

基于多核学习整合 GIS 局部放电多类特征的分类研究

宋人杰,杨 爽,孟凡奇
(东北电力大学 电气工程学院,吉林 吉林 132012)

摘 要:传统的单一核函数构成的支持向量机(Support Vector Machine, SVM)无法解决气体绝缘组合电器(Gas Insulated Switcher, GIS)所采集到的局部放电数据(Partial Discharge, PD)分布不规则、特征类别复杂和规模巨大等问题.针对这类问题,本文提出使用多个核的线性组合方式即简单多核学习方法(Simple Multiple Kernel Learning, SimpleMKL)对多类特征进行分类研究.通过赋予不同局部放电特征不同的核函数,以多个核函数的线性加权代替传统的单一核函数,利用梯度下降法不停迭代求解核函数的权值系数,最终达到整合局部放电多类特征并提高分类精度的目的.实验结果表明:该方法对局部放电多个特征空间具有普适性,分类精度高于单核 SVM 和融合 SVM 识别方法.

关键词:气体绝缘组合电器;局部放电;模式识别;简单多核学习

中图分类号:TM595 **文献标志码:**A

Research on classification of multi-class partial discharge features in GIS based on multiple kernel learning

SONG Renjie, YANG Shuang, MENG Fanqi
(School of Electrical Engineering, Northeast Electric Power University, Jilin Jilin 132012, China)

Abstract: The SVM formed by the traditional single kernel function cannot solve the practical problems such as irregular distribution of GIS partial discharge, complicated characteristic category and large scale. In view of the above problems, this paper proposes the use of multiple kernel linear combinations, SimpleMKL method, to study the classification of multiple features. By assigning different kernel functions with different partial discharge characteristics, linear weighting of multiple kernel functions replaces the traditional single kernel function, and the gradient descent method is used to iteratively solve the weight coefficients of the kernel, eventually achieving the integration of PD multiple types of characteristics and improving the classification accuracy. The experimental results show that the proposed method is universal for multiple feature spaces of partial discharge, and the classification accuracy is higher than the single kernel SVM and fusion SVM recognition method.

Keywords: gas insulated switcher; partial discharge; pattern recognition; simple multi-core learning

收稿日期:2018-03-27
第一作者:宋人杰(1963—),女,吉林省吉林市人,教授,研究方向为智能信息处理及电力应用. email: 435535036@qq.com.
引用格式:宋人杰,杨爽,孟凡奇. 基于多核学习整合 GIS 局部放电多类特征的分类研究[J]北京交通大学学报,2018,42(5):93—98.
SONG Renjie, YANG Shuang, MENG Fanqi. Research on classification of multi-class partial discharge features in GIS based on multiple kernel learning[J] Journal of Beijing Jiaotong University, 2018, 42(5): 93—98. (in Chinese)

使用 GIS 局部放电信息对绝缘缺陷进行分类研究对掌握气体绝缘组合电器的故障部位及绝缘状况,保障电网的安全可靠运行具有重要意义^[1-3]。绝缘缺陷分类的前提是要筛选出有效的局部放电特征集。目前检测 GIS 设备是否存在局部放电的主要方法有脉冲电流法(Pulse Current Method, PCM)、特高频法(Ultra-High Frequency, UHF)、超声波法(Ultrasonic, US)和 SF₆ 气体分解组分分析法(Decomposition Component Analysis, DCA)等^[4-6]。基于 UHF 的统计特征参数、基于 US 的时频域特征、基于 DCA 的气体参数等被证明具有良好的辨识能力。

模式识别的关键环节是设计合适的分类器^[7]。国内外已有学者将人工神经网络^[8-9]和支持向量机技术^[10]应用于局部放电模式识别中,但由于局部放电数据具有复杂性和分散性,神经网络在应用中容易受到条件限制,存在收敛速度慢、容易陷入局部收敛等问题。虽然 Vapnik^[11]于 1995 年提出的支持向量机理论可以较好的解决神经网络中存在的问题,但是当数据维度过高时,SVM 的求解速度会受到一定的影响。文献^[12]中利用最小二乘支持向量机(Little Squares Support Vector Machine, LSSVM)针对特高频等局部放电信息进行绝缘缺陷识别,该方法存在以下问题:不同局部放电特征采用同一核函数会使核函数的格式固定,而不同核函数造成的分类结果差异也较大,从而导致训练后的核参数对样本数据仍然具有很强的敏感性,泛化能力和鲁棒性较差。文献^[13]选取参数不同的径向基核函数,以线性加权的方式求解最优参数,而最优参数的求解是通过不断调整权重实现的,但是,仅利用径向基核函数能否实现多类样本空间的分类识别并未被证实,值得进一步研究。

