

DOI:10.13296/j.1001-1609.hva.2015.04.003

# 基于 DGA 的差分进化支持向量机电力变压器故障诊断

贾立敬, 张建文, 王传林, 严家明, 周贤娇, 陈鲁娜

(中国矿业大学信息与电气工程学院, 江苏 徐州 221116)

**摘要:** 针对支持向量机中参数选择严重影响分类效果的特点, 提出采用差分进化算法对核函数  $g$  和惩罚因子  $c$  进行优化, 得到最优的支持向量机模型, 用于变压器的故障诊断。在简单介绍支持向量机的基础上, 分析了采用差分进化算法对支持向量机优化的可行性。通过将收集的数据样本进行预处理, 再利用差分进化的变异、交叉和选择对高斯径向基核函数进行优化, 搜索出最优  $(c, g)$ , 并对得到的参数进行验证, 获得最优的支持向量机模型。仿真实验表明, 与 SVM、GRID-SVM、GA-SVM、PSO-SVM 相比, 该方法误判率最低、全局寻优能力及鲁棒性较好。

**关键词:** 支持向量机; 差分进化; 核函数; 故障诊断

## Fault Diagnosis of Power Transformer Based on DGA of Algorithm for SVM

JIA Lijing, ZHANG Jianwen, WANG Chuanlin, YAN Jiaming, ZHOU Xianjiao, CHEN Luna

(School of Information and Electrical Engineering, China University of Mining and Technology, Jiangsu Xuzhou 221116, China)

**Abstract:** In response to parameter selection seriously affect classification results in SVM, this paper proposes a method using differential evolution optimizes on parameter of kernel function  $g$  and penalty parameter  $c$ , aiming to getting the SVM machine model for the fault diagnosis of transformer. Firstly, this paper analyzes the feasibility of using differential evolution algorithm for SVM optimization based on the brief introduction of SVM. Through pretreating the collecting data samples and using the mutation, crossover and selection of differential evolution optimizes on RBF, the best parameters  $c$  and  $g$  are found out, and the parameters to obtain the SVM model are verified. The results show that, compared with non-optimized SVM, GRID-SVM, GA-SVM and PSO-SVM, this method has the lowest misjudgment rate and good global search ability and better robustness.

**Key words:** SVM; DE; kernel function; fault diagnosis

## 0 引言

电力变压器作为电力系统的主要设备, 其造价昂贵、结构复杂, 承担着联系不同电压等级电网的重任, 其运行状态直接影响系统的安全水平和可靠性<sup>[1]</sup>。一旦出现故障将会引起局部乃至大面积的停电, 造成重大经济损失, 所以研究大型电力变压器的故障诊断具有重大意义和实用价值。

变压器的故障诊断方法多种多样, 其中油中溶解气体分析方法 DGA 是检测变压器内部故障的一种有效手段<sup>[2]</sup>, 能及时发现电力变压器内部故障重

要的常规监测手段, 并在变压器的运行维护中发现并排除了多次故障隐患<sup>[3]</sup>。传统的故障诊断方法是依据《变压器油中溶解气体分析和判断导则(GB/T 7252—2001)》<sup>[4]</sup>, 当变压器发生故障时, 通过主要产生的以下 7 种气体: 乙炔( $C_2H_2$ )、甲烷( $CH_4$ )、乙烷( $C_2H_6$ )、以及氢气( $H_2$ )、一氧化碳( $CO$ )和二氧化碳( $CO_2$ )<sup>[5-6]</sup>的体积分数或比值, 利用特征气体法、罗杰斯比值法、改良三比值法<sup>[7]</sup>进行分析诊断故障, 但这些方法存在编码不全、编码边界过于绝对、不能诊断多故障等问题<sup>[8]</sup>。为了弥补比值法存在的“编码盲点”问题, 文[9]中从计算智能的角度对变压器故障诊断的研究成果进行了总结, 通过引入专家系统<sup>[10-11]</sup>、模糊数学<sup>[12]</sup>、人

收稿日期: 2014-10-17; 修回日期: 2014-11-21

基金项目: 第 54 批博士后基金(2013M541755)。

Project Supported by the Fifty-fourth Group of Postdoctoral Fund(2013M541755).

