

基于 VMD 形态梯度谱与 BAS-RF 的变压器绕组 松动诊断*

颜 锦¹, 马宏忠¹, 朱 昊¹, 张玉良¹, 许洪华²

(1. 河海大学能源与电气学院 南京, 211100) (2. 国网江苏省电力公司南京供电公司 南京, 210019)

摘要 为有效提取变压器振动信号中的绕组状态信息, 提出一种基于变分模态分解 (variational mode decomposition, 简称 VMD)、形态梯度谱的特征提取, 采用天牛须搜索算法优化随机森林 (beetle antennae search - random forest, 简称 BAS-RF) 识别绕组松动状态的诊断方法。首先, 将实测变压器振动信号经 VMD 分解得到若干个模态分量; 其次, 计算多个尺度的形态梯度谱以形成初始特征样本集, 为防止维数灾难, 使用主成分分析法对初始特征样本集进行降维处理; 最后, 利用天牛须搜索算法对随机森林中决策树的个数和树的深度进行寻优以构造分类器模型, 实现对变压器绕组松动状态的识别。实验结果表明, 该方法能有效提取变压器绕组松动故障特征信息, 且具有优良的抗噪性能, 构建的 BAS-RF 模型具有较高的识别准确率和识别速度。

关键词 变压器; 绕组松动; 变分模态分解; 形态梯度谱; 随机森林

中图分类号 TH113.1; TM41

引 言

变压器是电力系统中重要的组成部分, 在发电、输电和配电中起着不可或缺的作用^[1]。变压器绕组松动是最常见的故障, 其易导致变压器抗短路能力严重下降, 利用变压器产生的振动信号来诊断绕组故障已成为近年来研究的热门方向^[2]。

变压器振动信号具有非平稳和非线性的特点, 且受背景噪声干扰严重, 需要对信号进行分析和处理^[3-4], 相关方法包括小波分析、经验模态分解 (empirical mode decomposition, 简称 EMD) 等^[5-6]。虽然小波分析有较好的局部特征表现能力, 但小波基和分解尺度的不同选择会影响分解精度, 且其无法实现完全自适应分解。EMD 虽能自适应分解, 但其分解过程中存在分解层数过多、模态混叠等缺点^[7]。变分模态分解是一种非线性信号处理方法^[8-9], 其数学理论完备, 能避免 EMD 固有的端点效应和模态等缺点, 极大提高了分解信号的精度, 具有分解效率较高且噪声鲁棒性良好的特点。

形态谱 (pattern spectrum, 简称 PS) 是在数学形态学^[10]基础上发展起来的, 其对非线性信号具有良好的分析处理能力, 可以在不同结构和尺度下提取原始信号的形态特征成分, 在故障诊断领域有着广

泛应用^[11-13]。然而, 当振动信号含有大量的背景噪声干扰时, 用形态谱来定义故障特征往往存在精度不够等问题。因此, 将形态梯度算子引入到形态谱中形成形态梯度谱 (pattern gradient spectrum, 简称 PGS), 可以很好地在复杂环境中提取变压器振动信号中的非线性故障特征。

变压器绕组松动故障识别方法有神经网络^[14]、支持向量机^[15]及随机森林 (random forest, 简称 RF)^[16]等。神经网络具有抗过拟合能力不足、容易陷入局部最优解及训练时间过长等缺点。支持向量机适用于小样本训练, 对大规模样本训练和解决多分类问题存在困难, 且其参数选择对分类精度影响较大。随机森林是以决策树为基础并经过 Bagging 集成的机器学习算法, 具有较强抗噪、抗过拟合能力, 泛化性能优异且效率高, 但 RF 中决策树的深度和棵数选取会对分类的准确度产生影响^[17]。因此, 提出一种天牛须搜索算法 (beetle antennae search, 简称 BAS) 对随机森林 2 个关键参数进行寻优, 进一步提高其识别准确性。

笔者针对变压器绕组松动故障振动信号易受噪声干扰且绕组不同松动程度难以准确识别的问题, 提出利用 VMD 形态梯度谱与 BAS-RF 相结合的故

* 国家自然科学基金资助项目 (51577050); 国网江苏省电力公司重点科技资助项目 (J2020042)