针对上述问题,本文作者提出基于多核学习整合 GIS 局部放电多类特征的分类方法。SimpleMKL 利用一种自适应的 l_2 范数正则化方法来考虑多核学习问题^[14-15],并采用 l_2 约束以提高权重的稀疏性。该算法核的定义形式为多个核的线性组合,使其可以解决多特征的复杂问题。与其余多核学习算法相比,SimpleMKL 可以通过多核的叠加形式来提高算法的收敛速度与效率。因此该方法针对局部放电模式识别中特征向量的多元化和放电类型的多样性具有较好的适用性。

本文作者对多类别局部放电信息进行对比分析。首先赋予不同的局部放电特征向量不同的核函数,在对多类特征进行整合后构造 SimpleMKL 分

类模型,最后使用该分类模型完成 4 种绝缘缺陷类型的识别,实验结果验证了该方法的有效性和实用性。

1 SimpleMKL 分类模型

1.1 标准 SVM

在标准 SVM、支持向量回归(Support Vector Regression, SVR)和相关向量机(Relevance Vector Machine, RVM)中,都是通过引入单核特征空间内的单一核函数,将输入线性不可分的样本映射到高维空间内,从而达到线性可分或者近似线性可分。因此,核函数的选择尤为关键。在标准 SVM 中,假设有数据集 $(x_i, y_i)_{i=1}^l$,其中 x_i 属于输入空间 X , y_i 代表类别标签,对于单核分析算法,学习问题的解决方案的形式如下

$$f(x) = \sum_{i=1}^l a_i^* y_i K(x, x_i) + b^* \quad (1)$$

式中: a_i^* 和 b^* 为将要学习的系数; $K(x, x_i)$ 为正定核函数。求解方程可表示为

$$\min J(\mathbf{w}, \xi) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} C \sum_{i=1}^l \xi_i^2 \quad (2)$$

式中: \mathbf{w} 为权向量; ξ_i 为误差变量; $C > 0$ 为正则化因子。

根据拉格朗日乘子法,引入拉格朗日乘子 α_i ,将式(2)的最小值问题转化为其对偶问题,即求下列方程式(3)的最大值,同时,式(3)要满足卡罗需-库恩-塔克条件(Karush-Kuhn-Tucker, KKT)条件。

$$\max L(\mathbf{w}, b, \xi, a) = J(\mathbf{w}, \xi) - \sum_{i=1}^l a_i \{y_i [\mathbf{w}^T \varphi(x_i) + b] - 1 + \xi_i\} \quad (3)$$

式中: $\varphi(\cdot)$ 为非线性映射函数; b 为偏置项。

对于多核分析问题,核矩阵可以表示为

$$K(x, x_i) = \sum_{k=1}^M \mathbf{d}_k K_k(x, x_i), \quad \mathbf{d} \geq 0, \sum_k \mathbf{d}_k = 1 \quad (4)$$

式中: M 是总核函数数量; \mathbf{d}_k 为核矩阵的权重;在这个框架内,内核的数据表示问题转移到权重 \mathbf{d}_k 的求解与选择上。

1.2 SimpleMKL 二分类

对于 SimpleMKL 问题,可以描述为

$$\begin{cases} \min_{\mathbf{d}_k, f_k, b, \xi_i} \left(\sum_k \frac{1}{\mathbf{d}_k} \|f_k\|^2 + C \sum_i \xi_i \right) \\ J(\mathbf{d}) = y_i \sum_k f_k(x_i) + y_i b \geq 1 - \xi_i \quad \forall_i \\ \sum_k \mathbf{d}_k = 1 \\ \xi_i \geq 0 \end{cases} \quad (5)$$

式中,每一个 \mathbf{d}_k 控制着目标函数中 f_k 的平方范数.因此, \mathbf{d}_k 越小, f_k 越平滑.当 $\mathbf{d}_k = 0$ 时, f_k 也必须为 0,以便问题保持良好的定义. \mathbf{d}_k 的稀疏约束通过 l_1 范数约束被添加,它可以导出具有少量基核的稀疏决策函数.最小化的目标函数在其参数 \mathbf{d}_k, f_k, b 和 ξ 中是联合线性凸的.

