$ 之间的随机数。

经验表明, 上述优化算法在训练特征参数时, 具有收敛速度迅速、通用性强的特点, 但同时也有着容易早熟、后期迭代效率不高等缺陷。为此, 文中通过对算法关键参数—惯性权重(φ)、加速度因子(c_1, c_2)进行修改, 并引入变异算子, 使得算法兼具前期全局和后期局部的寻优能力。具体体现在:

1) 文[16]提出了一种线性递减的惯性权重因子, 然而迭代后期, φ 的减小会使粒子陷入局部最优, 为此文中采用一种线性微分递减策略, 化简后为

$$\varphi_t = \varphi_{\max} - (\varphi_{\max} - \varphi_{\min})(t/T_{\max})^2. \quad (11)$$

式(11)中: $\varphi_{\max}$ 为惯性权重最大值, 文中选择 0.9; $\varphi_{\min}$ 为惯性权重最小值, 选择 0.4; t 代表当前迭代次数; $T_{\max}$ 代表迭代总数。

2) 学习因子 c_1 和 c_2 的大小决定了粒子间信息交流的能力, 通常其和大于 4。文中采用线性调整学习因子的策略, 原理简单、编程方便且应用效果较好。变换公式为:

$$c_1 = 2.5 - 1.5t/T_{\max}; \quad (12)$$

$$c_2 = 1 + 1.5t/T_{\max}. \quad (13)$$

3) 迭代后期, 为了使粒子能够跳出当前搜索到的最优位置, 在更大的空间中展开搜索, 引入变异因子, 该方法避免引入选择因子^[17], 导致种群多样性丢失的缺点。定义个体有 5% 的变异率, 其伪代码为: 假如 rand_1 大于 0.95 或者小于 0.05, 则对当前粒子随机赋值, 其他保持当前粒子不变。

3.2 适应度评价函数

采用交叉验证(cross validation, CV)方法。假设对于 N 个训练样本数据, 平均分成 m 组, 将每个子集数据分别作一次验证集, 同时其余 $(m-1)$ 组子集数据作为训练集, 这样会得到 m 个模型, 以这 m 个模型验证集的分类准确率的平均数作为粒子的适应度函数, 该方法可以有效地避免网络过学习和欠学习状态发生。

3.3 状态识别步骤

综上所述, 基于改进粒子群算法(improved particle swarm optimization, IPSO)优化 KELM 的励磁涌流和故障电流识别的具体实施步骤为:

1) 在可行域内, 对迭代总次数 $T_{\max}$ 、种群规模 M 、个体位置和速度最大、最小值(防止粒子盲目寻找)以

及分组数 m 进行设定;

2) 根据特征参数可以确定每个粒子的维数, 在 $[-5, 5]$ 内随机赋值;

3) 导入训练样本, 通过 KELM 进行第 1 次前向运算, 计算每个粒子适应度值, 根据适应度值的大小, 对粒子进行排序, 寻找出初始个体极值 P_{si} 和群体极值 P_{sg} ;

4) 进入迭代过程, 根据式(9)、(10)对位置和速度更新, 并判断是否越界, 若越界则赋予最值, 否则进入下一步;

5) 判断个体是否变异, 若变异则对当前个体位置随机赋值, 并计算当前粒子的适应度值, 否则根据更新后的粒子位置, 计算其适应度值;

6) 根据更新后的适应度值, 与上次得到的个体极值 P_i 和群体极值 P_g 比较并更新;

7) 判断当前迭代次数是否达到了设定的最大迭代次数 T_{max} , 若符合则迭代终止, 否则转向 4);

8) 网络训练结束后, 根据寻找到的最优粒子, 得到最优参数 γ 和 C , 导入测试样本进行测试, 评价其泛化能力。

4 仿真试验

在 EMTDC 电磁暂态仿真试验平台进行试验。试验模拟变压器为三单相变压器组, 高低压侧为 Y/D 联接。单相变压器参数为: 额定容量 10 500 kVA; 低压侧额定电压 10.5 kV; 低压侧额定电流 1 000 A;