收稿日期: 2021-04-29; 修回日期: 2021-08-28

障诊断方法。首先,提取变压器绕组各状态下振动信号的VMD形态梯度谱;其次,采用主成分分析法对特征集进行筛选,得到最优特征子集,将其输入到BAS-RF中以实现变压器不同绕组松动程度的识别;最后,与传统的粒子群算法优化随机森林(particle swarm optimization random forest,简称PSO-RF)和遗传算法优化随机森林(genetic algorithm random forest,简称GA-RF)进行对比,验证了笔者所提方法的有效性。

1 变分模态分解

VMD是一种新的自适应、非递归信号处理方法,具有较高的分解精度且能够减轻模态混叠、端点效应等现象,可以将任何复杂的序列信号分解成若干个固有模态分量(intrinsic mode function,简称IMF),并通过构造变分问题及对方程式的求解来确定其中心频率和带宽。为求得变分约束问题的最优解,通常在变分分解框架内引入拉格朗日算子和惩罚因子,将约束问题转换为非约束问题,再利用交替方向乘子法进行迭代求解。VMD的具体实现步骤参见文献[18]。

2 形态梯度谱

2.1 多尺度形态学

传统形态学只能从单尺度去衡量信号的特征成分,这会遗漏重要的特征信息,而多尺度形态学分析能够从多个尺度上对信号进行形态变换,从而获取更全面的故障特征信息。其中,形态学定义了如下4种最基本的运算^[10]: \oplus 为膨胀运算; \ominus 为腐蚀运算; \circ 为开运算; \bullet 为闭运算。假设 g 为单位结构元素, f 为非负函数,则可定义 g 为尺度下的结构元素,共进行 $\lambda-1$ 次膨胀运算,即

$$\lambda g = \underbrace{g \oplus g \oplus \dots \oplus g}_{\lambda-1} = \underbrace{((g \oplus \dots \oplus g) \oplus g) \oplus g}_{\lambda-1} \quad (1)$$

在尺度 λ 下,对信号进行膨胀、腐蚀运算,即

$$(f \oplus \lambda g)(n) = f \oplus \underbrace{(g \oplus g \oplus \dots \oplus g)}_{\lambda-1} \quad (2)$$

$$(f \ominus \lambda g)(n) = f \ominus \underbrace{(g \ominus g \ominus \dots \ominus g)}_{\lambda-1} \quad (3)$$

膨胀和腐蚀分别是在结构元素确定的领域中取得最小值和最大值^[12],且腐蚀是膨胀的对偶运算。

在尺度 λ 下,形态开、闭运算可定义为

$$(f \circ \lambda g)(n) = ((f \ominus \lambda g) \oplus \lambda g)(n) \quad (4)$$

$$(f \bullet \lambda g)(n) = ((f \oplus \lambda g) \ominus \lambda g)(n) \quad (5)$$

形态开、闭运算实际上是腐蚀和膨胀的运算组合,可以分别滤去信号波峰和波谷噪声^[13]。

2.2 形态谱

形态谱以数学形态学分析为理论基础,在一维信号处理分析中,能以直方图形式定量地反映信号在不同尺度结构元素的形态运算下形状的变化特征。

如果 f 为一离散的函数,其尺度大小只取连续的整数值, f 相对于 g 的形态谱可定义为

$$PS_f(+\lambda, g) = A[f \circ \lambda g - f \circ (\lambda + 1)g] \quad (6)$$

$$PS_f(-\lambda, g) = A[f \bullet \lambda g - f \bullet (\lambda - 1)g] \quad (7)$$

形态谱分析的核心是进行形态开、闭运算,其通常由正负区间构成。形态开运算只能平滑信号中的正向脉冲,所得的正区间代表振动信号的内在特征信息;而闭运算只能平滑信号中的负向脉冲,所得的负区间代表振动信号的外在背景信息。考虑到这两者的一致性,在下面的分析中都采取形态谱开运算。

2.3 形态梯度谱

变压器运行时振动信号含有大量的噪声干扰成分,会淹没有效形态特征信息,使得传统的形态谱对不同故障状态的区分效果不佳。因此,将数学形态梯度算子推广到传统的形态学计算中,得到一种改进的形态谱,即形态梯度谱,其计算方法如下。