目标函数 $J(\mathbf{d})$ 实际上是一个最佳的 SVM 目标值.通过投影梯度法求解单纯形上的最小化问题式(5),该投影梯度法假定 $J(\mathbf{d})$ 可微.事实上,原始问题式(5)的拉格朗日可以写成

$$L = \frac{1}{2} \sum_k \frac{1}{\mathbf{d}_k} ||f_k||^2 + C \sum_i \xi_i + \sum_i a_i [1 - \xi_i - y_i (\sum_k f_k(x_i) + b)] - \sum_i v_i \xi_i \quad (6)$$

根据原始变量将该拉格朗日的导数设置为零并分别求解 f_k, b, ξ_i 的偏导数,得到

$$\begin{cases} \frac{1}{\mathbf{d}_k} f_k(\cdot) = \sum_i a_i y_i K_k(\cdot, x_i) & \forall k \\ \sum_i a_i y_i = 0 \\ C - a_i - v_i = 0 \end{cases} \quad (7)$$

根据这些等式,相关的对偶问题是

$$\begin{cases} \max_a - \frac{1}{2} \left(\sum_{i,j} a_i a_j \sum_k \mathbf{d}_k K_k(x, x) + \sum_i a_i \right) \\ \sum_i a_i y_i = 0 \\ C \geq a_i \geq 0 \end{cases} \quad (8)$$

这是使用单个矩阵的 SVM 对偶问题.因此,这个步骤可以通过任何 SVM 算法来解决.为了计算 \mathbf{d}_k 关于 $J(\mathbf{d})$ 的导数, $J(\mathbf{d})$ 是以上方程式(8)的最优目标值.由于强对偶性, $J(\mathbf{d})$ 也是对偶问题的目标值.如果 a^* 为式(8)的最优解,那么对于一个给定的 \mathbf{d}_k , 有

$$J(\mathbf{d}) = -\frac{1}{2} \sum_{i,j} a_i^* a_j^* \sum_k \mathbf{d}_k K_k(x, x) + \sum_i a_i^* \quad (9)$$

通过简单地推导方程式(9)中给出的关于 \mathbf{d}_k 的对偶函数,得

$$\frac{\partial J}{\partial \mathbf{d}_k} = -\frac{1}{2} \sum_{i,j} a_i^* a_j^* y_i y_j K_k(x, x) \quad \forall k \quad (10)$$

完成 J 的梯度运算后, \mathbf{d} 可以通过梯度下降进行更新,同时确保满足 \mathbf{d} 的约束条件.这可以首先通过减少梯度,然后通过投影来保证 \mathbf{d} 的非负性.更新方案如下

$$\mathbf{d}^{t+1} \leftarrow \mathbf{d}^t + r_t \mathbf{D}_t \quad (11)$$

式中, \mathbf{D}_t 是梯度下降方向的向量,步长 r_t 是通过使用一维线性搜索来确定的,并具有适当的停止标准.综上所述, SimpleMKL 二分类算法可以描述为

- 1) 设置 \mathbf{d}_m^l 初值: $\mathbf{d}_m^1 = \frac{1}{M}$, $m = 1, 2, 3, \dots, m$.
- 2) 对于 t 次迭代,利用组合核 $K = \sum_k \mathbf{d}_k^t K_k$ 计算标准支持向量机的目标函数 $J(\mathbf{d})$.
- 3) 利用目标函数 $J(\mathbf{d})$ 对 \mathbf{d} 求偏导,计算梯度、梯度方向 \mathbf{D}_t 和最优步长 r_t .
- 4) 利用式(11)更新 \mathbf{d} ,再利用新的 \mathbf{d} 更新核函数、梯度、梯度方向 \mathbf{D}_t 和最优步长 r_t .
- 5) 判断是否满足迭代终止条件,若不满足返回到第 2 步,并重复第 2 步到第 4 步,直到达到停止迭代条件结束.