工神经网络<sup>[13]</sup>、灰色理论<sup>[14]</sup>等智能方法来对变压器故障进行判别,取得了一定的进展<sup>[15]</sup>。但是这些理论的提出大多数针对大样本数据,鉴于实际条件下变压器故障样本数据有限,不确定性因素多,因此以上智能故障诊断方法无法取得其最佳效果。

支持向量机算法是应用统计学习理论,专门解决具有非线性、样本少及维数高特性的模式识别问题的学习机器。采用支持向量机对变压器故障进行分类的过程中参数选择对判断效果产生很大影响。基于此,文中提出采用差分进化算法对 SVM 分类器的参数进行寻优,该算法使用了差分策略进行变异操作,通过随机个体间的差分向量对个体进行影响,有效利用了群体分布特性,提高算法的搜索能力,克服了传统 SVM 分类器参数选择效率低、泛化能力弱的问题。

文中通过差分进化算法对高斯径向基核函数进行优化,搜索到最优 $(c, g)$ ,再将得到的参数进行验证,获得最优的支持向量机模型。通过仿真实例将典型故障气体的相对含量作为支持向量机的输入,7 种典型故障作为输出,其最终分类结果与未经优化的 SVM、粒子群优化的 SVM、网格搜索方法优化的 SVM 进行比较,验证了该方法的准确性。

## 1 支持向量机概述

支持向量机(support vector machine, SVM)是应用统计学习理论,解决小样本数据的分类和回归问题的学习算法,其主要思想是,将输入空间中线性不可分的样本经过非线性映射到高维空间,变成线性可分问题,通过建立一个超平面,使正反样本数据被分开,同时之间的隔离边缘最大化<sup>[16]</sup>。

针对线性可分问题,通过定义分类超平面 $\langle \omega \cdot x \rangle + b = 0$ ,  $\omega \in R^n$  为超平面的法线,  $b \in R$  为截距,将训练样本集 $(x_1, y_1), (x_2, y_2), x \in R^n, y \in \{-1, +1\}$ 准确分开,并且使分类间隔最大,此时的超平面为该向量集合的最优分类超平面,见图 1。




图 1 最优分类面示意图

Fig. 1 The diagram of optimal classification plane

为了获得最优的分类超平面,需要寻找最优的参数  $\omega, b$ ,使得式(1)平面分别位于平面 $\langle \omega \cdot x \rangle + b = 0$ 的两侧,同时使得式(2)分类间隔最大,即 $\|\omega\|$ 最小化,可变为式(3)约束优化问题。

$$\begin{cases} \langle \omega \cdot x \rangle + b = 1 & y_i = 1 \\ \langle \omega \cdot x \rangle + b = -1 & y_i = -1 \end{cases}; \quad (1)$$

$$d = \frac{|1 - (-1)|}{\sqrt{\omega_1^2 + \omega_2^2 + \dots + \omega_N^2}} = \frac{2}{\|\omega\|}; \quad (2)$$

$$\begin{cases} \min \frac{1}{2} \|\omega\|^2 \\ \text{s.t. } y_i(\langle \omega \cdot x_i \rangle + b) \geq 1 \end{cases}. \quad (3)$$

通过构造 Lagrange 函数求解式(3)约束优化问题。引入 Lagrange 因子  $\alpha_i \geq 0$ ,可构造 Lagrange 函数为

$$L = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^l \alpha_i [y_i(\langle \omega \cdot x_i \rangle + b) - 1]. \quad (4)$$

对式(3)求关于  $\omega$  和  $b$  的偏微分,并令其为 0,可得到

$$\begin{cases} \omega = \sum_{i=1}^l \alpha_i y_i x_i \\ \sum_{i=1}^l \alpha_i y_i = 0 \end{cases}. \quad (5)$$