将形态梯度算子引用到形态谱的开运算中,并假设 f 为某时域中的函数, g 为其结构函数,则形态梯度谱的定义为

$$PGS(f, \lambda, g) = \begin{cases} \frac{dA(f \oplus \lambda g - f \ominus \lambda g)}{d\lambda} & (\lambda \geq 0) \\ \frac{dA(f \ominus (-\lambda)g - f \oplus (-\lambda)g)}{d\lambda} & (\lambda < 0) \end{cases} \quad (8)$$

对于一维离散信号,因形态梯度算子具有外延性,可将形态梯度谱简化为

$$PGS_+(\lambda, g) = A[f \oplus \lambda g - f \ominus \lambda g - (f \oplus (\lambda + 1)g - (f \ominus (\lambda + 1)g))] \quad (9)$$

$$PGS_-(\lambda, g) = A[f \ominus (-\lambda)g - f \oplus (-\lambda)g - (f \ominus (-\lambda + 1)g - (f \oplus (-\lambda + 1)g))] \quad (10)$$

其中: $A(f) = \sum_n f(n)$ 。

相比于形态开运算,形态梯度运算能充分挖掘变压器绕组不同松动故障的特征信息,通过不同尺度清晰地显示出不同的形态成分。

3 天牛须算法优化随机森林

3.1 随机森林

RF是集群分类模型中的一种,其由多个决策树组成^[19],每个决策树之间相互独立,并分别对输入样本集进行分类,将得票数最多的类别作为最终的决策。该算法具体过程如下:

- 1) 在原始数据中选出 M 个样本集,对样本集进行 m 次有放回随机抽取采样,得到每个决策树的训练子集,用未抽到的样本作为测试集;
- 2) 对每个样本子集按照决策树生成算法构建决策树模型,其中每棵树都不会进行剪枝;
- 3) 重复步骤 1 和 2,最终由 m 个决策树组成随机森林分类器;
- 4) 用 m 个决策树进行分类,利用投票法将票数最多的类别作为随机森林算法识别结果。

3.2 天牛须搜索优化随机森林

RF算法中决策树的个数 b 和树的深度 l 的选取对分类准确度有着重要影响,其中决策树的个数影响泛化误差,树的深度影响计算速度及复杂度。因此,提出一种天牛须搜索优化随机森林新算法。天牛须搜索算法是一种群体智能算法^[20],启发于天牛觅食行为,其具体步骤如下。

- 1) 初始天牛触须方向,即建立归一化随机向量 \vec{q} 。初始两须距离为 p^0 ,初始位置为 u^0 ,并设定最大迭代次数 T ,则

$$\vec{q} = \frac{\text{rands}(k, 1)}{\|\text{rands}(k, 1)\|} \quad (11)$$

其中: k 为空间维度。

- 2) 计算两须坐标,分别用 u_l^t 和 u_r^t 表示经过 t 次迭代后左、右须坐标为

$$\begin{cases} u_l^t = u^t - p^t \vec{q} \\ u_r^t = u^t + p^t \vec{q} \end{cases} \quad (12)$$

其中: P^t 为第 t 次迭代两触须间距离。

$$p^t = 0.95p^{t-1} + 0.01 \quad (13)$$

- 3) 以 K -折交叉验证法识别率作为适应度值,计算左、右两须的气味强度分别为 $f(u_l^t)$ 和 $f(u_r^t)$,再利用变步长法确定天牛的下一步位置,即

$$u^{t+1} = u^t + \delta^{t+1} \vec{q} \text{sign}(f(u_r^t) - f(u_l^t)) \quad (14)$$

其中: $\text{sign}(\cdot)$ 为符号函数; δ^{t+1} 为 $t+1$ 次迭代时的移动步长。

$$\delta^{t+1} = 0.95\delta^t \quad (15)$$

- 4) 如果参数满足最优条件或达到最大迭代次

数,则执行下一步;否则,返回步骤 2。

- 5) 最终确定天牛搜索食物的位置,即决策树个数 b 和树的深度 l 的最优解。

4 变压器绕组松动诊断模型

为准确获取变压器绕组状态信息和提高抗噪声能力,提出一种基于 VMD 和形态梯度谱的特征提取,并采用 BAS-RF 进行变压器绕组松动故障识别,具体诊断流程如图 1 所示。