迭代停止条件包含 KKT 条件,对偶误差,达到最大迭代次数等.

1.3 SimpleMKL 的多类分类理论

对于 SimpleMKL 的多分类问题,与 SVM 多类分类一样,通过两类分类器解决.它可由每一个两类分类器目标函数求和获得,即

$$J(\mathbf{d}) = \sum_{k \in K} J_k(\mathbf{d}) \quad (12)$$

式中: K 表示两类分类器的集合; $J_k(\mathbf{d})$ 是第 k 个两类 SVM 分类器的目标函数值.如果在多核 SVM 分类算法中目标函数已更新,则 $J(\mathbf{d})$ 的梯度为

$$\frac{\partial J}{\partial \mathbf{d}_m} = -\frac{1}{2} \sum_{k \in K} \sum_{i=1}^n \sum_{j=1}^m a_{i,k}^* a_{j,k}^* y_i y_j K_m(x, x) \quad \forall k \quad (13)$$

2 局部放电的特征选择

本文采取 3 路信号对绝缘缺陷类型进行识别,分别是 UHF 信号、US 信号和化学信号.针对 UHF 信号,选取统计特征参数^[16];对 US 信号,选取时域和频域特征参数^[16];针对化学信号,根据 SF₆ 气体分解组分的故障诊断原理^[17],以 DCA 为依据,对 SF₆ 故障分解产物和分解组分比值为特征量进行定量分析.

2.1 基于 UHF 统计特征参数

采用 UHF 法可以根据局部放电的相位分布谱图(Phase Resolved Partial Discharge, PRPD)提取有用的统计算子^[16].统计算子是对各种分布进行统计分析,采用定量的参数来描述分布的形状特征.本文采用的统计特征参数主要如表 1 所示.

由表 1 可以看出,由统计特征参数构成的局部放电模式识别的特征值矩阵 $\mathbf{V}_1 = [M_1, M_2, M_3,$

$M_4, M_5, M_6, M_7, M_8, M_9, M_{10}, M_{11}]$, 共有 11 个特征因子.

表 1 基于 UHF 统计特征参数

Tab.1 Statistical characteristic parameters based on UHF

统计参数	参数表示	基本意义
S_k	S_{k1}	M_1
	S_{k1}	M_2
	S_{k1}	M_3
	S_{k1}	M_4
K_u	S_{k1}	M_5
	S_{k1}	M_6
	S_{k1}	M_7
	S_{k1}	M_8
C_c	M_9	互相关系数
Q	M_{10}	放电量因数
m	M_{11}	修正的互相关数

2.2 基于 US 时域和频域特征参数

采用的是时域分析法和频域分析法对局部放电的 US 信号特征提取后的参数^[17], 针对局部放电 US 信号的特点, 在时域和频域上分别选取了 5 个和 3 个特征参数. 具体参数为: P_1 为均方根, P_2 为方差, P_3 为绝对积分平均值, P_4 为峰度, P_5 为偏度, P_6 为功率谱最大值, P_7 为中值频率, P_8 为平均功率频率.

由上可以看出, 由时域和频域特征参数构成的局部放电模式识别的特征值矩阵 $V_2=[P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8]$, 共有 8 个特征因子.

2.3 基于 DCA 气体分解产物特征参数

由于 SF_6 在局部放电条件下产生气体分解产物与绝缘缺陷类型之间的关系紧密相连, 这些分解组分气体可反映出故障的性质、产生机理和发展与演变过程等. 本文以文献[18]的研究分析为参考依据, 将以下 5 种气体的体积分数作为特征值为: Q_1 为 $c(\text{SO}_2\text{F}_2)$, Q_2 为 $c(\text{SOF}_2)$, Q_3 为 $c(\text{SO}_2)$, Q_4 为 $c(\text{CO}_2)$, Q_5 为 $c(\text{CF}_4)$. 其中, SF_6 气体分解产物构成的局部放电模式识别特征值矩阵 $V_3=[Q_1, Q_2, Q_3, Q_4, Q_5]$, 共有 5 个特征因子.

