

# 应用多分类多核学习支持向量机的 变压器故障诊断方法

郭创新<sup>1</sup>, 朱承治<sup>2</sup>, 张琳<sup>3</sup>, 彭明伟<sup>1</sup>, 刘毅<sup>1</sup>

(1. 浙江大学电气工程学院, 浙江省 杭州市 310027; 2. 浙江省电力公司, 浙江省 杭州市 310007;  
3. 西北电网公司, 陕西省 西安市 710048)

## A Fault Diagnosis Method for Power Transformer Based on Multiclass Multiple-kernel Learning Support Vector Machine

GUO Chuang-xin<sup>1</sup>, ZHU Cheng-zhi<sup>2</sup>, ZHANG Lin<sup>3</sup>, PENG Ming-wei<sup>1</sup>, LIU Yi<sup>1</sup>

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, Zhejiang Province, China;  
2. Zhejiang Electric Power Corporation, Hangzhou 310007, Zhejiang Province, China;  
3. Northwest China Grid Company Limited, Xi'an 710048, Shaanxi Province, China)

**ABSTRACT:** A novel support vector machine (SVM), i.e. multiclass multiple-kernel learning support vector machine (MMKL-SVM), for the fault diagnosis of power transformers is proposed in this paper. Unlike traditional SVM that may fail under some circumstances, the fault diagnosis method based on MMKL-SVM has some good theoretical properties, e.g. it only deals with a simple objective function, and the classification results can be obtained by direct calculation on the basis of a simple decision function; it can conduct calculation with an optimal kernel function composed of linear combinations of basic kernels, further boosting the overall performance; the solutions for it can be efficiently gained by iteratively solving two convex optimization functions with a low computation cost and high speed. Diagnosis test results show that the MMKL-SVM method has high classification accuracy, which proves its effectiveness and usefulness.

**KEY WORDS:** transformer; fault diagnosis; support vector machine (SVM); multiclass multiple-kernel learning

**摘要:** 提出一种基于多分类多核学习支持向量机的变压器故障诊断方法, 相对于传统的 2 分类支持向量机, 该方法有如

下特点: 算法针对单一的优化目标函数求解, 只需设计 1 组参数, 降低了支持向量机在解决多类问题中模型构造和参数选择的难度; 核函数是多个基核函数的组合, 提高了分类的精度; 将模型分解为 2 个凸优问题进行求解, 问题的复杂度低, 求解速度快。诊断实例表明, 该方法能保证较高的诊断准确率, 具有较好的实用性和推广性。

**关键词:** 变压器; 故障诊断; 支持向量机; 多分类多核学习

## 0 引言

电力变压器是电力系统中的重要设备, 利用油中溶解气体分析(dissolved gas analysis, DGA)方法检测油浸变压器内部故障, 已成为对其进行绝缘检测的重要手段。变压器结构的复杂性以及故障原因、故障现象和故障机制的多样性、随机性和模糊性, 使得其绝缘故障诊断存在许多困难。近几年来, 人们借助人工神经网络、模糊数学、聚类原理、灰色系统理论探索变压器故障诊断也获得了一些应用成果, 但也存在不足<sup>[1-8]</sup>。

支持向量机(support vector machine, SVM)理论通过结构风险最小化原理来提高泛化能力, 较好地解决了传统智能方法应用中样本小、非线性、局部极小点等实际问题。近年来, 相关学者将 SVM 引入到变压器诊断中, 利用置信范围最小化以控制诊断中的风险问题。文献[9-14]采用分层决策的方法, 利用 2 分类 SVM 建立了基于多类 SVM 分类器的变压器故障诊断模型, 取得了较好的故障诊断效果,

**基金项目:** 国家自然科学基金项目(50677062); 国家高技术研究发展计划项目(863 计划)(2008AA05Z210); 新世纪优秀人才支持计划项目(NCET-07-0745); 浙江省自然科学基金项目(R107062)。

Project Supported by National Natural Science Foundation of China (50677062); The National High Technology Research and Development of China(863 Program)(2008AA05Z210); Project Supported by Program for New Century Excellent Talents in University(NCET-07-0745); Project Supported by Natural Science Foundation of Zhejiang Province(R107062)。

但是上述基于 2 分类法组合的多类支持向量机存在如下几点缺陷值得改进: 1) 该模型需要反复分组原始数据、选取训练及测试样本等数据, 容易出现混淆和差错。由于变压器故障类型多样, 对于  $N$  类故障分层组合模型需要构造  $N-1$  个二值 SVM 分类器, 相应地需要设计  $N-1$  组参数。2) 基于 2 分类法组合的多类支持向量机(如一对多、一对一的方法)有其局限性, 对于一对多的方法, 训练样本的不均衡将对精度产生影响, 存在误分、拒分区域; 一对一的分类算法采用了投票法, 存在不同类投票相同的情况, 出现不可分的区域。3) 具有不同核函数和参数的 SVM 其性能存在很大差异, 基于单核函数的优化参数方法由于单核函数的格式固定和变化空间的相对狭小, 训练后的有效参数仍然对样本数据有较强的敏感性, 推广能力和鲁棒性较差。