将式(5)代入式(4)得

$$L = \frac{1}{2} \langle \omega \cdot \omega \rangle - \sum_{i=1}^l \alpha_i [y_i(\langle \omega \cdot x_i \rangle + b) - 1] = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \langle x_i \cdot x_j \rangle. \quad (6)$$

在约束条件式(7)下,求式(6)最大值。当求得  $\alpha_i^*$

最优时  $\omega^* = \sum_{i=1}^l \alpha_i^* y_i x_i$ 。

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad \alpha_i \geq 0. \quad (7)$$

此时,分类函数为

$$f(x) = \text{sgn} \left( \sum_{SVS} \alpha_i^* y_i \langle x_i \cdot x \rangle + b^* \right). \quad (8)$$

式(8)中:支持向量机(SVS)= $\{x_i | \alpha_i^* > 0, i=1, 2, \dots, N_s\}$ ;  $N_s$  是支持向量数目,非支持向量对应的  $\alpha_i$  均为 0。利用核函数代替特征空间内积,得最优分类函数为

$$f(x) = \text{sgn} \left[ \sum_{SVS} \alpha_i^* y_i k(x_i \cdot x) + b^* \right]. \quad (9)$$

针对线性不可分问题,支持向量机通过引入松弛变量  $\xi_i$  和惩罚因子  $C$ ,其目标函数为

$$L(\omega, \xi) = \frac{1}{2} \|\omega\|^2 + C \left( \sum_{i=1}^l \xi_i \right). \quad (10)$$

常用的核函数有多项式核、Sigmoid 核和高斯径向基核(RBF)<sup>[17]</sup>。

## 2 差分进化算法

### 2.1 差分进化算法

差分进化是一种采用实数编码求最值的优化算法,利用种群中个体向量的分布特性获得差分向量,指导进一步的搜索。其原理与遗传算法相似,包括变异、交叉和选择3个阶段,但该算法使用了差分策略。其基本思想是:从当前种群提取方向信息及搜索步长,为了提高种群多样性加上随机差分和交叉,通过变异和交叉,产生一个临时种群;然后对这两个种群进行一一对比、选择,从而产生新一代种群,按上述方法对种群不断进化,直至满足条件为止<sup>[18]</sup>。其流程如下。

1)种群初始化。随机产生的初始种群见式(11)。

$$x_{j,i} = x_{j,\min} + \text{rand}_{i,j}[0,1] \cdot (x_{j,\max} - x_{j,\min})$$

$$i=1,2,\dots,NP, j=1,2,\dots,D. \quad (11)$$

式(11)中: $x_{j,\max}$ 和 $x_{j,\min}$ 为变量 $x$ 的搜索空间 $[x_{j,\min}, x_{j,\max}]$ ;  $\text{rand}_{i,j}[0,1]$ 为 $[0,1]$ 区间内均匀分布的随机数; $NP$ 表示种群大小; $D$ 表示问题空间解的维数。

2)差分变异操作。在当前种群中随机选取两个相异个体,将其向量缩放后与待变异的个体进行向量合成,生成新的个体,即

$$V_i(g+1) = X_{r1}(g) + F \cdot [X_{r2}(g) - X_{r3}(g)]. \quad (12)$$

式(12)中: $r_1, r_2, r_3, i$ 为区间 $[1, NP]$ 内互不相同的整数; $F$ 为缩放因子; $X_{r1}(g)$ 为第 $g$ 代种群中第 $r_1$ 个个体。如果“染色体”中各“基因”不在边界范围内,则重新生成新的变异个体。

这种通过差分策略实现个体变异,是与遗传算法的不同之处,也是差分进化算法中的重要操作。

3)交叉操作。为了增加种群的多样性引入了交叉操作,差分进化算法采用离散交叉算子:二项式交叉和指数交叉<sup>[19]</sup>。

$$U_{j,i}(g+1) = \begin{cases} V_{j,i}(g+1) & \text{rand} > CR \text{ 或 } j = j_{\text{rand}} \\ X_{j,i}(g) & \text{其他} \end{cases} \quad (13)$$

