基于 KELM-VPMCD 方法的未知局部放电类型的模式识别

高佳程1,曹雁庆2,朱永利1,贾亚飞1

(1. 华北电力大学 新能源电力系统国家重点实验室,河北 保定 071003;

2. 国电电力发展股份有限公司,北京 100101)

摘要:为了解决局部放电类型未知的样本无法被正确识别的问题,提出了一种基于核极限学习机-变量预测模型(KELM-VPMCD)的未知局部放电类型的识别方法。通过 KELM 对已知局部放电类型的训练样本进行 训练,然后对各局部放电类型已知的样本建立相应的变量预测模型。利用这些模型对测试样本进行回归预 测。根据各样本的预测误差平方和,利用 Otsu 算法设置误差阈值,通过阈值识别各样本的局部放电类型。识 别结果表明,所提方法对于未知的局部放电类型具有较高的正确识别率。

关键词:局部放电;模式识别;核极限学习机;变量预测模型 中图分类号:TM 835 文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.05.021

0 引言

电网中电气一次设备绝缘性能的优劣直接影响 到整个电网的安全运行。局部放电 PD(Partial Discharge)是电气一次设备内部绝缘劣化的重要征兆 和主要表现形式^[1]。电力设备内部绝缘劣化的机理 不同,引起的局部放电类型也不同,而不同的局部放 电类型对设备绝缘造成的损害程度不同。因此,进 行局部放电类型的模式识别已经成为了一次设备状 态评估方面的重要组成部分^[2]。

分类器的设计是模式识别工作中的重要环节。 在局部放电的模式识别中,常用的分类方法主要 有^[3-6]:神经网络 ANN (Artificial Neural Network)、支 持向量机 SVM (Support Vector Machine)、模糊聚类 FC(Fuzzy Cluster)和贝叶斯分类 BC(Bayesian Classifier)等,这些方法在工程中都取得了良好的分类效 果,但并不能识别出未包含在已有的局部放电类型 训练样本库中的局部放电类型。即对于那些不属于 局部放电类型训练样本库中任何一种已知放电类型 的局部放电,现有分类方法无法进行正确归类。而 在实际的工程应用中,由于电力设备复杂、故障多 样,已有的局部放电类型训练样本库中不可能包含 所有局部放电类型,必然存在一定的疏漏,而构建绝 对完备的样本库工作量巨大,并不可行。因此,如何 识别这些未知类型的局部放电样本是局部放电模式 识别中的一项重要内容,而有关这一方面的研究非 常少。

目前在故障诊断中,单分类方法可用于识别未 知类型样本。单分类方法主要可以划分为密度估计 方法和边界方法2类。密度估计方法依据一定的概

收稿日期:2018-01-15;修回日期:2018-03-29

基金项目:国家自然科学基金资助项目(51677072)

率密度分布,根据经验风险设置相应的密度阈值,将 所有概率密度低于该阈值的样本判定为未知类型样 本。当样本规模足够大时,密度估计的效果较好^[7]。 但当样本数目有限,或分布模型不适合数据时将会 出现较大偏差,从而无法对目标样本做出正确的判 定。边界方法主要包括单分类支持向量机^[8] OCSVM (One-Class Support Vector Machine)和支持向量数据 描述^[9] SVDD(Support Vector Data Description),这2 种方法存在一定程度的等效,它们利用有限的样本 数据,通过优化目标函数获取样本集合的封闭边界。 边界方法避免了密度估计法对于样本数量的苛求, 但在很大程度上依赖于训练样本性能的优劣和参数 的选择,并且计算效率很低。另外,一些聚类算法也 可以用于未知样本的识别,但这些算法大多计算速 度偏低,而且对于类型已知的样本仍需进行后续识 别以确定其类别。

基于变量预测模型的模式识别 VPMCD(Variable Predictive Model based Class Discriminate)是由 Rahuraj 等人提出的一种模式识别方法^[10]。VPMCD 方法依 据各特征值之间相互内在的联系,针对不同的类别, 对各个特征值建立反映这种特征值之间相互内在关 系的变量预测模型(VPM)。利用建立好的 VPM 对 测试样本的特征向量进行回归预测,利用预测误差 平方和构建判别函数,从而实现模式识别^[11]。

然而,VPMCD 方法使用多项式响应面法建立 VPM,高阶计算量很大,无法随着样本容量的增大而 有效提高其近似精度,这严重限制了方法的使用^[12]。 极限学习机 ELM(Extreme Learning Machine)法是由 Huang 等人提出的一种单层前馈神经网络算法,该 方法利用核极限学习机(KELM)将核函数引入 ELM 中,构成具有最小平方最优解的 ELM,具有可调参数 少、收敛速度快、泛化性能较好等优点^[13]。

本文提出了一种基于 KELM 的改进 VPMCD (KELM-VPMCD)方法,用于识别未知的局部放电类

Project supported by the National Natural Science Foundation of China(51677072)