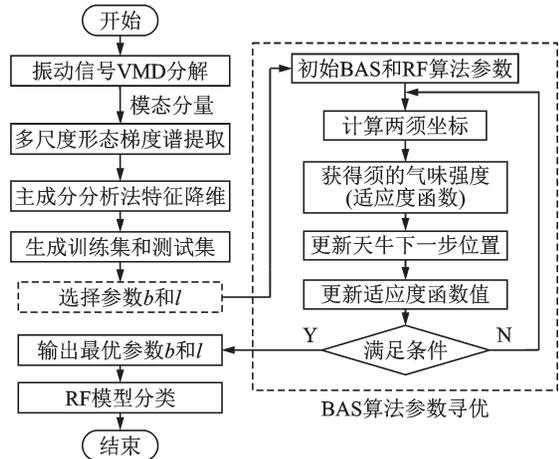


图 1 变压器绕组松动诊断流程图

Fig.1 Flow chart of transformer winding loosening diagnosis

5 变压器绕组松动故障诊断

5.1 变压器振动实验

以南京立业变压器有限公司的 110 kV 变压器为对象,进行了振动测试,变压器的型号为 SFZ10-31500/110。振动信号采集系统由振动加速度传感器(型号为 JF2020)、数据采集装置(型号为 DH5922D)和 Matlab 软件构成。由于变压器绕组振动通过固体构件传播到油箱顶部的衰减较小,所以在变压器顶部采集的振动信号包含更为完整的变压器内部信息^[1]。3 个测点位置如图 2 所示,设置采样频率为 10 kHz,采样时间为 10 s。

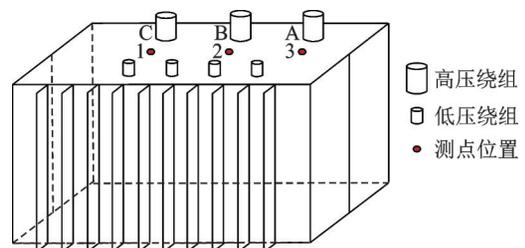


图 2 测点位置示意图

Fig.2 Diagram of measuring point position

在进行变压器绕组松动模拟实验时,每次按照抽油、吊罩以及改变变压器压紧螺母的压紧力等步骤进行实验,并利用液压系统设置变压器绕组压紧力,现场实验如图 3 所示,实验故障设置如图 4 所示。本次实验分别模拟了 3 种变压器绕组松动故障状态:①正常状态,三相绕组压紧力均为 28 MPa;②绕组不完全松动状态,其中 B 相绕组压紧力为 14 MPa,其余两相为额定压紧力;③绕组完全松动状态,其中 B 相绕组压紧力为 0,其余两相为额定压紧力。



图 3 实验现场

Fig.3 Experimental site



图 4 实验故障设置

Fig.4 Setting up experimental failure

5.2 变压器绕组松动特征提取

以采集 2 号测点的变压器振动信号为例进行分析,变压器绕组在不同压紧状态下的振动信号时域如图 5 所示。由图可知,在时域内观察 3 种压紧状态下变压器振动信号的幅值各不相同,但仅从幅值的差异中难以区分变压器绕组故障。因此,引入 VMD 及多尺度形态梯度谱来定量表征振动信号的故障特征,实现变压器绕组松动程度的判别。

利用 VMD 对 3 种状态下的变压器振动信号进行分解,并通过观察中心频率的方法^[21]确定分解模态个数 K 值。以变压器绕组正常状态为例,求得 $K=4$ 。变压器振动信号经 VMD 的处理结果如图 6 所示,可以发现不同频带的 IMF 分量和信号的原始分量基本一致,其端点效应和模态混叠现象得到抑制,能够准确地把变压器振动信号中的有效信息提取出来。为了验证 VMD 较相对于 EMD 分解的优越性,利用 EMD 对振动信号进行了处理。图 7 为变压器振动信号经 EMD 的处理结果,由图可知:EMD