针对这些问题, 本文提出了基于多核学习、多类目标函数方法<sup>[14-16]</sup>的多分类支持向量机方法(multiclass multiple-kernel learning support vector machine, MMKL-SVM), 并将之运用于油浸式变压器的故障诊断。较之传统的 2 分类 SVM, MMKL-SVM 构造学习过程简单, 分类器的鲁棒性强, 精度高。

## 1 油中溶解气体分析

电力变压器的故障诊断是根据故障特征来诊断故障, 为变压器检修提供智能化决策。目前电力变压器故障诊断中应用较多的是传统 DGA 方法。

正常情况时, 变压器内部绝缘油和有机绝缘材料在电和热的作用下会逐渐老化分解, 产生  $H_2$ 、 $CH_4$ 、 $C_2H_2$ 、 $C_2H_4$ 、 $C_2H_6$  等气体, 这些气体基本溶解在油中。当变压器发生故障时, 这些气体的产量会迅速增加, 随着故障的发展, 气体不断地溶解在油中。研究表明, 变压器油中溶解气体的组成与含量和故障类型及故障严重程度有密切的关系, 因而监测油中所含气体的种类、含量及增长情况等, 有利于发现潜伏性故障以及对故障变压器进行诊断。

DGA 方法已被证明是诊断变压器故障的一种有效方法, 在此基础上形成了很多实用性的算法, 如 IEC 推荐的三比值法、Rogers 法、Dornerburg 法等, 它们的共同特点是对变压器油中溶解的各种气体的比值进行编码, 然后由相应的编码查出对应的故障。这些方法仍存在一些缺陷, 人们在这些方法的基础上, 引入专家系统、人工神经网络、

模糊数学、进化遗传算法、支持向量机等人工智能方法来对电力变压器故障进行诊断, 取得了一定的进展。

## 2 基于多分类目标函数及多核学习的支持向量机方法

### 2.1 多分类目标函数支持向量机模型

为有效地解决引言中所述缺陷 1) 及 2), 最近一些机器学习的研究领域更关注于所谓直接实现“一次性”的多类分类, 本文采用了多类目标函数 SVM 模型。该方法和传统方法的不同之处是它将多个分类面的参数求解合并到一个最优化问题中, 通过求解该最优化问题“一次性”地实现多类分类。多类目标函数支持向量机模型隐藏了中间的二值分类层, 表现为从输入数据到输出分类结果的直接过程, 避免混淆和差错的可能性。该模型只需设计 1 组参数, 降低了模型构造和参数选择的难度。训练样本的不均衡也不会对分类精度产生太大影响。

### 2.2 多分类多核学习支持向量机方法

在支持向量机中, 通过核函数的非线性映射, 输入空间中线性不可分的问题在高维特征空间中就可能变成线性可分的问题。通过在特征空间中构造最优超平面可以有效地实现非线性分类。实践表明, 支持向量机的泛化能力与核函数密切相关, 如何构造与实际问题相适应的核函数一直是支持向量机研究的重要课题。近年来, 在机器学习领域, 核的选择和学习, 即如何选择或者构造适合数据的有效核函数, 成为支持向量机的一个热点研究方向。传统 SVM 通常采用单一的核函数实现, 单一核函数一般只能反映特征空间中某一类数据的特性, 必然会造成引言中所述的缺陷 3)。为克服该缺陷, 当前众多研究学者采用多核学习的方法以改进核方法(包括支持向量机分类器)的性能<sup>[17-20]</sup>。在此类方法中, 传统的核函数被众多“基核”的凸组合代替, 即

$$K(\mathbf{x}_i, \mathbf{x}) = \sum_{l=1}^M d_l K_l(\mathbf{x}_i, \mathbf{x}), \quad d_l \geq 0, \quad \sum_{l=1}^M d_l = 1 \quad (1)$$

式中:  $M$  为基核的数目;  $d_l$  为第  $l$  个基核函数对应的权值;  $K_l(\mathbf{x}_i, \mathbf{x})$  为基核。可分别选取不同的核函数和自由参数, 例如可以选取一组不同宽度的径向基函数。使用多个核函数的组合, 即使未知最优参数, 学习机器也可以通过调整权值, 找到最合适的参数, 显然使用多个核函数的组合比只使用单一核函