型。首先,利用不同的局部放电模型采集局部放电 样本,提取相应的放电特征向量;然后,将 KELM 回 归与 VPMCD 方法结合,用 KELM 回归模型替代原 VPMCD 方法中的多项式响应面模型,训练已知类型 的局部放电样本,获得相应的 VPM;然后,利用训练 好的各 VPM 对测试样本进行预测;最后,依据 Otsu 算法对样本回归得到的期望方差划分阈值,判定样 本的局部放电类型是已知还是未知。

1 KELM-VPMCD 方法的基本原理

1.1 VPMCD 方法的基本原理

设某一样本 x 可由 p 个特征值描述,其特征向 量形式可表示为 $x = [X_1, X_2, \dots, X_p]$ 。x 中的某一特 征值 X_i 与其他的 1 个或多个特征值之间存在着一定 的线性或非线性函数关系。当样本类型不同时,各 特征值之间的相互关联也不同。为了识别不同的样 本类型,需要建立能够表征特征值 $X_1 - X_p$ 间关系的 VPM,以便对测试样本的特征值进行回归预测,进一 步实现对样本类型的正确划分。为特征值 X_i 建立 对应的变量预测模型 VPM_i,可选择的模型主要包括 线性模型(L)、线性交互模型(LI)、二次交互模型 (QI)和二次模型(Q)^[11]。

对特征值*X_i*进行预测,其对应的变量预测模型 VPM_i可表示为:

$$X_i = f(X_i, \cdots, X_l, b_a, \cdots, b_a, r) + \varepsilon$$
(1)

其中, $1 \leq j \leq l \leq p \perp j, q \neq i; b_q, \dots, b_s$ 为模型参数;r为模型阶数且 $r \leq p-1; \varepsilon$ 为预测误差。

对于某一样本类型,若预测模型的类型、阶数以 及对 X_i 的预测变量确定,则参数 b_q — b_o 可通过多项 式响应面法求解获得:

$$Y = D \cdot \boldsymbol{B} \tag{2}$$

其中,Y为模型响应值,即 X_i 的预测值;D为输入变量的多项式基函数;B为模型参数矩阵。

对于第 k 种样本类型, 在模型类型和阶数确定的前提下, 根据预测变量 X_j 的不同组合, 可得到 C_{p-1}^r 种 X_i 的变量预测模型 VPM^k_i, 以拟合误差平方和 最小的目标函数, 寻求最优 VPM^k_i, 即:

$$\min J_k(\boldsymbol{B}) = \min \| \boldsymbol{D} \cdot \boldsymbol{B} - X_i \|^2$$
(3)

对于g种不同的样本类型,经过训练建立 $g \times p$ 个预测模型 VPM^k_i($k=1,2,\dots,g$)。

VPMCD 方法对测试样本利用 VPM^k_i 得到 $g \times p$ 个特征量预测值 \hat{X}^{k}_{i} ,以同一类别下所有特征值的预测误差平方和 $\| S^{k} \|$ 最小为判别函数,对测试样本的类型进行分类,即样本类别 L^{*} 为:

$$L^* = \underset{k}{\arg} \min \| S^k \| = \underset{k}{\arg} \min \sum_{i=1}^{p} (X_i - \hat{X}_i^k)^2 \quad (4)$$

1.2 KELM 的基本原理

ELM 是一种新型的单层前向型神经网络。相较于传统的人工神经网络,ELM 仅通过一步计算即可解析出网络的输出权值,极大地提高了网络的泛化能力和学习速度,具有较强的非线性拟合能力,其计算量和搜索空间也得到了大幅的降低^[14-15]。ELM 的网络结构如图1所示。



图 1 ELM 的网络结构

Fig.1 Network structure of ELM

设给定 *N* 个训练样本 { $(\mathbf{x}_{i}, \mathbf{t}_{i})$ }^{*N*}_{*i*=1}, 输入数据 $\mathbf{x}_{i} = [X_{i1}, X_{i2}, \dots, X_{ip}]^{T} \in \mathbf{R}^{p}$, 目标输出值 $\mathbf{t}_{i} = [T_{i1}, T_{i2}, \dots, T_{im}] \in \mathbf{R}^{m}$ 。含 *K* 个隐含层节点、激励函数为 $g_{i}(\mathbf{x}_{i})$ 的 ELM 网络模型可以表示为:

$$\mathbf{y}_i = \sum_{j=1}^{K} \boldsymbol{\beta}_j g_j(\mathbf{x}_i; \boldsymbol{\omega}_j, b_j) \quad i = 1, 2, \cdots, N \quad (5)$$

其中, $y_i \in \mathbb{R}^m$ 为网络的输出值; β_j 为连接隐含层与 输出层的输出权值; $g_j(x_i; \omega_j, b_j)$ 为第j 个隐含层节 点的激活函数; ω_j 为连接第j 个隐含层节点和输入 节点之间的权重; b_j 为网络第j 个隐含层节点的 偏置。

当激活函数 $g(\cdot)$ 能够零误差地逼近任意 N 个 样本,即存在 $\sum_{i=1}^{N} ||y_i - t_i|| = 0$ 时,可得:

$$\boldsymbol{t}_i = \sum_{j=1}^{K} \boldsymbol{\beta}_j \boldsymbol{g}_j (\boldsymbol{\omega}_j \cdot \boldsymbol{x}_i + \boldsymbol{b}_j) \quad i = 1, 2, \cdots, N \quad (6)$$