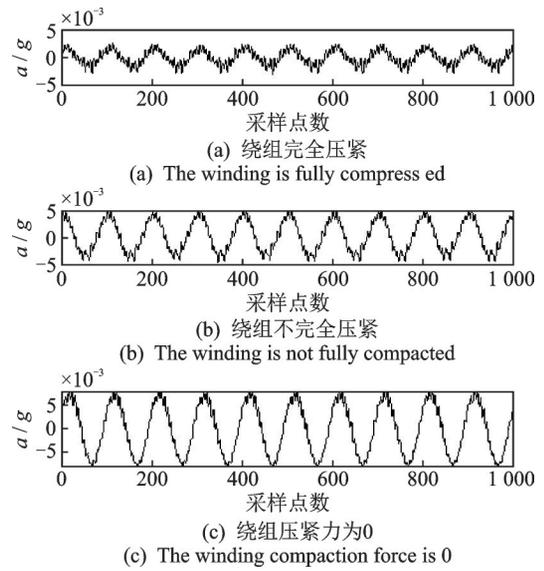


图 5 变压器振动信号时域图

Fig.5 Time-domain diagram of transformer vibration signals

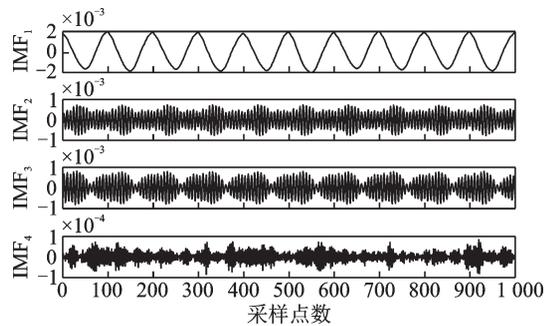


图 6 变压器振动信号经 VMD 的处理结果

Fig.6 The result of the closing signal processed by VMD

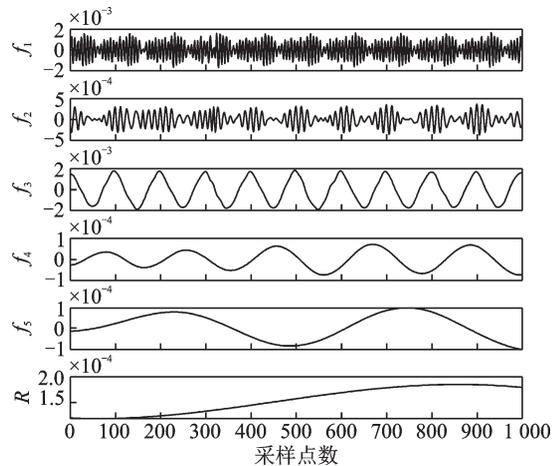


图 7 变压器振动信号经 EMD 的处理结果

Fig.7 The result of the closing signal processed by EMD

得到了 6 个模态分量,分解的层数过多且出现了虚假模态,不利于特征量的提取;VMD 对非线性振动信号实现了有效分离,改善了 EMD 固有的缺点。

用 PGS 对变压器振动信号进行分析,选取最常用的扁平型结构元素 $[0, 0, 0]$,尺度范围设为 $0 \sim$

20. 变压器正常状态下的形态谱与形态梯度谱如图 8 所示。由图可以看出:正常状态下不同分量的 PS 值随着结构元素尺度变化而产生较大波动,稳定性较差,且不同分量的 PS 值曲线重叠在一起,这是因为振动信号受噪声干扰分量影响导致的;PGS 值曲线随着结构元素尺度的增大而平滑地下降,不同分量的 PGS 值互不交叉,区分性明显,有利于下一步的变压器绕组松动状态分类识别。

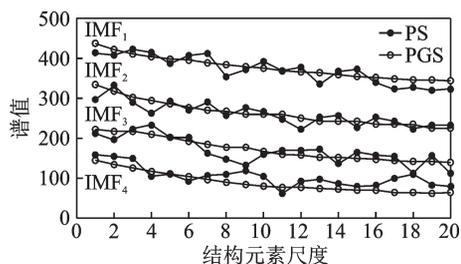


图 8 正常状态下的形态谱与形态梯度谱

Fig.8 Pattern spectrum and pattern gradient spectrum under normal condition

对变压器绕组正常状态、不完全松动及完全松动状态的振动信号进行 VMD 分解并提取特征量,以 IMF₁ 分量为例进行分析,不同状态下的形态谱与形态梯度谱如图 9 所示。由图可以看出:在变压器绕组不同松动状态下 PS 值曲线相互交叉和重叠,若将其选为故障特征则可区分度较差;PGS 值曲线对不同松动故障区分度高,并与绕组压紧力呈现良好的关联性,随着绕组松动程度加深,振动信号中的 100, 200 和 300 Hz 等各频率分量幅值均发生变化,导致其内部包含特定尺度元素的成分增多,从而在幅值整体上表现为上升的趋势。