数的鲁棒性更强。

本文提出的基于多分类目标函数和多核学习的支持向量机算法(MMKL-SVM)具体如下。

对于有  $n$  个样本  $\{x_i, y_i\}_{i=1}^n$  的 SVM 多分类问题, 其中  $x_i$  属于输入空间  $\mathcal{X}$ , 样本共有  $k$  类。参照文献[14], 使用基于向量的类标度方法, 定义  $k$  维向量  $\mathbf{y}_i$  和  $\mathbf{v}_j, j=1, 2, \dots, k$ , 当样本  $i$  属于第  $j$  类时, 向量  $\mathbf{y}_i$  的第  $j$  列为 1, 而其余维为  $-1/(k-1)$ , 当样本属于第  $l$  类时, 定义  $\mathbf{y}_i = \mathbf{v}_l = (1, -1/(k-1), \dots, -1/(k-1))$ , 同理, 当样本属于第  $k$  类时, 定义  $\mathbf{y}_i = \mathbf{v}_k = (-1/(k-1), \dots, 1)$ 。

相应定义  $k$  元决策函数  $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), \dots, f_k(\mathbf{x})]$ ,

且对于任意  $\mathbf{x} \in \mathbf{R}^d$ , 均存在  $\sum_{j=1}^k f_j(\mathbf{x}) = 0$ , 该约束条件反映了在基于上述类标度定义的情况下, 某样本只属于  $k$  类中的一类这一基本性质赋予决策函数的特性。此外, 定义  $k$  维向量  $\mathbf{L}(\mathbf{y}_i)$ , 当样本  $i$  属于第  $j$  类时,  $\mathbf{L}(\mathbf{y}_i)$  的第  $j$  列为 0, 而其余列为 1。参照式(1), 决策函数可表示为

$$f_j(\mathbf{x}) = b_j + \sum_{i=1}^n c_{ij} \sum_{l=1}^M d_l K_l(\mathbf{x}_i, \mathbf{x}) \quad (2)$$

$$d_l \geq 0, \quad \sum_{l=1}^M d_l = 1, \quad j=1, \dots, k$$

令  $\mathbf{L}_j(j=1, \dots, k)$  表示第  $i$  行为  $\mathbf{L}(\mathbf{y}_i) = (L_{i1}, \dots, L_{ik})$  的  $n \times k$  阶矩阵的第  $j$  列, 同样, 令  $\boldsymbol{\xi}_j(j=1, \dots, k)$  表示第  $i$  行为  $\boldsymbol{\xi}_i$  的  $n \times k$  阶矩阵的第  $j$  列,  $\mathbf{y}_j$  表示第  $i$  行为  $\mathbf{y}_i$  的  $n \times k$  阶矩阵的第  $j$  列,  $\mathbf{K}_l$  表示  $n \times n$  阶矩阵, 其中第  $i$  行、第  $j$  列元素为  $K_l(\mathbf{x}_i, \mathbf{x}_j)$ ;  $\mathbf{e}$  表示  $n \times 1$  阶单位向量。基于多分类目标函数和多核学习支持向量机模型的原问题(primal problem)可表示为

$$\left\{ \begin{array}{l} \min J_p(d_l, \boldsymbol{\xi}, \mathbf{c}, \mathbf{b}) = \frac{C}{n} \sum_{j=1}^k \mathbf{L}_j^T \boldsymbol{\xi}_j + \frac{1}{2} \sum_{j=1}^k [\mathbf{c}_j^T (d_l \sum_{l=1}^M \mathbf{K}_l) \mathbf{c}_j] \\ \text{s.t. } b_j \mathbf{e} + (d_l \sum_{l=1}^M \mathbf{K}_l) \mathbf{c}_j - \mathbf{y}_j \leq \boldsymbol{\xi}_j, \quad j=1, \dots, k \\ \boldsymbol{\xi}_j \geq \mathbf{0}, \quad j=1, \dots, k \\ (\sum_{j=1}^k b_j \mathbf{e}) + (d_l \sum_{l=1}^M \mathbf{K}_l) \sum_{j=1}^k \mathbf{c}_j = \mathbf{0} \\ \sum_{l=1}^M d_l = 1, \quad d_l \geq 0 \end{array} \right. \quad (3)$$

式中  $C$  为惩罚参数。

采用 2 步式的迭代优化方法来求解上述优化问

题<sup>[16]</sup>, 式(3)可转化为如下问题进行求解:

$$\min J(d_l), \quad \sum_{l=1}^M d_l = 1, \quad d_l \geq 0 \quad (4)$$

其中

$$J(d_l) = \left\{ \begin{array}{l} \min J_p(\boldsymbol{\xi}, \mathbf{c}, \mathbf{b}) = \frac{C}{n} \sum_{j=1}^k \mathbf{L}_j^T \boldsymbol{\xi}_j + \frac{1}{2} \sum_{j=1}^k [\mathbf{c}_j^T (d_l \sum_{l=1}^M \mathbf{K}_l) \mathbf{c}_j] \\ \text{s.t. } b_j \mathbf{e} + (d_l \sum_{l=1}^M \mathbf{K}_l) \mathbf{c}_j - \mathbf{y}_j \leq \boldsymbol{\xi}_j, \quad j=1, \dots, k \\ \boldsymbol{\xi}_j \geq \mathbf{0}, \quad j=1, \dots, k \\ (\sum_{j=1}^k b_j \mathbf{e}) + (d_l \sum_{l=1}^M \mathbf{K}_l) \sum_{j=1}^k \mathbf{c}_j = \mathbf{0} \end{array} \right. \quad (5)$$