输出权值 $\boldsymbol{\beta}$ 的求解等价于求取线性方程组 $H=\boldsymbol{\beta}T$ 的最小二乘解 $\boldsymbol{\beta}^*$ 。根据广义逆理论,其解如式(7)所示。

$$\boldsymbol{\beta}^* = \boldsymbol{H}^{\mathrm{T}} \boldsymbol{T} = \boldsymbol{H}^{\mathrm{T}} (\boldsymbol{H} \boldsymbol{H}^{\mathrm{T}})^{-1}$$
(7)

其中,**H**为 ELM 的隐含层输出矩阵;**H**⁺为隐含层输 出矩阵 **H** 的广义逆;**T** 为期望输出向量。

在隐含层特征映射 $h(\mathbf{x})$ 未知的情况下,将核函数引入 ELM 中^[15],利用核矩阵 $\boldsymbol{\Omega}_{ELM}$ 替代随机矩阵 \boldsymbol{HH}^{T} :

$$\begin{cases} \boldsymbol{\Omega}_{\text{ELM}} = \boldsymbol{H}\boldsymbol{H}^{\text{T}} \\ \boldsymbol{\Omega}_{i,j} = h(\boldsymbol{x}_i) \cdot h(\boldsymbol{x}_j) = K(\boldsymbol{x}_i, \boldsymbol{x}_j) \end{cases}$$
(8)

其中, $h(\cdot)$ 为隐含层节点输出函数; $K(\cdot)$ 为核函数, 通常设定为径向基函数(RBF)核,如式(9)所示。

$$K(\boldsymbol{x}_i, \boldsymbol{x}_j) = \exp\left(-\frac{\|\boldsymbol{x}_i - \boldsymbol{x}_j\|^2}{\sigma^2}\right)$$
(9)

其中,σ为核参数。

KELM 模型的输出为:

$$\mathbf{y}(\mathbf{x}) = h(\mathbf{x}) \mathbf{H}^{\mathrm{T}} (\mathbf{I}/C + \mathbf{H}\mathbf{H}^{\mathrm{T}})^{-1} \mathbf{T} =$$

 $\begin{bmatrix} K(\mathbf{x}, \mathbf{x}_{1}) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_{N}) \end{bmatrix} (\mathbf{I}/C + \mathbf{\Omega}_{\mathrm{ELM}})^{-1} \mathbf{T}$ (10)

其中,I为对角矩阵;C为惩罚参数。

相较于 ELM, KELM 算法不需单独设定网络隐 含层节点的特征映射函数 h(x) 的具体形式以及节 点个数,也不需要设定隐含层的初始权重和偏置,而 只需确定核函数 $K(\cdot)$ 的具体形式即可求出 KELM 模型的输出值。

1.3 基于 KELM-VPMCD 的模式识别方法

在原 VPMCD 方法中,当依据误差平方和最小确定最优模型 VPM^k_i时,存在严重的"过拟合"问题,并且高阶计算量很大。本文利用 KELM 回归替代原 VPMCD 方法中的多项式响应面回归对样本进行回归预测。

KELM-VPMCD 方法的实现过程如下^[13]。

(1) 训练过程。

a. 步骤 1:对于 g 分类问题,共收集 N 个训练样本,且 $N = n_1 + \dots + n_k + \dots + n_g$ 。提取样本特征值 $x_j = [X_{i_1}, X_{i_2}, \dots, X_{i_p}](j=1, 2, \dots, N)$ 。

b.步骤 2:令 *k*=1、*i*=1。

c. 步骤 3:优化惩罚参数 C_k 和核参数 σ_k 。

d. 步骤 4:利用 n_k 个第 k 类样本进行训练,利用 KELM 回归对第 i 个特征值建立 VPM^k_i。

e. 步骤 5:*i*←*i*+1,循环步骤 4,直至 *i*=*p* 时结束循环。

f. 步骤 6:*k*←*k*+1,循环步骤 3—5,直至 *k*=*g* 时 结束循环。至此,训练共获得 *g*×*p* 个 VPM。

(2) 测试过程。

a. 步骤 1:对于 *n* 个测试样本,提取特征值 **x**_j = [X_{i1}, X_{i2}, …, X_{ip}](j=1,2, …, n)。

b. 步骤 2:令 *j*=1、*k*=1。

c. 步骤 3: 对任一测试样本 \mathbf{x}_{j} 利用 VPM^k₁ VPM^k_p 对 X_{j1} — X_{jp} 进行预测,获得预测值 $\hat{\mathbf{x}}_{j}^{k} = [\hat{X}_{j1}^{k}, \hat{X}_{j2}^{k}, \cdots, \hat{X}_{jp}^{k}]_{\circ}$

d. 步骤 4:计算预测误差平方和 || $S_j^k || = \sum_{i=1}^p (X_{ji} - \hat{X}_{ij}^k)^2$ 。

e. 步骤 5:k←k+1,循环步骤 3、4,直至 k=g 时
 结束循环。以预测误差平方和最小为判别函数,样
 本 x_j 的类别标签 L^{*}(x_j)可由式(11)确定。