2.4 基于 DCA 比值特征参数

分解气体的比值可以消除分解气室的体积效应, 从而可以作为模式识别较为可靠的依据. 本文 SF_6 分解特征组分比值的构建借鉴文献[18]的原理, 选择 $c(\text{SO}_2\text{F}_2)/c(\text{SOF}_2)$, $c(\text{CF}_4)/c(\text{CO}_2)$ 和 $c(\text{SOF}_2+\text{SO}_2\text{F}_2)/c(\text{CF}_4+\text{CO}_2)$ 作为判断局部放电模式的定量指标. 将它们分别用参数 B_1, B_2 和 B_3 表示.

由上可以看出, DCA 比值法构成的特征值矩阵

$V_4=[B_1, B_2, B_3]$, 共有 3 个特征因子.

3 基于 SimpleMKL 的局部模式识别

3.1 识别流程

应用 SimpleMKL 进行局部放电信息整合模式识别流程如下: 1) 实验建立 M 类绝缘缺陷类型; 2) 针对 N 类局部放电特征参数, 为每一类参数选择恰当的核函数; 3) 为所有核函数选择适当参数, 整合 V_1 至 V_4 特征值矩阵构造 SimpleMKL 模型; 4) 每组实验数据有 500 组, 4 组数据一共有 2 000 组, 选取实验数据里的 70% 用作模型训练, 30% 用作模型验证.

多核学习识别流程图如图 1 所示.

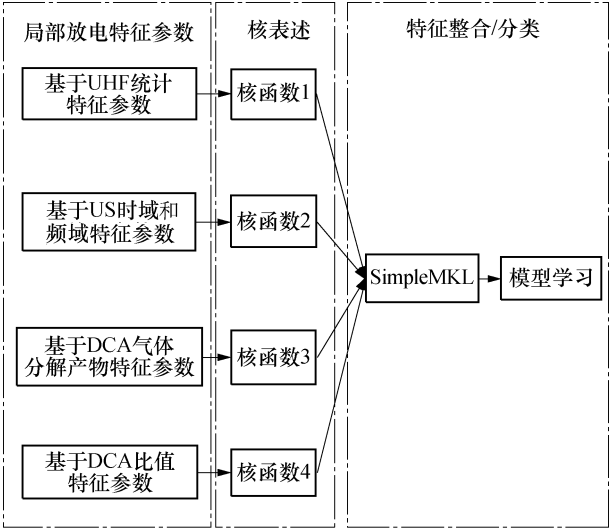


图 1 多核学习识别流程

Fig.1 Multi-core learning pattern recognition process

3.2 核函数的选择

鉴于单核函数基于不同参数的核函数构成的多类特征空间具有不确定性, 因此, 本文在核函数结构的选择上, 使用不同核函数不同参数构成多核. 在核函数的选择上, 主要采用高斯径向基核函数 (Radial Basis Function, RBF) 和多项式核函数 (Polynomial Kernel Function, POLY). 表达式分别为

$$K(x, x') = \exp(-\frac{\|x - x'\|^2}{2\sigma^2}) \tag{14}$$

$$K(x, x') = (x \cdot x' + 1)^p \tag{15}$$

式中: σ 为高斯径向基核参数; p 为多项式系数.

单核 SVM 应用于 4 种类别的放电特征时, 由于核函数的不同, 分类识别效果差异也比较大. 鉴于 RBF 与 POLY 被广泛应用于支持向量机模型中, 因此本文分别将这两种核函数应用于每类训练集的单核 SVM 中, 通过 3 重交叉验证得到的各个放电特征识别结果如表 2 所示.

表 2 单核 SVM 识别结果

Tab.2 Recognition results of single kernel SVM %

放电特征	准确率	
	RBF	POLY
基于 UHF 统计特征参数	91.33	90.24
基于 US 时域和频域特征参数	95.24	94.76
基于 DCA 气体分解产物特征参数	97.14	95.43
基于 DCA 比值特征参数	95.89	94.13

表 2 描述了不同放电特征在单核支持向量机下采用不同核函数的识别效果.由表 2 可知,基于 UHF 的统计特征参数和基于 US 的时频域特征参数的最佳 SVM 模型核函数为 RBF 核函数;基于 DCA 的气体分解产物特征参数与基于 DCA 比值法的特征参数的最佳核函数为 POLY 核函数.