式中  $J(d_l)$  可视为式(5)所示的支持向量机目标函数的最优值。优化问题求解的 2 步式迭代优化算法流程如下所示:

- 1) 令  $d_l^{(1)} = 1/M, l=1, \dots, M$ ;
- 2) 求解式(5)表示的优化问题, 得到优化参数和  $J^{(t)}(d_l)$  的表达式, 其中  $t$  表示迭代的步数;
- 3) 采用共轭投影梯度法求解式(4)所示的等式约束优化问题;
- 4) 返回步骤 2), 直至满足一定的收敛判断条件, 收敛条件为达到预定的迭代次数。

由上述可见, 求解优化问题式(5)是关键所在。对于给定的参数  $d_l$ , 式(5)是一个具有等式和不等式约束的二次优化问题, 采用拉格朗日泛函方法求取其偶问题。引入非负的拉格朗日乘子  $\boldsymbol{\alpha}_j = (\alpha_{1j}, \dots, \alpha_{nj})^T, \boldsymbol{\gamma}_j = (\gamma_{1j}, \dots, \gamma_{nj})^T$  以及无约束的拉格朗日乘子  $\boldsymbol{\delta}_f = (\delta_{1f}, \dots, \delta_{nf})^T$ , 式(5)的拉格朗日函数如式(6)所示:

$$L = \frac{C}{n} \sum_{j=1}^k \mathbf{L}_j^T \boldsymbol{\xi}_j + \frac{1}{2} \sum_{j=1}^k [\mathbf{c}_j^T (d_l \sum_{l=1}^M \mathbf{K}_l) \mathbf{c}_j] + \sum_{j=1}^k \boldsymbol{\alpha}_j^T [b_j \mathbf{e} + (d_l \sum_{l=1}^M \mathbf{K}_l) \mathbf{c}_j - \mathbf{y}_j - \boldsymbol{\xi}_j] - \sum_{j=1}^k \boldsymbol{\gamma}_j^T \boldsymbol{\xi}_j + \boldsymbol{\delta}_f^T [(\sum_{j=1}^k b_j \mathbf{e}) + (d_l \sum_{l=1}^M \mathbf{K}_l) \sum_{j=1}^k \mathbf{c}_j] \quad (6)$$

将泛函关于  $\boldsymbol{\xi}_j, \mathbf{c}_j, b_j$  求极值, 根据极值条件可以得到下列特性:

$$\frac{\partial L}{\partial \boldsymbol{\xi}_j} = \frac{C}{n} \mathbf{L}_j - \boldsymbol{\alpha}_j - \boldsymbol{\gamma}_j = \mathbf{0}, \quad j=1, \dots, k \quad (7)$$

$$\frac{\partial L}{\partial \mathbf{c}_j} = (d_l \sum_{l=1}^M \mathbf{K}_l) \mathbf{c}_j + (d_l \sum_{l=1}^M \mathbf{K}_l) \boldsymbol{\alpha}_j + (d_l \sum_{l=1}^M \mathbf{K}_l) \boldsymbol{\delta}_f = \mathbf{0} \quad (8)$$

$$\partial L / \partial b_j = (\alpha_j + \delta_f)^T e = 0 \quad (9)$$

令  $\bar{\alpha} = (\sum_{j=1}^k \alpha_j) / k$ ，由于  $\delta_f$  是无约束的，设  $\delta_f = -\bar{\alpha}$ ，式(9)可表示为  $(\alpha_j - \bar{\alpha})^T e = 0$ ，同时利用式(7)、(8)，代入拉格朗日函数，考虑 Wolfe 对偶性质，可以得到式(5)表述的优化问题的对偶问题，即

$$\begin{cases} \max J_D(\alpha) = \frac{1}{2} \sum_{j=1}^k (\alpha_j - \bar{\alpha})^T (d_l \sum_{l=1}^M K_l) \cdot \\ \quad (\alpha_j - \bar{\alpha}) + \sum_{j=1}^k \alpha_j^T y_j \quad (10) \\ \text{s.t. } \mathbf{0} \leq \alpha_j \leq (CL_j/n), \quad j=1, \dots, k \\ \quad (\alpha_j - \bar{\alpha})^T e = 0, \quad j=1, \dots, k \end{cases}$$