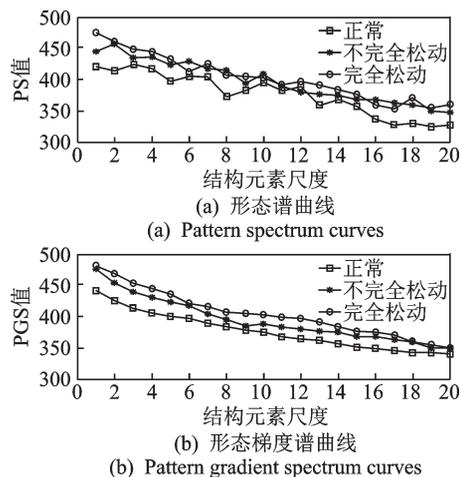


图 9 不同状态下的形态谱与形态梯度谱

Fig.9 Pattern spectrum and pattern gradient spectrum under different condition

综上所述,PGS 相比 PS 更能充分提取变压器振动信号中的特征信息,可用作初始特征向量集。

5.3 变压器绕组松动识别

采集变压器绕组不同松动状态下的振动信号,其中每种状态选取 100 组数据,共有 300 组数据样本。利用基于 VMD-PGS 的方法对实测变压器不同绕组状态振动信号进行特征提取,形成原始特征向量样本集,每组数据样本构成 4×20 的特征矩阵。为了防止维数灾难,去除冗余信息,提高分类识别速度,采用主成分分析法重构低维、高识别度的特征向量,然后取累计贡献率达到 90% 的特征主成分作为最优特征子集。

为了验证笔者所提方法能有效提取振动信号中的故障特征,同时采用 VMD-PGS, VMD-PS, EMD-PGS 以及直接对原始信号 3 种方式进行特征提取,再将最优特征输入到 BAS-RF 进行识别。其中,EMD-PGS 方法是将原始振动信号经过 EMD 分解后,利用相关系数法筛选出前 4 个对故障敏感的分量,求取各分量的 PGS 并用主成分分析法得到最优特征向量,再输入到 BAS-RF 进行训练和测试。从每种状态随机选取 50 组用于训练,其余 50 组作为测试集进行测试。计算时设定 BAS 算法的初始左、右天牛须距离为 2,初始步长为 4,迭代次数为 100。RF 中的参数 *b* 和 *l* 设定取值范围分别为 [1, 500] 和 [1, 300]。为了减小偶然因素的影响,共重复进行了 10 次独立实验,每次实验都从原始数据集中随机选择训练和测试数据,使用不同方法比较诊断性能。10 次试验下不同方法的诊断准确率对比如图 10 所示,不同方法性能比较如表 1 所示。

由表 1 可知:基于 VMD-PGS 方法得到的特征向量故障识别率最高,可达 100%;10 次试验的平均故障识别准确率为 98.07%,均高于其他方法的识别准确率。这是由于 EMD 自身的递归分解模式使得对信号进行处理时存在很大的弊端,导致分解出现

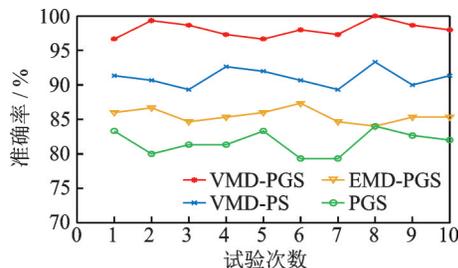


图 10 10 次试验下不同方法的诊断准确率对比

Fig.10 Comparison of diagnostic accuracy using different methods under 10 trials

表1 不同方法性能比较

Tab.1 Performance comparison of different methods

方法	平均准确率/%	运行时间/s
VMD-PGS	98.07	35
VMD-PS	91.10	49
EMD-PGS	85.53	56
PGS	81.67	71

模态混叠现象,造成提取的特征可区分度不高;而VMD是一种非递归的分解模式,具有完备的数学理论和带通滤波器组结构特性,能将各个分量实现有效分离。此外,与传统的PS相比,PGS值的平滑性很好,减小了由于特征值上下波动而带来的误判,更有利于变压器绕组不同松动状态的识别。