高压侧额定电压 110 kV; 高压侧额定电流 95.45 A; 空载电流为 0.14%; 空载损耗为 6.8 kW; 短路损耗为 7.73 kW; 短路电压为 10.02%。试验工况: 空载合闸、单相接地故障(A 相 32%匝处短路)、两相接地短路故障(A、B 相 32%匝处短路)、三相短路(A、B 和 C 相 32%匝处短路)、匝间短路(A 相 8%匝处发生短路)以及带匝间短路空载合闸。仿真空载合闸时考虑初始合闸初相角在 $0^\circ \sim 360^\circ$ 间变化, 剩磁在 $0\% \sim 60\%$ 额定工作磁密间变化。试验信号采样频率为 5 000 Hz, 采样




图 1 试验系统接线示意图

Fig. 1 Wiring schematic for test system

时间 0.1 s, 试验系统接线图见图 1。

4.1 时域波形及 IMF 波形分析

6 种工况下 A、B、C 三相差动电流时域波形见图 2。由图 2(a)知, A 相和 C 相波形呈偏向时间轴一侧的尖顶波, B 相波形为关于时间轴的对称波形; 由图 2(b)~(e)知, A 相、B 相和 C 相电流波形基本类似正弦曲线; 由图 2(f)知, A 相、C 相电流呈类似正弦波形, 这是因为 A 相匝间短路故障将反映在 A、C 相差流上, 而 B 相电流出现偏向时间轴一侧, 主要是受合闸涌流的影响。




图 2 不同工况下电流波形

Fig. 2 Current waveforms in different conditions

合闸非对称涌流、对称涌流以及内部故障电流

EMD 分解波形图见图 3。发现高频段 c_1 、 c_2 与低频段

c_3 、 c_4 包含的模态分量数目会有所不同。




图3 励磁涌流和故障电流 EMD 分解对比

Fig. 3 Contrast to EMD decomposition of inrush current and fault current

4.2 奇异谱熵值分析

以 A 相为例, 把 5 种工况下各自 EMD 分解得

到的 IMF 分量进行相空间重构, 得到轨迹矩阵 A_k 并对其进行 SVD 得到奇异值。

不同状态之间的差异可以由奇异值的大小所反映, 而奇异谱熵可以定量地描述这种变化程度^[18]。谱熵值越小, 说明能量越集中; 谱熵值越大, 说明能量在整个频段分布得越均匀^[19]。利用信息熵基本公式, 计算得到各分量的奇异谱熵值, 并组成特征向量。多次试验后, 空载合闸、单相接地短路、两相接地短路、三相短路和匝间短路各取 3 组特征向量, 见表 1。

表 1 特征向量

Table 1 Feature vectors

状态	波形特征	编号	E_1	E_2	E_3	E_4
空载 合闸	非对称 涌流	1	4.796 3	3.934 1	2.099 1	1.266 1
		2	4.798 2	3.985 2	2.150 3	1.248 2
		3	4.798 9	4.022 1	2.124 3	1.292 9
空载 合闸	对称涌流	1	4.753 5	3.956 1	1.634 9	1.014 3
		2	4.756 7	3.951 9	1.664 8	0.987 2
		3	4.755 3	3.967 8	1.643 6	0.956 9
单相 短路	类似 正弦波	1	4.714 8	3.971 2	1.435 1	0.898 4
		2	4.713 8	3.955 1	1.413 2	0.855 6
		3	4.713 2	3.968 3	1.478 2	0.864 1
两相 短路	类似 正弦波	1	4.750 1	3.968 9	1.334 1	0.971 2
		2	4.745 6	3.971 5	1.346 6	0.968 9
		3	4.746 3	3.983 1	1.338 7	0.971 4
三相 短路	类似 正弦波	1	4.751 0	3.971 8	1.394 3	0.964 6
		2	4.754 6	4.022 6	1.363 0	0.985 5
		3	4.766 4	3.958 9	1.374 3	1.010 9
匝间 短路	类似 正弦波	1	4.718 8	4.021 8	1.226 1	1.160 2
		2	4.718 5	4.021 2	1.254 2	1.161 9
		3	4.718 2	4.018 0	1.235 5	1.154 5

由表 1 可以发现:

1) 各种工况下, 频段从高到低, 奇异谱熵值逐渐减小, 这是因为高频段(c_1 和 c_2)中包含的模态分量较多, 该频段能量分布分散, 不确定性较大; 低频段(c_3 和 c_4)能量分布集中在基频和二次谐波等, 不确定性较小。