由于  $\bar{\alpha} = (\sum_{j=1}^k \alpha_j) / k$ ，求解式(10)的二次规划问题可以得到最优解  $\alpha_j^*$ 。设最优解  $\alpha_j^{*(t)}$  为 2 步式迭代优化算法的第  $t$  步迭代值，将之代入式(10)的目标函数，根据对偶理论，式(5)的目标函数最优值为

$$J(d_l) = \frac{1}{2} \sum_{j=1}^k (\alpha_j^{*(t)} - \bar{\alpha}^{*(t)})^T (d_l \sum_{l=1}^M K_l) \cdot (\alpha_j^{*(t)} - \bar{\alpha}^{*(t)}) + \sum_{j=1}^k \alpha_j^{*(t)T} y_j \quad (11)$$

根据 2 步式迭代优化算法的步骤 3)，对  $d_l^{(t)}$  进行修正，得到  $d_l^{(t+1)}$  代入式(10)求取最优解  $\alpha_j^{*(t+1)}$ ，当达到设定的迭代次数后，所求得的最优解记为  $\alpha_j^*, c_j^*, b_j^*, d_l^*, \xi_j^*, \gamma_j^*$ 。由式(8)可以得到  $c_j^*$ ，根据 Kuhn-Tucker 定理，最优解满足如下条件：

$$\alpha_j^* \perp [b_j^* e + (d_l^* \sum_{l=1}^M K_l) c_j^* - y_j - \xi_j^*], \quad j=1, \dots, k \quad (12)$$

$$\gamma_j^* = (L_j - \alpha_j^*) \perp \xi_j^*, \quad j=1, \dots, k \quad (13)$$

式中“ $\perp$ ”表示向量的点积为 0。

利用支持向量集合可以得到基于最优超曲面的决策函数，即

$$f_j(\mathbf{x}) = b_j^* + \sum_{s=1}^{n_s} c_{ij}^* [d_l^* \sum_{l=1}^M K_l(x_s, \mathbf{x})] \quad (14)$$

决策规则为

$$\phi(\mathbf{x}) = \arg \max_j f_j(\mathbf{x}) \quad (15)$$

### 3 基于 MMKL-SVM 的变压器故障诊断

#### 3.1 故障特征量的选择与故障分类

为研究充油变压器潜伏性故障诊断分类问题，本文选择变压器油中 5 种溶解气体  $H_2$ 、 $CH_4$ 、 $C_2H_2$ 、

$C_2H_4$ 、 $C_2H_6$  的含量作为特征参数，模式向量为  $\mathbf{x}_i = (x_{i1}, x_{i2}, x_{i3}, x_{i4}, x_{i5})$ 。考虑到各种溶解气体含量的巨大差异性 & 分散性，为降低它们之间由于量值差异过大造成的影响，需要对 DGA 原始数据进行归一化处理，即将各种溶解气体含量换算为 [0,1] 范围内的相对含量，以降低气体之间的互斥性。归一化处理如下：

$$x'_{ij} = x_{ij} / \sum_{j=1}^5 x_{ij}, \quad i=1, \dots, n \quad (16)$$

变压器的故障类型一般有放电型和过热型 2 大类，但考虑到变压器的实际可能故障类型有放电和过热同时发生的情况，参照改良三比值法和 IEC60599—2007<sup>[21]</sup> 的规定，本文考虑如下 8 种故障模式：低温过热  $T_1$  (低于 300 °C)，中温过热  $T_2$  (300~700 °C)，高温过热  $T_3$  (高于 700 °C)，局部放电或受潮 PD，低能放电  $D_1$ ，高能放电  $D_2$ ，低能放电兼过热  $MF_1$ ，高能放电兼过热  $MF_2$ 。

#### 3.2 支持向量机参数的确定

在本文提出的 MMKL-SVM 方法中，惩罚参数  $C$  和基本核函数选择对于 SVM 诊断的准确率影响很大。

在变压器故障诊断中，通常选取高斯径向基函数作为基本核函数，并在参数范围内以指数增长方式确定每个基本核  $K_l(\mathbf{x}_i, \mathbf{x})$  的宽度参数  $\sigma_l$ ，基本核函数的个数  $M$  也因此而确定。每个基本核函数对应的线性组合权值  $d_l$  在支持向量机的训练中得到。

对于惩罚参数  $C$ ，同样在参数范围内以指数增长方式得到一系列的值，采用交叉验证的方法确定最优的惩罚参数  $C$ 。对每个待验证的参数，将  $N$  个数据样本随机分成  $k$  个互不相交的子集  $\{S_1, S_2, \dots, S_k\}$ ，每次依此选择其中一个子集  $S_i$  作为测试集，而其余样本作为训练集，得到错误分类的样本点个数为  $l_i$ ， $k$  次验证完成后，可以得到错误分类的样本点总数，总数越大，交叉验证精度就越差。选取获得最高交叉验证精度的  $C^*$  作为 SVM 模型的参数。