为了证明采用BAS-RF的收敛速度和分类准确度要优于其他传统方法,将其与GA-RF,PSO-RF和RF作比较,并将基于VMD-PGS方法得到的特征向量分别输入到不同分类器。其中:设定GA算法的变异概率为0.01,交叉概率为0.6;PSO算法局部搜索能力为2,全局搜索能力为2;种群数量都设为20,最大迭代次数为100。不同分类算法的诊断结果如表2所示,3种优化算法迭代曲线见图11。

表2 不同分类算法的诊断结果

Tab.2 Diagnostic results of different algorithms

分类模型	平均准确率/%	运行时间/s
BAS-RF	98.07	35
GA-RF	92.67	67
PSO-RF	90.73	58
RF	88.10	101

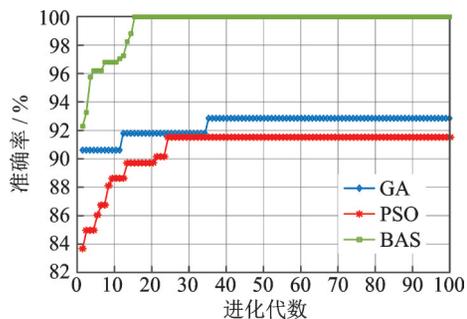


图11 3种优化算法迭代曲线图

Fig.11 Iterative process curves of three optimization methods

由表2可以看出,未经优化的RF故障识别准确率最低,所运行的时间也最长,这是因为没有进行参数优化,导致分类精度不佳。使用粒子群算法和遗传算法对RF进行优化后,虽然使其平均故障识别准确率提高到90%以上,且运算时间也有所提高,

但仍低于笔者提出的BAS-RF模型故障识别准确率和运行时间。与BAS相比,GA和PSO算法优化RF时易陷入局部最优解,导致模型泛化性能较差,故障识别准确率较低。综上所述,随机森林模型决策树的个数以及树的深度选取对识别结果准确性有较大影响,BAS具有良好的优化性能。

6 结论

1) 采用VMD和PGS相结合的方法可以从受背景噪声干扰的变压器振动信号中提取出不同尺度下的特定形态特征信息,相对于其他提取方法,其在对绕组松动故障特征定量描述上有更好的效果。

2) 通过主成分分析法对初始特征集进行优选,可以构造低维特征空间,消除冗余信息,提高变压器松动故障识别的计算效率和分类精确度。

3) 提出一种BAS-RF分类识别算法,实验结果表明,BAS-SVM分类器平均识别准确率达到98.07%,在运行时间和识别率方面都要优于传统的PSO-RF,GA-RF和RF方法。

参 考 文 献

- [1] 马宏忠,弓杰伟,李凯,等.基于ANSYS Workbench的变压器绕组松动分析及判定方法[J].高电压技术,2016,42(1):192-199.
MA Hongzhong, GONG Jiwei, LI Kai, et al. Analysis and determination method for transformer winding looseness based on ANSYS Workbench[J]. High Voltage Engineering, 2016, 42(1):192-199.(in Chinese)
- [2] 杨毅,刘石,张楚,等.基于振动分布特征的电力变压器绕组故障诊断[J].振动与冲击,2020,39(1):199-208.
YANG Yi, LIU Shi, ZHANG Chu, et al. Winding fault diagnosis of power transformer based on vibration distribution features[J]. Journal of Vibration and Shock, 2020, 39(1):199-208.(in Chinese)
- [3] GARCIA B, BURGOS J C, ALONSO A M. Winding deformations detection in power transformers by tank vibrations monitoring[J]. Electric Power Systems Research, 2005, 74(1):129-138.
- [4] GARCIA B, BURGOS J C, ALONSO A M. Transformer tank vibration modeling as a method of detecting winding deformations-part II: experimental verification[J]. IEEE Transactions on Power Delivery, 2006, 21(1):164-169.
- [5] 赵妙颖,许刚.基于经验小波变换的变压器振动信号特征提取[J].电力系统自动化,2017,41(20):63-69,91.