$$L^{*}(\mathbf{x}_{j}) = \underset{k}{\arg \min} ||S_{j}^{k}|| = \underset{k}{\arg \min} \sum_{i=1}^{p} (X_{ji} - \hat{X}_{ji}^{k})^{2}$$
(11)

f. 步骤 6:*j*←*j*+1,循环步骤 3—5,直至 *j*=*n* 时结束,至此,完成了对所有测试样本类型的识别。

1.4 标准数据仿真分析

选择 UCI 数据库中的 Iris 和 Seeds 数据集进行 仿真分析,验证 KELM-VPMCD 方法的可行性。Iris 数据集包含 3 类数据,每组数据包含 4 个属性,每类 数据随机抽取 50 组,其中 30 组作为训练样本,20 组 作为测试样本。Seeds 数据集包含 3 类数据,每组数 据包含 7 个属性,每类数据随机抽取 70 组,其中 40 组作为训练样本,30 组作为测试样本。将本文方法 与 VPMCD 方法、BP 神经网络和 SVM 方法进行对 比。BP 神经网络选择 3 层,激活函数选择 sigmoid 函数;SVM 方法选用 RBF 为核函数。2 类数据集的 识别结果如附录中的表 A1 所示。由表中结果可知, 对于 Iris 和 Seeds 数据集,相较于其他方法,KELM-VPMCD 方法均具有很高的正确识别率,即能有效地 对待测样本进行分类。

2 基于 KELM-VPMCD 方法的未知局部放电 类型的识别

利用 KELM-VPMCD 方法对待测样本进行放电 类型的识别时,利用训练后的某种放电类型的 VPM 对各测试样本的特征值进行预测,计算预测误差平 方和。以预测误差平方和误差是否小于规定阈值为 判别函数,判断测试样本是否属于该类局部放电。 若样本不属于任何已知的局部放电类型,则判定该 样本的局部放电类型为未知。

利用 VPM 对 n 个局部放电样本的各个特征变 量进行预测,并求取预测误差平方和向量 S_{SEj}(j=1, 2,…,n)。若第 j 个局部放电样本属于第 g 类局部 放电类型,则利用相应的 VPM 进行预测所得到的 S_{SEj}应该在其阈值区间内。若 S_{SEj}超过了相应的阈 值,则说明该局部放电样本不属于此类局部放电。 各种局部放电类型的误差平方和阈值可由 Otsu 算 法获得^[16]。基于 KELM-VPMCD 的样本放电类型的 识别流程如图 2 所示。

基于 KELM-VPMCD 的样本放电类型识别具体 步骤如下。

a. 以所有训练样本和测试样本构成集合 *S*,依据 1.3 节对训练样本进行训练,建立相应的变量预测模型 VPM^{*k*}_{*i*}。

b. 令 k=1,利用 VPM^k₁—VPM^k_p 对集合 S 中的样本进行预测,得到相应的 $S_{SEkj}(j=1,2,\dots,n+N)$ 。

c. 将所有 S_{SEkj} 依据大小划分为 1—m 个等级, 其中 max { S_{SEkj} } 对应等级 m,min { S_{SEkj} } 对应等级 1。





d. 利用 Otsu 算法对所有 *S*_{SE4} 划分阈值 *T*,并求 得 *T* 对应的阈值 *S*_{SE47}。

e. 根据阈值 S_{SEKT} 判别测试样本是否属于第 k 类 局部放电类型。若第 j 个样本属于第 k 类放电,则该 测试样本完成放电类型的判别;若不属于,则对继续 该样本进行第 k+1 类放电类型的判别。

f. 令 k = k + 1, 重复步骤 **b**—**e** 直至 k = g 结束。 至此, 测试样本集合中所有属于已知局部放电类型的样本已经完成判别并进行了分类。

g. 当 *k*=*g* 时,测试样本集合中的剩余样本判别为未知局部放电类型的样本。

3 局部放电样本识别及结果分析

3.1 局部放电样本的采集与特征提取

据电气设备局部放电的形式和特点,在实验室 中构造悬浮放电、板对板放电、针板放电和电晕放电 这4种局部放电模型,如图3所示。

本文采用传统的脉冲电流法监测局部放电信号,采用的测量标准为 IEC60270—2000。实验中使

用 TWPD-2F 局部放电综合分析仪采集放电信号,采 样频率为 40 MHz,带宽为 40~300 kHz。高压实验平 台型号为 TWI 5133 - 10/100 am^[17],实验接线图如 图 4 所示。本文以每个工频周期记录得到的数据作 为一个局部放电样本。





(a)悬浮放电





(c) 针板放电

图 3 4 种局部放电模型

Fig.3 Four types of PD model



图 4 实验接线示意图

Fig.4 Experimental wiring diagram

本文采用文献[17]提出的基于变分模态分解 VMD(Variational Mode Decomposition)算法和样本熵 的特征提取方法:首先利用 VMD 算法对采集到的 1 个周期内的放电波形进行分解,得到各个不同中心 频率的固有模态函数;然后,对每个模态分量提取样 本熵;最后,将每个样本的不同模态函数的样本熵共 同构成该样本的特征向量。