2) 对同一类型状态, 同一频段分量 3 次测量奇异谱熵值变化很小, 具有相对稳定性, 有一定的抗干扰能力。

5 IPSO-KELM 诊断模型

5.1 样本的选取及模型参数设置

经测试, 选择奇异谱熵值 H_3 和 H_4 作为特征输入量, 网络训练效果较好, 因此输入节点设置为 2; 而输出节点设置为 1, 其中当网络输出 1 时, 代表励磁涌流, 当网络输出为 2 时, 代表故障电流。通过仿

真试验,共搜集了 180 组训练样本(空载合闸 60 组,单相短路、两相短路、三相短路和匝间短路各 30 组)和 60 组测试样本(带匝间短路空载合闸中涌流 30 组,故障电流 30 组)。当电流互感器(TA)饱和,励磁涌流间断角消失,因此,训练样本和测试样本中各包含 2 组饱和和非对称励磁涌流^[20]。部分测试集样本见表 2。

表 2 部分测试集样本

Table 2 Part of testing samples

状态	编号	H ₃	H ₄
涌流	1	1.947 7	1.120 1
	2	1.926 4	1.104 3
	3	1.911 9	1.098 8
故障电流	1	1.324 2	1.200 2
	2	1.326 9	1.184 3
	3	1.336 4	1.197 9

在使用 IPSO 优化 KELM 参数前,需对训练样本数据进行[-1 1]区间归一化处理,公式为

$$y=2(x-x_{\min})/[(x_{\max}-x_{\min})-1] \quad (11)$$

式(11)中: $x_{\max}$ 、 $x_{\min}$ 分别表示特征量 x 最大、最小值; y 表示对应归一化的值以及对 IPSO 算法参数进行设置^[24],见表 3。

表 3 参数设置

Table 3 Setting of parameters

参数	数值
种群规模 M	30
位置最大值 $x_{\max}$	5
位置最小值 $x_{\min}$	-5
速度最大值 $v_{\max}$	1
速度最小值 $v_{\min}$	-1
最大迭代次数 $T_{\max}$	100
组数 m	4

5.2 参数寻优方法比较


为了最快得到最优网络参数,采用网格搜索、遗传算法、粒子群算法和改进的粒子群算法对参数 γ 和 C 进行寻优并比较,结果见图 4。

从图 4 可以看出,网络搜索法,参数搜索范围较广,需尝试参数所有可能解,才能得到最优模型,相对所需时间较长;与遗传算法和粒子群算法相比,改进后的粒子群算法,在第 9 次迭代时,粒子就找到了最优训练精度下的参数,收敛速度最快。


5.3 模型验证

将测试集样本带入 IPSO-KELM 模型中,分类准确率达到了 98.333 3%(59/60),仅有一个励磁涌流样本错误分类。


为缩短保护的响应时间,文中分别采用 3/4T、T




(a) 网格搜索寻优图



(b) GA 搜索算法寻优图



(c) PSO 搜索算法寻优图



(d) IPSO 搜索算法寻优图

图 4 核函数极限学习机参数寻优图

Fig. 4 Optimizing figure of KELM's parameters

和 2T 的时间窗数据,建立各自训练模型并验证,结果见表 4。

表 4 显示,当数据窗长度为 T 和 2T 时,模型分

表 4 不同数据窗长度的 IPSO-KELM 模型分类准确度

Table 4 Classification accuracy of IPSO-KELM mode with different data window lengths

数据窗长度	分类准确度(正确数目/总数)
3/4T	53.333 3%(32/60)
T	100%(60/60)
2T	98.333 3%(59/60)

类准确度均至少达到了 98.333 3%, 当数据窗长度为 3/4T, 分类准确度明显下降, 仅为 53.333 3%, 主要是因为数据窗长度少于一个周期 T 时, 因端点效应分解得到的 IMF 分量失真, 励磁涌流和故障电流计算得到的奇异谱熵值区分也不明显, 导致训练得到的模型分类准确度不高。即使对数据合理延拓, 削弱端点造成的影响, 也会增加整体响应时间, 因此, 文中所提方法数据窗长度采用一个周期最适宜。为进一步验证 IPSO-KELM 模型输出结果的时效性, 采用文[6]中的方法提取励磁涌流数据, 并导入学习好的 IPSO-KELM 模型中。经测试, 对于各个时刻网络模型都可以作出正确的输出响应。