其交叉过程为将变异得到的个体与目标个体按照式(13)进行操作。式(13)中: $\text{rand}$ 表示区间 $(0,1)$ 内均匀分布的随机数; $U_{j,i}(g+1)$ 和 $V_{j,i}(g+1)$ 分别为 $U_i(g+1)$ 和 $V_i(g+1)$ 的第 $g+1$ 代新种群中第 $i$ 个个体的第 $j$ 个分量; $CR$ 表示交叉概率因子,其值越大则选择的交叉位越大; $j_{\text{rand}}$ 为 $[1, D]$ 内均匀分布的随机整数。图2为8个基因位的“染色体”交叉操作示意图。

4)选择操作。将经过变异和交叉操作产生的后代群体,采用贪婪选择策略进行适应度的比较,见式(14)。

$$X_i(g+1) = \begin{cases} U_i(g+1) & f[U_i(g+1)] \leq f[X_i(g)] \\ X_i(g) & \text{其他} \end{cases} \quad (14)$$




图2 交叉示意图

Fig. 2 The cross schematic diagram

选择 $U_i$ 和 $X_i$ 中适应度最优的作为子代。其流程图见图3。




图3 差分进化算法流程图

Fig. 3 The differential evolution algorithm flow chart

由于差分进化算法原理相对简单,控制参数较少,优化速度较高、全局搜索能力及鲁棒性较强,提出采用差分进化算法对SVM参数进行优化。

### 2.2 差分进化算法的SVM参数寻优

基于DE的全局搜索能力,以样本误判率最小为优化准则建立目标函数,对支持向量机分类器的核参数和惩罚参数寻优,克服传统SVM分类器参数选择效率低、泛化能力弱的问题,提高了支持向量机的分类精度和实用性能。

基于DE-SVM的软测量模型属于黑盒子一类的模型,只关心对象的输入与输出,而不必关心对象的具体结构,输入与输出的映射关系由SVM完成。在基于DE算法的SVM建模中,正规化惩罚因子 $c$ 和核参数 $g$ 由DE算法产生,SVM的输出与实际值 $y$ 的误差平方和作为DE算法的目标函数。具体建模方法步骤为:

1)将样本参数分为训练集和测试集两部分,并对其进行归一化处理。

2)进行差分进化算法的初始化操作,设置种群大小 $NP$ ,种群维数,进化代数 $T$ ,缩放因子 $F$ ,交叉

概率  $CR$ 。

3) 选择 RBF 函数作为支持向量机的核函数, 并将训练集输入到 SVM, 将训练后的输出值与实际值误差平方和结果作为 DE 算法的目标函数, 判断误差大小是否满足要求或者  $G$  是否等于  $G_m$ , 若满足其中一项, 则可以获得最优的参数  $c, g$ 。否则  $G=G+1$ , 并进行变异、交叉、选择操作, 获得新的  $c, g$ 。

4) 将得到的最优值  $c, g$  作为 SVM 的参数, 测试集作为输入, 根据差分进化算法的支持向量机计算出预测输出。

5) 对测试集的实际值与预测值进行比较分析, 判断分类的准确程度。参数优化流程图见图 4。




图 4 参数优化流程图

Fig. 4 The parameters optimization flow chart

### 3 实例仿真与结果分析

为了验证上述方法的可行性, 对变压器油中溶解气体的体积分数进行仿真。将收集的数据样本分为训练集和测试集, 并对数据进行归一化处理, 通过差分进化算法寻取最优参数值, 再把得到的值进行验证, 其完整模型见图 5。




图 5 基于 DE 的 SVM 模型

Fig. 5 The SVM model based on DE

#### 3.1 样本分类

由于支持向量机针对的是小样本数据, 文中采用大型电力变压器油中溶解的  $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$  的体积分数作为特征值, 以低温过热、中温过