3.2 识别结果及分析

为了充分验证本文所提方法的有效性,本文依次选取4种局部放电模型中的一种作为已知局部放电类型,其他3种局部放电模型作为已知样本以外的未知局部放电类型。从3类已知类型的局部放电 样本中随机抽取一部分信号和假定的未知类型的局部放电样本中随机抽取一部分信号和假定的未知类型的局部放电样本共同组成测试样本。采用已知类型的局部放电样本对 KELM-VPMCD 分类器进行训练以确定相应的 VPM,然后对测试样本进行判断。 每种局部放电模型有 50 个采集样本,则共有 200 个样本。3 种已知类型的放电各随机选取 30 个,构成训练样本集合。随机抽取 20 个未知类型的 局部放电样本与剩余所有已知类型的样本,共同构 成测试样本集合。这样,对于每次试验,训练样本中 包含 90 个样本,测试样本中包含 80 个样本。

当选定未知放电类型后,利用 KELM-VPMCD 方法对训练样本进行训练,然后对测试样本进行回 归预测,得到所有样本的误差平方和。利用粒子群 优化(PSO)算法优化参数(*C*,σ),然后对样本的平 方误差划分等级,并利用 Otsu 算法求解每种已知局 部放电类型的阈值 *T* 及对应误差平方和。本文选定 最大等级 *m*=50。依次轮流设定不同局部放电类型 作为未知局部放电类型,在所有可能的情况下,优化 后的参数以及各已知局部放电类型样本在 Otsu 算 法下的判别阈值如表 1 所示。

表 1 参数(C,σ)及误差平方和的 Otsu 阈值 Table 1 Parameters(C,σ) and Otsu thresholds of MSE

_		~(<i>°</i> , <i>°</i> , <i>°</i> ,		
	局部放电类型	(C,σ)	Т	误差平方和
	悬浮放电	(0.51,1.41)	12	0.079 8
	板对板放电	(0.47,0.13)	21	0.100 8
	针板放电	(0.50,0.18)	15	0.097 5
	电晕放电	(0.50,1.05)	14	0.103 6

利用 KELM-VPMCD 方法对局部放电样本进行 训练和识别,同时与 OCSVM、SVDD 和密度估计方 法以及传统 VPMCD 方法对样本集合的识别结果进 行对比。其中,OCSVM 与 SVDD 方法均采用高斯核 函数,密度估计方法的密度估计模型选择高斯密度 估计模型。各方法的相关参数见附录中的表 A2。

依次设定不同的局部放电类型作为未知的局部 放电类型,利用不同识别方法对局部放电样本进行 识别。在不同的未知局部放电类型的条件下,各识 别方法对已知与未知局部放电类型的识别结果见附 录中的表 A3。各种识别方法对 4 种不同的局部放 电类型的正确识别率见附录中的表 A4。

由表 A3、A4中的数据分析可得,KELM-VPMCD 方法对局部放电样本的识别率最高,识别效果最佳。 尤其针对未知局部放电类型的样本,KELM-VPMCD 方法的识别效果明显优于其他方法。这是因为 KELM-VPMCD 方法着重考虑了各特征量间的内在 联系,并且避免了传统 VPMCD 方法中回归模型确 定和阶数选择困难的问题,稳定性更强。表 A3中结 果显示,当选定不同类型的局部放电样本作为未知 局部放电类型样本进行识别时,单分类的 OCSVM 方 法与 SVDD 方法所得到的结果差异明显,这是由于 OCSVM 与 SVDD 方法受样本空间中特征量的分布 影响较大造成的。样本分布集中程度高,类内、类间 差异小,识别效果好;反之,识别效果差。图 5 为 4



种类型的局部放电样本特征量的空间分布,图中, X_1, X_2 和 X_3 为特征空间的三维特征量。

结合图 5,当选定的训练样本类间差异很大,如 选择悬浮放电、板对板放电和电晕放电为已知局部 放电类型时,OCSVM 方法与 SVDD 方法对未知样本 的识别效果很差。而 KELM-VPMCD 方法突出考量 了特征值间的内在联系,因此在样本特征向量的表 示上存在足够的裕度,在样本数量较少或样本质量 较差时仍能具备良好的识别效果。

同时,针对4种不同的放电类型,结合表A3、表A4和图5结果分析可得:电晕放电的识别效果较为理想,板对板放电的识别效果较差。这是由于电晕放电的放电脉冲具有明显的极性效应,局部放电样本的空间分布集中放电特征明显,而板对板放电的局部放电样本空间分布分散,类内差异较大,所以识别率低。