- ZHAO Miaoying, XU Gang. Feature extraction for vibration signals of power transformer based on empirical wavelet transform [J]. Automation of Electric Power Systems, 2017, 41(20):63-69,91.(in Chinese)
- [6] 汲胜昌,刘味果,单平,等.小波包分析在振动法监测变压器铁芯及绕组状况中的应用[J].中国电机工程学报,2001(12):25-28.
JI Shengchang, LIU Weiguo, SHAN Ping, et al. Application of the wavelet packet to the monitoring of the core and winding condition of transformer[J]. Proceedings of the CSEE, 2001(12):25-28.(in Chinese)
- [7] 雷亚国.基于改进Hilbert-Huang变换的机械故障诊断[J].机械工程学报,2011,47(5):71-77.
LEI Yaguo. Machinery fault diagnosis based on improved Hilbert-Huang transform[J]. Journal of Mechanical Engineering, 2011, 47(5):71-77. (in Chinese)
- [8] ANEESH C, KUMAR S, HISHAM P M, et al. Performance comparison of variational mode decomposition over empirical wavelet transform for the classification of power quality disturbances using support vector machine [J]. Procedia Computer Science, 2015, 46:372-380.
- [9] 刘长良,武英杰,甄成刚.基于变分模式分解和模糊C均值聚类的滚动轴承故障诊断[J].中国电机工程学报,2015.35(13):1-8.
LIU Changliang, WU Yingjie, ZHEN Chenggang. Rollingbearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering [J]. Proceedings of the CSEE, 2015, 35(13):1-8. (in Chinese)
- [10] MARAGOS P. Pattern spectrum and multiscale shape representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(7):701-716.
- [11] DONG Y B, LIAO M F. Fault diagnosis of rolling element bearing based on modified morphological method [J]. Mechanical Systems and Signal Processing, 2011, 25(4):1276-1286.
- [12] 王书涛,张金敏,李圆圆,等.基于数学形态学和模糊聚类的旋转机械故障诊断[J].仪器仪表学报,2012,33(5):1055-1061.
WANG Shutao, ZHANG Jinmin, LI Yuanyuan, et al. Rotating machinery fault diagnosis based on mathematical morphology and fuzzy clustering[J]. Chinese Journal of Scientific Instrument, 2012, 33(5):1055-1061. (in Chinese)
- [13] 胡振邦,张东升,章云,等.数学形态学滤波器在转子失衡识别中的应用[J].振动、测试与诊断,2014,34(6):1038-1044.
HU Zhenbang, ZHANG Dongsheng, ZHANG Yun, et al. Research of rotor unbalance recognition based on mathematical morphology filter [J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(6):1038-1044. (in Chinese)
- [14] LIM S, ZHU J. Integrated data envelopment analysis: global and local optimum [J]. European Journal of Operational Research, 2013, 229(1):276-278.
- [15] 李赢,舒乃秋.基于模糊聚类和完全二叉树支持向量的变压器故障诊断[J].电工技术学报,2016,31(4):64-70.
LI Ying, SHU Naiqiu. Transformer fault diagnosis based on fuzzy clustering and complete binary tree support vector machine [J]. Transactions of China Electrotechnical Society, 2016, 31(4):64-70.(in Chinese)
- [16] 胡青,孙才新,杜林,等.核主成分分析与随机森林相结合的变压器故障诊断方法[J].高电压技术,2010,36(7):1725-1729.
HU Qing, SUN Caixin, DU Lin, et al. Transformer fault diagnosis method using random forests and kernel principle component analysis [J]. High Voltage Engineering, 2010, 36(7):1725-1729.(in Chinese)
- [17] MENZE B H, KELM M B, MASUCH R, et al. A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data [J]. BMC Bioinformatics, 2009, 10(1):1-16.
- [18] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.
- [19] RODRIGUEZ-GALIANO V F, GHIMIRE B, ROGAN J, et al. An assessment of the effectiveness of a random forest classifier for land-cover classification [J]. ISPRS Journal of Photogrammetry & Remote Sensing, 2012, 67:93-104.
- [20] JIANG X, LI S. BAS: beetle antennae search algorithm for optimization problems [J]. International Journal of Robotics and Control, 2017, 1(1):1-5.
- [21] 程珩,励文艳,权龙,等.基于VMD-MDE和ELM的柱塞泵微弱故障诊断[J].振动、测试与诊断,2020,40(4):635-642.
CHENG Hang, LI Wenyan, QUAN Long, et al. Weak fault diagnosis of axial piston pump based on VMD-MDE and ELM [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(4):635-642. (in Chinese)



第一作者简介:颜锦,男,1995年8月生,硕士。主要研究方向为变压器故障诊断与状态监测。

E-mail:qq804302585@163.com