热、高温过热、局部放电、低能放电、电弧放电以及正常状态作为 SVM 的状态输出。其中训练集 28 组, 测试集 28 组, 训练集合测试集对应的样本数见表 1。

表 1 训练集和测试集对应的样本分布

Table 1 Training set and testing set corresponding sample distribution

| 序号 | 故障性质            | 训练集 | 测试集 |
|----|-----------------|-----|-----|
| 1  | 低温过热(<150 ℃)    | 4   | 4   |
| 2  | 中温过热(150~300 ℃) | 4   | 4   |
| 3  | 高温过热(300~700 ℃) | 4   | 4   |
| 4  | 局部放电            | 4   | 4   |
| 5  | 低能放电            | 4   | 4   |
| 6  | 电弧放电            | 4   | 4   |
| 7  | 正常状态            | 4   | 4   |
| 总共 | —               | 28  | 28  |

由表 1 得到图 6 特征气体分布。由图 6 可知电力变压器内部不同故障产生的特征气体及其体积分数不同, 当温度较低时,  $CH_4$  占的比例较大; 随着温度的升高,  $C_2H_4$  体积分数急剧增加; 当严重过热时产生少量的  $C_2H_2$ ; 当发生局部放电时, 主要成分是  $H_2$ , 其次是  $CH_4$ ; 当发生火花放电时油中溶解的特征气体以  $C_2H_2$ 、 $H_2$  为主; 当发生电弧放电时, 故障特征气体主要是  $C_2H_2$ 、 $H_2$ , 其次是大量的  $C_2H_4$  和  $CH_4$ 。这种特征与大量的运行经验相符, 证明此样本数据的有效性。




图 6 特征气体分布

Fig. 6 Characteristics of the gas distribution

#### 3.2 参数优化

首先对 DE 算法中的参数进行初始化设置: 最大进化代数  $g_m=200$ , 缩放因子  $F=0.5$ , 交叉概率  $CR$  为 0.5, SVM 惩罚参数  $c$  和 RBF 核参数  $\delta$  的范围为  $[2^{-15}, 2^{15}]$ 。经过优化选择后最终得到支持向量机最优惩罚参数  $c=85.159\ 5$ ,  $g=0.128\ 75$ , 最佳分类准确率为 96.428 6%。

将寻优得到的  $(c, g)$  进行验证, 其准确率为 96.428 6%。

3.3 预测结果与分析

为了进一步验证该方法的有效性, 分别对未经优化的 SVM、经 GRID 优化的 SVM、经 GA 优化的 SVM、经 PSO 优化的 SVM 与经 DE 优化的 SVM 进行对比分析。比较结果见表 2。通过对比分析, 发现经过优化的 SVM 其分类准确率都得到不同程度的提高。但是网格法进行优化所需时间长, 搜索范围需要事先设定, 其准确性也有待于提高; 遗传算没有

记忆功能, 进行优化时以前的知识随着种群的改变被破坏; 粒子群算法相对于遗传算法, 不需要编码, 没有交叉和变异操作, 粒子只是通过内部进行更新, 因此原理更简单、参数更少、实现更容易, 但是其收敛性不如遗传算法。差分进化算法具有全局搜索能力, 以样本误判率最小为优化准则, 准确率较其余几种优化方法高, 因此选用差分进化的 SVM 进行故障诊断。

表 2 不同方法对变压器故障诊断的比较

Table 2 The comparison of different methods for transformer fault diagnosis

| 优化方法     | 第 1 类正确个数(正确率) | 第 2 类正确个数(正确率) | 第 3 类正确个数(正确率) | 第 4 类正确个数(正确率) | 第 5 类正确个数(正确率) | 第 6 类正确个数(正确率) | 第 7 类正确个数(正确率) | 总的正确个数(正确率) |
|----------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|-------------|
| SVM      | 3(0.75)        | 4(1.00)        | 2(0.50)        | 1(0.25)        | 1(0.25)        | 2(0.50)        | 3(0.75)        | 16(0.57)    |
| GRID-SVM | 3(0.75)        | 4(1.00)        | 2(0.50)        | 4(1.00)        | 3(0.75)        | 2(0.50)        | 1(0.25)        | 19(0.68)    |
| GA-SVM   | 4(1.00)        | 3(0.75)        | 2(0.50)        | 4(1.00)        | 4(1.00)        | 3(0.75)        | 2(0.50)        | 22(0.79)    |
| PSO-SVM  | 4(1.00)        | 4(1.00)        | 3(0.75)        | 4(1.00)        | 3(0.75)        | 3(0.75)        | 3(0.75)        | 24(0.86)    |
| DE-SVM   | 4(1.00)        | 4(1.00)        | 4(1.00)        | 4(1.00)        | 3(0.75)        | 4(0.75)        | 4(1.00)        | 27(0.96)    |