#### 3.3 故障诊断流程

1) 对训练集和验证集中各样本的 5 种气体浓度数据进行归一化处理，形成训练样本集和测试样本集；

2) 确定基本核函数的个数及每个基核的参数  $\sigma_l$ ，使用交叉验证的方法确定最优的惩罚参数  $C^*$ ；

3) 根据最优参数  $C^*$ ，利用训练样本和多分类多核学习方法得到相应的分类模型。

利用训练好的分类模型对验证集中的待测试样本进行故障诊断。

#### 4 诊断实例

本文搜集了已确定实际故障结果的347组典型变压器油中溶解气体分析检测记录,将这些样本分为2部分:选择210组DGA数据作为SVM学习样本;另外137组样本数据作为验证样本,对训练后的SVM分类器进行测试。

选取高斯型核函数作为多核学习支持向量机算法中的基本核函数,用基于交叉验证的方法确定最优的惩罚参数 $C^*$ 。 $\sigma_1$ 与 $C$ 分别在取值范围 $[2^{-15}, 2^{-14}, \dots, 2^{14}, 2^{15}]$ ,  $[2^{-7}, 2^{-6}, \dots, 2^6, 2^7]$ 内以指数增长方式获取,因此,本文中的支持向量机一共包含了31

个高斯型基核。对于15个备选的惩罚参数 $C$ ,将训练样本分为5组进行交叉验证,最优惩罚参数 $C^*$ 为 $2^3$ 。

支持向量机在确定相关参数后,通过多分类多核学习算法,通过训练迭代运算就可以得到最优权重系数,从而获取分类判决函数。针对验证样本集的变压器各种故障诊断准确率结果如表1所示。

为比较本文多分类多核学习MMKL-SVM的性能,分别采用改良三比值法、BP神经网络和基于单高斯核函数二值SVM分层组合分类器对相同的样本集进行训练和故障诊断,各故障类型的诊断准确率如表1所示。表2则列举了验证样本集中9组典型样本的诊断实例。

表1 不同方法的诊断结果比较

Tab. 1 Comparison of fault diagnosis results by different methods

故障类型	训练样本数	验证样本数	改良三比值法诊断准确率/%	BP神经网络诊断准确率/%	SVM诊断准确率/%	MMKL-SVM诊断准确率/%
T <sub>1</sub>	25	16	75.0	81.3	87.5	93.8
T <sub>2</sub>	25	14	85.7	85.7	92.9	92.9
T <sub>3</sub>	45	28	82.1	85.7	89.3	92.9
PD	25	20	80.0	90.0	95.0	95.0
D <sub>1</sub>	25	18	83.3	83.3	88.9	94.4
D <sub>2</sub>	40	24	83.3	87.5	91.6	95.8
MF <sub>1</sub>	10	8	75.0	75.0	87.5	87.5
MF <sub>2</sub>	15	9	66.7	66.7	77.8	88.9
总计	210	137	80.3	81.9	88.8	92.7

表2 变压器故障诊断实例

Tab. 2 Samples of fault diagnosis for power transformer

序号	气体含量/( $\mu\text{L}\cdot\text{L}^{-1}$ )					诊断结果				实际故障
	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	改良三比值法	BP神经网络	SVM	MMKL-SVM	
1	50.0	90.0	18.0	260.0	5.9	T <sub>3</sub>	T <sub>3</sub>	T <sub>3</sub>	T <sub>3</sub>	铁心多点接地
2	334.0	39.9	47.8	5.4	247.6	D <sub>2</sub>	D <sub>2</sub>	D <sub>2</sub>	D <sub>2</sub>	高能树枝放电
3	538.3	12.6	8.7	14.1	0.3	—	PD	PD	PD	主变油泵进水受潮
4	247.0	137.9	153.8	60.4	176.6	D <sub>1</sub>	D <sub>1</sub>	D <sub>2</sub>	D <sub>2</sub>	固定部件间接触放电
5	25.6	142.8	339.9	82.6	1.5	T <sub>1</sub>	T <sub>2</sub>	T <sub>2</sub>	T <sub>3</sub>	主变套管引线热击穿
6	324.0	345.0	748.0	99.6	177.0	MF <sub>2</sub>	D <sub>2</sub>	MF <sub>2</sub>	MF <sub>2</sub>	主变匝间短路, 属电弧放电兼过热
7	100.0	94.0	22.0	304.0	118.0	D <sub>1</sub>	D <sub>1</sub>	MF <sub>1</sub>	MF <sub>1</sub>	金属异物坠地放电
8	220.0	340.0	42.0	480.0	14.0	T <sub>3</sub>	T <sub>3</sub>	MF <sub>2</sub>	MF <sub>2</sub>	分接开关弧光烧损
9	5 945.0	7 964.0	26 979.0	5 835.0	57.4	T <sub>3</sub>	T <sub>3</sub>	T <sub>3</sub>	MF <sub>2</sub>	多处电弧放电, 局部高温过热

由表1和表2可见:

1) SVM在小样本情况下能够获得较强的泛化能力,其诊断结果与实际结果吻合性很好。

2) SVM较好地解决了传统比值法中的编码缺失(表2中样本3)与编码边界过于绝对(样本4)的弊端,诊断准确率高于改良三比值法。

3) SVM与BP神经网络故障分类方法相比,故障诊断准确率更高。特别是针对多重故障样本(样本6~8),SVM能获得准确的诊断结论,这是因为

支持向量机通过求解全局最优点,解决了在神经网络方法中无法避免的局部极值问题,此外SVM通过核函数在高维特征空间对样本进行分类,因此准确度更好。

4) 本文提出的MMKL-SVM算法较传统单核二值SVM分层组合算法的故障诊断效果更优(样本5, 9),说明在样本不均衡的情况下,MMKL-SVM算法能更好地选择有效的核函数来反映训练数据的特性,泛化能力和鲁棒性更强。而且,MMKL-

SVM 算法具有低计算复杂度。

## 5 结论

基于 SVM 的变压器故障诊断已成为变压器故障诊断的一个研究热点; 然而, 传统 SVM 在解决变压器故障诊断这个多类问题时存在一些固有缺陷。针对这些问题, 本文提出了基于多核学习、多类目标函数方法的多分类支持向量机模型 MMKL-SVM, 并将其运用于变压器故障诊断。该模型具有如下的优点:

1) 相对传统的 SVM 模型, 多类目标函数 SVM 避免了中间的二值分类层, 表现为从输入数据到输出分类结果的直接过程, 有效地避免混淆和差错的可能性。

2) 只需设计 1 组参数, 降低了支持向量机在解决多类问题中的模型构造和参数选择的难度。训练样本的不均衡也不会对分类精度产生太大影响。

3) 基于多核考习的 SVM 方法使用多个核函数的组合, 可以更好地识别样本数据的特征, 加大了最优核函数的搜索空间, 增强了分类器的鲁棒性, 使得分类的精度进一步提高。

4) 将模型分解为 2 个凸优问题进行求解, 问题的复杂度低, 求解速度快。

实例计算表明, 本文提出的 MMKL-SVM 故障诊断模型能保证较高的诊断准确率, 具有较好的实用性和推广性。

## 参考文献

- [1] 彭宁云, 文习山, 王一, 等. 基于线性分类器的充油变压器潜伏性故障诊断方法[J]. 中国电机工程学报, 2004, 24(6): 147-151. Peng Ningyun, Wen Xishan, Wang Yi, et al. A potential fault diagnosis method based on linear classifier for oil-immersed transformer[J]. Proceedings of the CSEE, 2004, 24(6): 147-151(in Chinese).
- [2] 杨兵, 丁辉, 罗为民, 等. 基于知识库的变压器故障诊断专家系统[J]. 中国电机工程学报, 2002, 22(10): 121-124. Yang Bing, Ding Hui, Luo Weimin, et al. Expert system of transformer fault diagnosis based on knowledge base[J]. Proceedings of the CSEE, 2002, 22(10): 121-124(in Chinese).
- [3] 束洪春, 孙向飞, 司大军. 电力变压器故障诊断专家系统知识库建立和维护的粗糙集方法[J]. 中国电机工程学报, 2002, 22(2): 31-35. Shu Hongchun, Sun Xiangfei, Si Dajun. A RS approach to founding and maintaining ES knowledge base for fault diagnosis of power transformer[J]. Proceedings of the CSEE, 2002, 22(2): 31-35(in Chinese).
- [4] 王财胜, 孙才新, 廖瑞金. 变压器色谱监测中的 BPNN 故障诊断法[J]. 中国电机工程学报, 1997, 17(5): 322-325. Wang Caisheng, Sun Caixin, Liao Ruijin. Monitoring transformer chromatography with BPNN fault diagnosis method[J]. Proceedings of the CSEE, 1997, 17(5): 322-325(in Chinese).
- [5] Guardado J L, Naredo J L, Moreno P. A comparative study of neural network efficiency in power transformer diagnosis using dissolved gas analysis[J]. IEEE Trans. on Power Delivery, 2001, 16(4): 643-647.
- [6] 孙才新, 郭俊峰, 廖瑞金, 等. 变压器油中溶解气体分析中的模糊模式多层聚类故障诊断方法的研究[J]. 中国电机工程学报, 2001, 21(2): 37-41. Sun Caixin, Guo Junfeng, Liao Ruijin, et al. Study on fault diagnose method of transformer DGA with fuzzy model hierarchy classification[J]. Proceedings of the CSEE, 2001, 21(2): 37-41(in Chinese).
- [7] 李俭, 孙才新, 陈伟根, 等. 灰色聚类与模糊聚类集成诊断变压器内部故障的方法研究[J]. 中国电机工程学报, 2003, 23(2): 112-115. Li Jian, Sun Caixin, Chen Weigen, et al. A method of synthesis based on the grey cluster and fuzzy cluster about internal fault diagnosis of transformer[J]. Proceedings of the CSEE, 2003, 23(2): 112-115(in Chinese).
- [8] 吕干云, 程浩忠, 翟海保, 等. 基于改进灰色关联分析的变压器故障识别[J]. 中国电机工程学报, 2004, 24(10): 121-126. Lü Ganyun, Cheng Haozhong, Zhai Haibao, et al. Fault diagnosis of power transformer based on improved grey relation analysis[J]. Proceedings of the CSEE, 2004, 24(10): 121-126(in Chinese).
- [9] 董明, 孟源源, 徐长响, 等. 基于支持向量机及油中溶解气体分析的大型电力变压器故障诊断模型研究[J]. 中国电机工程学报, 2003, 23(7): 88-92. Dong Ming, Meng Yuanyuan, Xu Changxiang, et al. Fault diagnosis model for power transformer based on support vector machine and dissolved gas analysis[J]. Proceedings of the CSEE, 2003, 23(7): 88-92(in Chinese).
- [10] 吕干云, 程浩忠, 董立新, 等. 基于多级支持向量机分类器的电力变压器故障识别[J]. 电力系统及其自动化学报, 2005, 17(1): 19-22. Lü Ganyun, Cheng Haozhong, Dong Lixin, et al. Fault diagnosis of power transformer based on multi-layer SVM classifier[J]. Proceedings of the CSU-EPSSA, 2005, 17(1): 19-22(in Chinese).
- [11] 吴晓辉, 刘炯, 梁永春, 等. 支持向量机在电力变压器故障诊断中的应用[J]. 西安交通大学学报, 2007, 41(6): 722-726. Wu Xiaohui, Liu Jiong, Liang Yongchun, et al. Application of support vector machine in transformer fault diagnosis[J]. Journal of Xi'an Jiaotong University, 2007, 41(6): 722-726(in Chinese).
- [12] 江伟, 罗毅, 涂光瑜. 基于多类支持向量机的变压器故障诊断模型[J]. 水电能源科学, 2007, 25(1): 52-55. Jiang Wei, Luo Yi, Tu Guangyu. Fault diagnosis model for power transformer based on multi-class support vector machine[J]. Water Resources and Power, 2007, 25(1): 52-55(in Chinese).
- [13] 肖燕彩, 陈秀海, 朱衡君. 遗传支持向量机在电力变压器故障诊断中的应用[J]. 上海交通大学学报, 2007, 41(11): 1878-1881, 1886. Xiao Yancai, Chen Xiuhai, Zhu Hengjun. The application of genetic support vector machine in power transformer fault diagnosis[J]. Journal of Shanghai Jiaotong University, 2007, 41(11): 1878-1881, 1886(in Chinese).