为了解决 RBF 和 POLY 的参数选择问题,本节为 RBF 核函数的每个特征核选择了 10 个不同的 σ 值, $\sigma = [0.5, 1, 2, 3, 7, 10, 12, 15, 17, 20]$;为 POLY 的每个特征核选择了 3 个不同系数, $p = [1, 2, 3]$.最终,本文将构建 702 个局部放电信号的基本特征核.

4 实验结果分析

本文对尖端放电、悬浮放电、自由金属放电和绝缘子表面金属颗粒放电 4 类绝缘缺陷类型下的局部放电信息进行分析,并针对每一类绝缘缺陷类型的每类局部放电特征值进行归一化处理,方程为

$$X_{\text{norm}} = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}, i = 1, 2, \dots, n \quad (16)$$

式中: X_i 为特征值; X_{norm} 为归一化值; X_{\max} 和 X_{\min} 分别为特征集 X 中的最大值和最小值.

为分析本文提出的基于多核学习整合 GIS 局部放电多类特征分类方法的性能,使用已经建立的局部放电信号数据,本文设计了实测数据对比实验,证明该方法在分类精度、速度和稳定性方面的优势.对于每个数据集,算法用不同的训练和测试集运行 20 次(70%的训练样本和 30%用来测试).训练数据过程中,当权重 d_k 小于 0.001 时,将被强制设置为 0.为了公正的比较,所有的实验都在 intel 2.7 GHz 和 8 GB 内存上运行.本文 SimpleMKL 训练的终止条件设置为以下迭代算法:当前后步骤权重之差 $\|d^{t+1} - d^t\| < 0.01$ 或达到最大迭代次数(500 次)时,迭代结束.终止条件的迭代过程如图 2 所示,图 2 中可以看出,迭代第 52 次时达到收敛条件.

本文将基于多核学习整合局部放电信号多类特征分类方法与单核单特征 SVM 分类器、单核多特征 SVM 和融合 SVM 分类器进行对比实验: 1)单

核单特征 SVM 分类器是由 4 个特征采取各自最优的核函数分别构建的,即, SVM- V_1 , SVM- V_2 , SVM- V_3 和 SVM- V_4 分类器;2)多类 SVM 是由 4 类特征信息整合后采用单核核函数构建的;3)融合 SVM 分类器包含 SVM-BSR (SVM-Bayes Sum Rule)和 SVM-MVR(SVM-Major Vote Rule)分类器.实验从分类精度和效率方面对比分析了这些分类器在 4 类绝缘缺陷类型的局部放电信号分类中的性能,且每个实验都采用 5 重交叉验证方法来评价分类的精度.




图 2 收敛条件

Fig.2 Convergence conditions

1)实验结果证明:本文提出的基于多核学习整合局部放电信号多类特征的分类方法可以达到平均 98.33%的分类精度,如表 3 所示.表 3 中分类精度数据说明了相比 4 种单核 SVM 分类器和融合 SVM 的分类器,本文提出的方法能够获得更高的分类精度.

表 3 同时也给出了经过 20 次训练,不同特征采用不同分类方法的运行时间.表 3 中数据表明,本文采取的算法运行速度更快.

表 3 不同分类方法的分类精度

Tab.3 Accuracy of different classification methods

方法	分类精度/%	训练时间/s
SVM- V_1	89.22±3.4	177.32±3.44
SVM- V_2	90.43±5.6	164.41±5.41
SVM- V_3	90.12±7.6	78.54±8.01
SVM- V_4	97.54±3.8	40.13±4.34
SVM- $V_{1,2,3,4}$	86.33±2.3	200.42±3.21
融合 SVM	90.55±4.1	80.17±4.89
SimpleMKL	98.33±1.34	20.39±1.34

2)图 3 给出了每类特征核权重 d_i 的最终值.通过图 3 分析可以看出,大多数的权重为零且只有小部分核权重不为零.本文中,702 个核参数的权重中只有 18 个权重参与学习(由图 3 得出),即仅有 18 个核参数用作了分类.这是因为在训练过程中,大部分冗余特征被删除,且只有小部分的有用特征在分类过程中保留下来.所以图 3 同样说明了本文提出