4 结语

文中提出一种基于差分进化支持向量机(SVM)的变压器故障诊断方法。该方法采用差分进化算法对支持向量机的核函数进行优化, 以选出最优的参数( $c, g$ ), 对电力变压器常见的 7 种故障进行分类识别。仿真测试结果表明, 该方法与未经优化的 SVM、粒子群优化的 SVM、网格搜索方法优化的 SVM 相比较, 具有较高的仿真速度和识别精度。

参考文献:

[1] 朱永利, 尹金良. 组合核相关向量机在电力变压器故障诊断中的应用研究[J]. 中国电机工程学报, 2013, 33(22): 68-74.  
ZHU Yongli, YIN Jinliang. Study on application of multi-kernel learning relevance vector machines in fault diagnosis of power transformers[J]. Proceedings of the CSEE, 2013, 33(22): 68-74.

[2] 马叶芝, 焦彦军, 王东升, 等. 变压器故障诊断中溶解气体的 PSO-WFCM 算法研究 [J]. 高压电器, 2014, 50(1): 72-76.  
MA Yezhi, JIAO Yanjun, WANG Dongsheng, et al. Detection of dissolved gas with PSO-WFCM algorithm power transformer[J]. High Voltage Apparatus, 2014, 50(1): 72-76.

[3] 谢红侠. 变压器维修决策的研究[D]. 徐州: 中国矿业大学, 2012.  
XIE Hongxia, Study on maintenance decision in transformer[D]. Xuzhou: China University of Mining and Technology, 2012.

[4] 国家质量监督检验检疫总局. GB/T 7252—2001 变压器

油中溶解气体分析和判断导则[S]. 2001.  
General Administration of Quality, Inspection and Quarantine of People's Republic of China. Supervision guide to the analysis and the diagnosis of gases dissolved in transformer oil[S]. 2001.

[5] MORAIS M R, MANNHEIMER A W, CARBALLEIRA M, et al. Furfural analysis for assessing degradation of thermally upgraded papers in transformer insulation [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 1999, 6(2): 159-163.

[6] 武中利. 电力变压器故障诊断方法研究[D]. 保定: 华北电力大学, 2013.  
WU Zhongli. Research on fault diagnosing methods for power transformers[D]. Baoding: North China Electric Power University, 2013.

[7] 熊浩, 孙才新, 杜鹏, 等. 基于物元理论的电力变压器状态综合评估 [J]. 重庆大学学报, 2006, 29(10): 24-28.  
XIONG Hao, SUN Caixin, DU Peng, et al. Based on a comprehensive assessment of the state of the power transformer matter element theory[J]. Journal of Chongqing University, 2006, 29(10): 24-28.

[8] SUN H C, HUANG Y C, HUANG C M. Fault diagnosis of power transformers using computational intelligence: A review[J]. Energy Procedia, 2012, 14(10): 1226-1231.

[9] 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): 32-35.  
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): 32-35.