- [14] Lee Y, Lin Y, Wahba G. Multicategory support vector machines: theory and application to the classification of microarray data and satellite radiance data[J]. *Journal of the American Statistical Association*, 2004, 99(3): 67-81.
- [15] Zien A, Ong C S. Multiclass multiple kernel learning[C]. 24 th International Conference on Machine Learning, Corvallis, 2007.
- [16] Rakotomamonjy A, Bach F, Canu S, et al. More efficiency in multiple kernel learning[C]. 24 th International Conference on Machine Learning, Corvallis, 2007.
- [17] Kim S J, Magnani A, Boyd S. Optimal kernel selection in kernel \_sher discriminant analysis[C]. 23rd International Conference on Machine Learning, Pittsburgh, 2006.
- [18] Lee Y, Wahba G, Ackerman S. Classification of satellite radiance data by multicategory support vector machines[J]. *Journal of Atmospheric and Oceanic Technology*, 2004(21): 159-169.
- [19] Sonnenburg S, Raetsch G, Schaefer C, et al. Large scale multiple kernel learning[J]. *Journal of Machine Learning Research*, 2006(7): 1531-1565.
- [20] Bach F, Lanckriet G, Jordan M. Multiple kernel learning, conic duality, and the smo algorithm[C]. 21st International Conference on Machine Learning, Banff, Canda, 2004.
- [21] IEC. IEC 60599—2007 Mineral oil-impregnated electrical equipment

in service: guide to the interpretation of dissolved and free gases analysis[S]. Geneva: IEC, 2007.



郭创新

收稿日期: 2009-11-20。

作者简介:

郭创新(1969—), 男, 教授, 博士生导师, 研究领域为智能电网和分布式能源并网, 智能信息处理技术及其在电力系统中的应用研究, guochuangxin@zju.edu.cn;

朱承治(1977—), 男, 博士, 从事智能信息处理技术及其在电力系统中的应用研究;

张琳(1980—), 女, 博士, 从事智能信息处理技术及其在电力系统中的应用研究;

彭明伟(1985—), 男, 硕士研究生, 研究方向为电力系统故障诊断和智能信息处理技术及其在电力系统中的应用;

刘毅(1982—), 男, 博士研究生, 从事智能信息处理技术及其在电力系统中的应用研究。

(责任编辑 马晓华)