4 结论

在电力设备局部放电模式识别中,存在对未知 类型的局部放电样本识别困难的问题。本文提出了 一种基于 KELM-VPMCD 的局部放电模式识别方法, 并将其应用于电力设备局部放电类型的识别中,实 现了对未知局部放电类型的正确识别。

a. KELM-VPMCD 方法充分利用特征变量之间的相互内在关系,以已知局部放电类型的 VPM 对未知类型的局部放电样本进行回归预测,其预测误差较为明显。因此,利用 Otsu 算法确立误差阈值后, KELM-VPMCD 方法可以有效地识别未知类型的局部放电样本。

b. KELM-VPMCD 方法采用 KELM 回归模型替 代了原多项式响应面模型,避免了模型选择和阶数 确定困难的问题。相较于 BP 神经网络和 SVM 分类 方法,KELM-VPMCD 方法设置参数少,避免了出现 局部最优的可能。

c. 与传统的单分类方法相比,KELM-VPMCD 方 法适应性强,对训练样本要求低,在训练样本数量较 少及样本类间、类内差异较大时仍能取得较高的正 确识别率。 d. 本文只是采用实验数据对所提出的方法进行了验证,而实际工程中,可能存在更多种已知和未 知类型的局部放电。因此,在实际应用中,需将已经 确定的样本作为训练样本,据此判断待测样本是否 都属于已知类。

致 谢

本文得到了中国国电集团公司的资助,特表 感谢!

附录见本刊网络版(http://www.epae.cn)。

参考文献:

[1]段伟润,张宇辉,李天云.抑制局部放电信号中周期性窄带干扰的子空间重构方法[J].电力自动化设备,2017,37(7):178-183.

DUAN Weirun,ZHANG YUhui,LI Tianyun. Subspace reconstruction to suppress periodic narrowband noises of partial discharge signals [J]. Electric Power Automation Equipment, 2017, 37(7): 178-183.

- [2] 刘凡,张昀,姚晓,等. 基于 K 近邻算法的换流变压器局部放电模式识别[J]. 电力自动化设备,2013,33(5):89-93.
 LIU Fan,ZHANG Yun,YAO Xiao, et al. Recognition of PD mode based on KNN algorithm for converter transformer [J]. Electric Power Automation Equipment,2013,33(5):89-93.
- [3]田质广,张慧芬,郎立国.基于遗传算法的神经网络在发电机定 子超高频局部放电模式识别中的应用[J].电力自动化设备, 2005,25(8):43-47.

TIAN Zhiguang, ZHANG Huifen, LANG Liguo. Application of genetic algorithm based on neural network in UHF PD recognition of generator stator [J]. Electric Power Automation Equipment, 2005, 25 (8):43-47.

- [4] 弓艳朋,刘有为,吴立远.采用分形和支持向量机的气体绝缘组 合电器局部放电类型识别[J].电网技术,2011,35(3):135-139.
 GONG Yanpeng,LIU Youwei,WU Liyuan. Identification of partial discharge in gas insulated switchgears with fractal theory and support vector machine [J]. Power System Technology, 2011, 35 (3):135-139.
- [5] 杨志超,范立新,杨成顺,等. 基于 GK 模糊聚类和 LS-SVC 的 GIS 局部放电类型识别[J]. 电力系统保护与控制,2014,42 (20):38-45.

YANG Zhichao, FAN Lixin, YANG Chengshun, et al. Identification of partial discharge in gas insulated switchgears based on GK fuzzy clustering & LS-SVM [J]. Power System Protection and Control, 2014,42(20):38-45.

- [6]陈新美,潘笑颜,路光辉,等. 基于朴素贝叶斯的局部放电诊断 模型[J]. 计算机应用与软件,2016,33(9):51-55.
 CHEN Xinmei, PAN Xiaoyan, LU Guanghui, et al. A partial discharge diagnosis model based on naive Bayes[J]. Computer Applications and Software,2016,33(9):51-55.
- [7] TARASSENKO L, HAYTON P, CERNEAZ N, et al. Novelty detection for the identification of masses in mammograms [C] // International Conference on Artificial Neural Networks. Cambridge, UK: IET, 1995:442-447.
- [8] XIAO Y, WANG H, XU W. Parameter selection of Gaussian kernel for one-class SVM[J]. IEEE Transactions on Cybernetics, 2015, 45 (5):941-953.
- [9] DAVID M J T. Support vector data description [J]. Journal of Machine Learning Research, 2004, 54(1):45-66.

- [10] RAO R, LAKSHMINARAYANAN S. VPMCD: variable interaction modeling approach for class discrimination in biological systems[J]. Febs Letters, 2007, 581(5):826-830.
- [11] 罗颂荣. 基于变量预测模型模式识别的旋转机械故障诊断研究
 [D]. 长沙:湖南大学,2015.
 LUO Songrong. Research on fault diagnosis method for rotating machinery using variable predictive model based class discriminate
 [D]. Changsha; Hunan University, 2015.
- [12]杨宇,潘海洋,李杰,等.基于改进多项式响应面的 VPMCD 方法及其在滚动轴承故障诊断中的应用[J].振动与冲击,2014,33(19):157-163.
 YANG Yu, PAN Haiyang, LI Jie, et al. VPMCD approach based on improved polynomial response surface and its application rolling

improved polynomial response surface and its application rolling bearing fault diagnosis [J]. Journal of Vibration and Shock, 2014, 33(19):157-163.