- [10] LIN C E, LING J M, HUANG C L. Expert system for transformer diagnosis using dissolved gas analysis[J]. IEEE Transaction on Power Delivery, 1993, 8(1): 231-238.
- [11] HUANG Y F. Developing a new transformer fault diagnosis system through evolutionary fuzzy logic[J]. IEEE Trans. on Power Delivery, 1997, 12(2): 761-767.
- [12] 杜文霞, 吕 锋, 句希源. 基于 BP 神经网络的电力变压器故障诊断[J]. 变压器, 2007, 44(3): 45-47.  
DU Wenxia, LYU Feng, JU Xiyuan. Fault diagnosis of power transformer based on BP neural network[J]. Transformer, 2007, 44(3): 45-47.
- [13] 宋 斌, 于 萍, 罗运柏, 等. 基于灰关联熵的充油变压器故障诊断方法 [J]. 电力系统自动化, 2005, 29(18): 76-79.  
SONG Bin, YU Ping, LUO Yunbo, et al. Oil-filled power transformer fault diagnosis based on gray relational entropy[J]. Automation of Electric Power Systems, 2005, 29(18): 76-79.
- [14] 肖燕彩. 支持向量机在变压器状态评估中的应用研究 [D]. 北京: 北京交通大学, 2008.  
XIAO Yancai. Application study of support vector machine transformer condition assessment[D]. Beijing: Beijing Jiaotong University, 2008.
- [15] HE H, STARZYK J A. A self-organizing learning array system for power quality classification based on wavelet transform[J]. IEEE Trans. on Power Delivery, 2006, 21(1): 286-295.
- [16] 平 源. 基于支持向量机的聚类及文本分类研究[D]. 北京: 北京邮电大学, 2012.  
PING Yuan. Research on clustering and text categorization based on support vector machine [D]. Beijing: Beijing University of Posts and Telecommunications, 2012.
- [17] 陈 涛, 雍龙泉, 邓方安, 等. 基于差分进化算法的支持向量机参数选择[J]. 计算机工程与应用, 2011, 47(5): 24-26.  
CHEN Tao, YONG Longquan, DENG Fang'an, et al. Parameters selection of support vector machine based on differential evolution[J]. Computer Engineering and Applications, 2011, 47(5): 24-26.
- [18] 陈 亮. 改进自适应差分进化算法及其应用研究[D]. 上海: 东华大学, 2012.  
CHEN Liang. Improved adaptive differential evolution algorithm and its applications[D]. Shanghai: Donghua University, 2012.
- [19] 林碧华, 顾幸生. 基于差分进化算法-最小二乘支持向量机的软测量建模[J]. 化工学报, 2008, 59(7): 1681-1685.  
LIN Bihua, GU Xingsheng. Soft sensor modeling based on DE-LSSVM[J]. Journal of Chemical Industry and Engineering, 2008, 59(7): 1681-1685.
- 贾立敬(1988—), 女, 硕士研究生, 从事电气设备状态监测与故障诊断技术方向研究。  
张建文(1968—), 男, 博士, 教授, 从事电气设备状态监测与故障诊断技术、高电压技术方向研究。  
王传林(1990—), 男, 硕士研究生, 从事电能质量监测方向研究。  
严家明(1977—), 男, 博士研究生, 从事高电压技术方向研究。  
周贤娇(1990—), 女, 硕士研究生, 从事高电压技术方向研究。  
陈鲁娜(1988—), 女, 硕士研究生, 从事高电压技术方向研究。

(编辑 袁 妮)

(上接第 12 页)

- [31] 陈 隽, 李劲彬, 夏 天, 等. 绝缘子对 GIS 中电磁波传播特性影响的仿真研究[J]. 陕西电力, 2014, 42(11): 6-8.  
CHEN Jun, LI Jinbin, XIA Tian, et al. Simulation study on influence of insulator on propagation characteristics of electromagnetic wave in GIS[J]. Shaanxi Electric Power, 2014, 42(11): 6-8.
- [32] 张思寒. 同塔多回输电线路雷击同时跳闸机理研究[J]. 陕西电力, 2014, 42(9): 44-47.  
ZHANG Sihan. Research on mechanism of lightning strike simultaneous tripping on multi-circuit transmission line on same tower[J]. Shaanxi Electric Power, 2014, 42(9): 44-47.
- 金立军(1964—), 男, 教授, 博士生导师, 研究方向为开关设备的智能化及在线监测与故障诊断。

(编辑 袁 妮)