的基于多核学习整合局部放电信号多类特征的分类方法具有较高的效率。

多类特征分类方法通过优化和整合不同的局部放电信号特征,删除冗余特征,充分使用有价值的特征,以提高局部放电特征的信息量,从而提高模式识别的分类精度和分类速度。




图 3 最终特征核权重

Fig.3 Final feature kernel weights

5 结论

本文作者提出了基于多核学习整合 GIS 局部放电信号多类特征的分类方法,将 SimpleMKL 多核学习方法应用于 GIS 局部放电模式中,实现了对 4 类绝缘缺陷的分类。主要结论如下:

1) 针对不同的局部放电特征采用不同的核函数和核参数,并使局部放电特征在 SimpleMKL 模型下进行训练学习,通过梯度下降法不停迭代求解权系数,最终实现多分类。

2) 本文设计多核学习模型整合了多类局部放电特征,且通过多核学习删除了冗余特征,使分类更有效率,其分类精度为 98.33% 明显优于单核 SVM 的 86.33% 和融合 SVM 的 90.55%,训练时间 20.39 s 也明显少于单核 SVM 的 200.42 s 和融合 SVM 的 80.17 s,具有较好的实用性和推广性。

3) 实验结果表明:本文设计的多核学习模型可以提高故障诊断的准确率,可以为现场 GIS 设备的状态检修、维护提供科学依据和指导,具有误判风险小、诊断准确率高和实用性强等优点。

参考文献 (References):

[1] KRANZ H G. Fundamentals in computer aided PD processing, PD pattern recognition and automated diagnosis in GIS [J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2002, 7(1): 12-20.

[2] BOGGS S A. Partial discharge: overview and signal generation[J]. IEEE Electrical Insulation Magazine, 1990, 6(4): 33-39.

[3] 肖燕,郁惟镛. GIS 中局部放电在线监测研究的现状与展望[J]. 高电压技术, 2005, 31(1): 47-49.

XIAO Yan, YU Weiyong. Present status and prospect of research of online partial discharge monitoring system in GIS[J]. High Voltage Engineering, 2005, 31(1): 47-49. (in Chinese)

[4] 李端姣,唐志国. GIS 局部放电特高频检测系统标定研究[J]. 高电压技术, 2015, 41(10): 3348-3354.

LI Duanjiao, TANG Zhiguo. Research on the calibration of UHF partial discharge detection system in GIS[J]. High Voltage Engineering, 2015, 41(10): 3348-3354. (in Chinese)

[5] 鲍永胜,郝峰杰,徐建忠,等. GIS 局部放电脉冲分类特征提取算法[J]. 电工技术学报, 2016, 31(9): 181-188.

BAO Yongsheng, HAO Fengjie, XU Jianzhong, et al. Classification feature extraction algorithm for GIS partial discharge pulses[J]. Transactions of China Electrotechnical Society, 2016, 31(9): 181-188. (in Chinese)

[6] 齐波,李成榕,骆立实,等. GIS 中局部放电与气体分解产物关系的试验[J]. 高电压技术, 2010, 36(4): 957-963.

QI Bo, LI Chengrong, LUO Lishi, et al. Experiment on the correlation between partial discharge and gas decomposition products in GIS[J]. High Voltage Engineering, 2010, 36(4): 957-963. (in Chinese)

[7] 孙即祥. 现代模式识别[M]. 2 版. 北京: 高等教育出版社, 2008: 46-48.

SUN Jixiang. Modern pattern recognition edition [M]. 2nd ed. Beijing: Higher Education Press, 2008: 46-48. (in Chinese)

[8] 周天春,杨丽君,廖瑞金,等. 基于局部放电因子向量和 BP 神经网络的油纸绝缘老化状况诊断[J]. 电工技术学报, 2010, 25(10): 18-23.

ZHOU Tianchun, YANG Lijun, LIAO Ruijin, et al. Diagnosis of aging condition in oil-paper insulation based on factor vectors of partial discharge and BP neural network [J]. Transactions of China Electrotechnical Society, 2010, 25(10): 18-23. (in Chinese)

[9] FOO J S, GHOSH P S. Artificial neural network modeling of partial discharge parameters for transformer oil diagnosis [C]// Report Conference on Electrical Insulation and Dielectric Phenomena, 2002: 470-473.

[10] 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. (in Chinese)