- [13] 刘念,张清鑫,刘海涛. 基于核函数极限学习机的微电网短期负荷预测方法[J]. 电工技术学报,2015,30(8):218-224.
 LIU Nian, ZHANG Qingxin, LIU Haitao. Online short-term load forecasting based on ELM with kernel algorithm in micro-grid environment[J]. Transactions of China Electrotechnical Society, 2015, 30(8):218-224.
- [14] 王守相,王亚旻,刘岩,等. 基于经验模态分解和 ELM 神经网络的逐时太阳能辐照量预测[J]. 电力自动化设备,2014,34(8): 7-12.

WANG Shouxiang, WANG Yawen, LIU Yan, et al. Hourly solar radiation forecasting based on EMD and ELM neural network [J]. Electric Power Automation Equipment, 2014, 34(8):7-12.

[15]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, 35(增刊):146-153.

YANG Xiyun, GUAN Wenyuan, LIU Yuqi, et al. Prediction intervals forecasts of wind power based on PSO-KELM[J]. Proceedings of the CSEE, 2015, 35(Supplement): 146-153.

- [16] 门洪,于加学,秦蕾. 基于 CA 和 OTSU 的电气设备红外图像分 割方法[J]. 电力自动化设备,2011,31(9):92-95.
 MEN Hong, YU Jiaxue, QIN Leil. Segmentation of electric equipment infrared image based on CA and OTSU[J]. Electric Power Automation Equipment,2011,31(9):92-95.
 [17] 贾亚飞,朱永利,王刘旺,等. 基于 VMD 和多尺度熵的变压器内
- [17] 贾亚飞,朱永利,主刈旺,等. 基于 VMD 和多尺度熵的变压器内 绝缘局部放电信号特征提取及分类[J]. 电工技术学报,2016, 31(19):208-217.

JIA Yafei, ZHU Yongli, WANG Liuwang, et al. Feature extraction and classification on partial discharge signals of power transformers based on VMD and multiscale entropy [J]. Transactions of China Electrotechnical Society, 2016, 31(19):208-217.

作者简介:



高佳程

高佳程(1993—),男,河北保定人,硕 士研究生,主要研究方向为电气设备在线 监测和故障诊断(E-mail:gaojiacheng1993@ 163.com);

曹雁庆(1972—),男,山西左权人,高 级工程师,主要研究方向为新能源生产运 行检修(**E-mail**:caoyq@600795.com.cn);

1 社 № (E-man; caoyq@000795.com.cn);
朱永利(1963—),男,河北冀州人,教授,博士,主要研究

方向为输变电设备在线监测与智能电网(E-mail:yonglipw@ 163.com)。

Pattern recognition of unknown PD types based on KELM-VPMCD

GAO Jiacheng¹, CAO Yanqing², ZHU Yongli¹, JIA Yafei¹

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Baoding 071003, China; 2. GD Power Development Co., Ltd., Beijing 100101, China)

Abstract: In order to solve the problem that the unknown PD(Partial Discharge) types cannot be recognized correctly, a method based on KELM-VPMCD (Kernel Extreme Learning Machine-Variable Predictive Model based Class Discriminate) is proposed to recognize the unknown PD types. The samples with the known PD types are trained by the KELM, and the corresponding VPMs (Variable Predictive Models) are constructed and used for the regression prediction of testing samples. According to the quadratic sum of regression prediction errors, the thresholds are set by Otsu algorithm to recognize the PD types of samples. The recognition results show that the proposed method can recognize the unknown PD types with high accuracy.

Key words: partial discharge; pattern recognition; KELM; VPMCD

(1) 好 (140 五 ご 16 140)	
(上接弟 140 贝 continued from page 140)	
研究生,研究方向为输电线路在线监测与故障诊断(E-mail:	向为输电线路在线监测与故障诊断;
1328255563@qq.com);	周 岩(1992—),男,河南南阳人,硕士研究生,研究方
朱永灿(1986—),男,河南濮阳人,博士研究生,研究方	向为输电线路在线监测与故障诊断;
向为智能电网在线监测理论与关键技术;	高 华(1993—),男,宁夏吴忠人,硕士研究生,研究方
魏雪倩(1991—),男,陕西延安人,硕士研究生,研究方	向为输电线路在线监测与故障诊断。

Fault diagnosis of high-voltage circuit breaker based on convolution neural network

HUANG Xinbo, HU Xiaowen, ZHU Yongcan, WEI Xueqian, ZHOU Yan, GAO Hua

(College of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: The traditional fault diagnosis methods of high-voltage circuit breaker rely too heavily on artificial experience and cannot precisely reflect the relationship between the characteristic parameters and fault types, so their accuracies are low. In order to solve this issue, it is proposed to diagnose the high-voltage circuit breaker fault by CNN (Convolution Neural Network). Combined with the characteristics of breaking coil and closing coil currents in highvoltage circuit breaker, the fault diagnosis model is built and then trained by the null point fault characteristic parameters to obtain the corresponding fault types. The simulative results show that with the overall accuracy of 93.68%, the proposed algorithm has a great advantage comparing with other algorithms based on the neural network.