6 结论

对各主要工况下的励磁涌流和内部故障电流进行分析, 提出了一种基于 EMD-SVD-KELM 与参数优选的励磁涌流辨识方法, 并得出如下结论:

1) 联合经验模态分解和奇异值分解, 可以有效地提取区分励磁涌流和故障电流特征量。

2) 针对核函数极限学习机中关键参数不易选择问题, 改进粒子群算法能够快速、准确地找到在某种意义上下的最优参数。

3) 经学习后的 IPSO-KELM 组合模型能够精确地对励磁涌流和故障电流进行辨识。

参考文献:

- [1] 王维检. 电气主设备继电保护原理与应用[M]. 北京: 中国电力出版社, 2002.
WANG Weijian. Relay protection principles and applications of electrical main equipments[M]. Beijing: China Electric Power Press, 2002.
- [2] 吴 劫. 电力变压器励磁涌流识别新方法研究[D]. 河北: 华北电力大学, 2014.
WU Jie. Research on novel method of inrush current identification of power transformer[D]. Hebei: North China Electric Power, 2014.
- [3] 严屹宏, 陈剑云. 基于小波分析的变压器励磁涌流和内部故障电流识别[J]. 高压电器, 2010, 46(12): 74-77.
YAN Yihong, CHEN Jianyun. Identification of transformer

inrush current and internal fault current on the basis of wavelet analysis[J]. High Voltage Apparatus, 2010, 46(12): 74-77.

- [4] MAO P L, AGGARWAL R K. A novel approach to the classification of the transient phenomena in power transformer using combined wavelet transform and neural network[J]. IEEE Trans. on Power Delivery, 2001, 16(4): 654-660.
- [5] 张 君, 韩 璞, 董 泽, 等. 基于小波变换的振动信号分析中能量泄漏的研究[J]. 中国电机工程学报, 2004, 24(10): 238-243.
ZHANG Jun, HAN Pu, DONG Ze, et al. Energy leakage research of wavelet transform application on vibration signature analysis[J]. Proceeding of the CSEE, 2004, 24(10): 238-243.
- [6] 李海峰, 王 钢, 李晓华, 等. 电力变压器励磁涌流判别的自适应小波神经网络方法[J]. 中国电机工程学报, 2005, 25(7): 144-150.
LI Haifeng, WANG Gang, LI Xiaohua, et al. Distinguish between inrush and internal fault of transformer based on adaptive wavelet neural network[J]. Proceeding of the CSEE, 2005, 25(7): 144-150.
- [7] 汤庆峰, 刘 念, 张建华, 等. 基于 EMD-KELM-EKF 与参数优选的用户侧微电网短期负荷预测方法[J]. 电网技术, 2014, 38(10): 2691-2699.
TANG Qingfeng, LIU Nian, ZHANG Jianhua, et al. A short-term load forecasting method for micro-grid based on EMD-KELM-EKF and parameter optimization[J]. Power System Technology, 2014, 38(10): 2691-2699.
- [8] 叶 林, 刘 鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.
YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceeding of the CSEE, 2011, 31(31): 102-108.
- [9] 朱艳伟, 石新春, 李 鹏. 多分辨率奇异谱熵和支持向量机在孤岛与扰动识别中的应用[J]. 中国电机工程学报, 2011, 31(7): 64-70.
ZHU Yanwei, SHI Xinchun, LI Peng. Classification of islanding and grid disturbance based on multi-resolution singular spectrum entropy and SVM[J]. Advanced Technology of Electrical Engineering and Energy, 2011, 31(7): 64-70.
- [10] 杨锡运, 关文渊, 刘玉奇, 等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报, 2015, 36(35): 146-153.
YANG Xiyun, GUAN Wenyuan, LIU Yuqi, et al. Prediction intervals forecasts of wind power based on PSO-KELM[J]. Proceeding of the CSEE, 2015, 36(35): 146-153.