Key words: electric circuit breakers; high-voltage circuit breakers; convolution neural network; breaking coil and closing coil currents; fault diagnosis

					0				
		识别率/%				平均识别率/%			
数据集类别		BP 神经 网络	SVM 方 法	VPMCD	KELM-VPMCD	BP 神经 网络	SVM 方 法	VPMCD	KELM-VPMCD
	Setosa	100.00	100.00	100.00	100.00			93.33	98.33
Iris	Versicolor	100.00	100.00	95.00	100.00	96.67	96.67		
	Virginica	90.00	90.00	85.00	95.00				
	Seed1	86.67	90.00	86.67	90.00				
Seeds	Seed2	86.67	86.67	76.67	93.33	87.78	88.87	76.67	91.11
	Seed3	90.00	90.00	66.67	90.00				

表 A1 UCI 数据集识别结果 TableA1 Results of recognition on UCI database

表 A2 OCSVM、SVDD 和 VPMCD 方法的相关参数 TableA2 Parameters of OCSVM, SVDD and VPMCD methods

	(<i>C</i> ,	$\sigma)$	VPMCD 方法参数		
同部放电尖型	OCSVM 方法	SVDD 方法			
	(0.21 , 0.88)	(0.10, 0.50)	$X_1 = 12.98X_2^2 + 46.17X_3^2 \cdot 18.56X_2X_3 + 18.98X_2 + 19.99X_3 + 0.48$		
悬浮放电			$X_2 = -50.39X_1^2 - 41.88X_3^2 + 11.02X_1X_3 - 22.74X_1 + 20.14X_3 - 0.04,$		
			$X_3 = 52.79X_1^2 + 74.42X_2^2 + 5.72X_1X_2 - 13.75X_1 - 6.06X_2 + 1.71$		
	(0.11, 0.26)	(0.23, 0.17)	$X_1 = 44.80X_2^2 - 19.31X_3^2 + 21.25X_2X_3 - 21.98X_2 + 3.56X_3 + 2.15$		
板对板放电			$X_2 = -9.59X_1^2 + 43.85X_3^2 + 4.75X_1X_3 + 8.40X_1 - 17.68X_3 - 0.29$		
			$X_3 = -52.60X_1^2 + 22.93X_2^2 + 47.74X_1X_2 + 34.81X_1 - 26.98X_2 - 4.54$		
	(0.67, 0.50)	(0.45, 0.18)	$X_1 = 12.58X_2^2 - 39.64X_3^2 - 7.41X_2X_3 - 4.18X_2 - 1.19X_3 + 1.42$		
针板放电			$X_2 = 26.82X_1^2 + 12.21X_3^2 + 0.90X_1X_3 - 32.63X_1 + 3.96X_3 + 9.46,$		
			$X_3 = -59.45X_1^2 + 30.44X_2^2 - 21.43X_1X_2 + 84.28X_1 + 53.22X_2 - 32.25$		
	(0.27, 0.23) (0.16	(0.16, 0.20)	$X_1 = -80.29X_2^2 + 8.64X_3^2 - 18.42X_2X_3 + 6.91X_2 + 50.40X_3 + 0.21$		
电晕放电			$X_2 = 16.69X_1^2 - 41.18X_3^2 - 4.19X_1X_3 - 17.96X_1 - 9.59X_3 + 4.86$		
			$X_3 = -23.52X_1^2 + 81.76X_2^2 + 32.47X_1X_2 + 25.98X_1 + 27.23X_2 - 7.18$		

表 A3 不同未知局部放电类型下,各种识别方法的正确识别率 Table A3 Recognition rate of different methods under different unknown PD types

未知局	汩汩米	识别率/%					总体识别率/%				
部放电 类型	型	OCSVM 方法	SVDD方 法	密度估计 方法	VPMCD 方法	KELM-VPMCD 方法	OCSVM 方法	SVDD 方法	密度估计 方法	VPMCD 方法	KELM-VPMCD 方法
悬浮放	已知	91.67	93.33	93.33	96.67	98.33	93.75 95.0	05.00	02.50	97.50	98.75
电	未知	100	100	95.00	100	100		95.00	92.50		
板对板	已知	78.33	81.67	78.33	95.00	96.67	78.75 8	80.00	76.25	96.25	97.50
放电	未知	75.00	70.00	70.00	100	100					
针板放	已知	83.33	85.00	80.00	91.67	96.67	80.00 83	02.75	76.05	93.75	97.50
电	未知	70.00	80.00	65.00	100	100		83.75	76.25		
电晕放	己知	91.67	91.67	90.00	98.33	98.33	02.75	02.55		00.75	00.75
电	未知	100	100	90.00	100	100	93.75	95.75	90.00	96.75	98.75

	TableA4 Recogn	ition rate of unite	tent I D types by u	merent methous	
局部放电类型	OCSVM 方法	SVDD 方法	密度估计方法	VPMCD 方法	KEL-VPMCD 方 法
悬浮放电	91.25	93.75	86.25	100	100
板对板放电	78.75	81.25	83.75	86.25	95.00
针板放电	80.00	82.50	78.75	90.00	97.50
电晕放电	93.75	93.75	86.25	98.75	100

表 A4 各种识别方法对不同局部放电类型的识别率 TableA4 Recognition rate of different PD types by different methods