- [11] HUANG G B, ZHOU H, DING X, et al. Extreme learning machine for regression and multiclass classification[J]. Systems, Man, and Cybernetics, Part B: IEEE Transactions on Cybernetics, 2012, 42(2): 513-529.
- [12] HUANG G B, WANG D H, LAN Y. Extreme learning machine: A survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2): 107-122.
- [13] SERRE D. Matrices: Theory and applications[M]. USA: Springer, 2010: 137-142.
- [14] TOH K A. Deterministic neural classification[J]. Neural Computation, 2008, 20(6): 1565-1595.
- [15] 姜志鹏, 文习山, 蓝磊, 等. 粒子群算法应用于避雷器均压环配置优化[J]. 高压电器, 2014, 50(1): 102-106.
- JIANG Zhipeng, WEN Xishan, LAN Lei, et al. Application of particle swarm optimization algorithm to configuration optimization of grading rings for arrester[J]. High Voltage Apparatus, 2014, 50(1): 102-106.
- [16] 李丽, 牛奔. 粒子群优化算法[M]. 北京: 冶金工业出版社, 2009.
- LI Li, NIU Ben. Particle swarm optimization algorithm[M]. Beijing: Metallurgical Industry Press, 2009.
- [17] 魏星, 舒乃秋, 张霖, 等. 基于改进 PSO-BP 混合算法的电力变压器故障诊断[J]. 电力自动化设备, 2006, 26(5): 35-38.
- WEI Xing, SHU Naiqiu, ZHANG Lin, et al. Power transformer fault diagnosis based on improved PSO-BP hybrid algorithm[J]. Electric Power Automation Equipment, 2006, 26(5): 35-38.
- [18] 张超, 陈建军, 杨立东, 等. 奇异值熵和支持向量机的齿轮故障诊断[J]. 振动、测试与诊断, 2011, 31(5): 600-604.
- ZHANG Chao, CHEN Jianjun, YANG Lidong, et al. Fault diagnosis of gear based on EEMD entropy of singular values and support vector machine[J]. Journal of Vibration, Measurement & Diagnosis, 2011, 31(5): 600-604.
- [19] 潘明清, 周晓军, 杨振龙, 等. 基于信息熵的支持向量机机械状态识别[J]. 传感技术学报, 2005, 18(2): 277-280.
- PAN Mingqing, ZHOU Xiaojun, YANG Zhenlong, et al. Application of support vector machine based on information on spectrum entropy in machine state identification[J]. Chinese Journal of Sensors and Actuators, 2005, 18(2): 277-280.
- [20] 尤夏, 张艳霞. 波动误差结合峰—峰间距法识别变压器励磁涌流[J]. 电力系统自动化, 2012, 36(14): 36-40.
- YOU Xia, ZHANG Yanxia. Recognition of transformer inrush current based on combination of fluctuation error and peak-to-peak space method[J]. Automation of Electric Power Systems, 2012, 36(14): 36-40.
- [21] 史峰, 王小川, 郁磊, 等. MATLAB 神经网络 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2010.
- SHI Feng, WANG Xiaochuan, YU Lei, et al. 30 case analysis of MATLAB neural network[M]. Beijing: Beijing University of Aeronautics and Astronautics Press, 2010.

施恂山(1991—), 男, 硕士研究生, 主要研究方向为电力设备状态监测与故障诊断(通信作者)。

马宏忠(1962—), 男, 博士, 教授, 研究方向为电力设备状态监测与故障诊断、新能源发电。

(上接第 82 页)

- LI Yangpong, ZHOU Qing, LIU Xiang. Experimental study on arc ablation resistance and dielectric of PTFE composites[J]. Insulating Materials, 2006, 39(2): 36-38.
- [19] 齐波, 李成榕, 郝震, 等. GIS 绝缘子表面固定金属颗粒沿面局部放电发展的现象及特征[J]. 中国电机工程学报, 2011, 31(1): 101-108.
- QI Bo, LI Chengrong, HAO Zhen, et al. Evolution phenomena and features of surface partial discharge initiated by immobilized metal particles on GIS insulators[J]. Proceedings of the CSEE, 2011, 31(1): 101-108.
- [20] 贾江波, 陈姝敏, 杨兰均, 等. GIS 中绝缘子附近自由导电微粒无害化研究[J]. 高压电器, 2004, 40(5): 370-372.
- JIA Jiangbo, CHEN Shumin, YANG Lanjun, et al. Study of deactivation of free conducting particle near spacer in GIS[J]. High Voltage Apparatus, 2004, 40(5): 370-372.
- [21] IEC 60270—2000. High-voltage test techniques partial discharge measurements[S]. 2000.

李松原(1987—), 男, 工程师, 从事开关专业相关方面的研究。