

自适应模糊支持向量机邻近增量算法 在变压器故障诊断中的应用

刘同杰^{1,2}, 刘志刚¹, 韩志伟¹

(1. 西南交通大学电气工程学院, 四川 成都 610031; 2. 乐山电业局, 四川 乐山 614000)

摘要: 提出了一种基于自适应模糊支持向量机增量算法的变压器故障诊断方法。对变压器故障诊断采取分层结构, 以模式识别思想提取与分类模式密切相关的输入特征, 有效地抑制了冗余信息的干扰; 采用参数自适应优化算法增强了 SVM 参数选择的灵活性, 加快了算法的收敛速度。邻近增量算法提高了诊断模型的精度与对于新样本的学习能力, 与普通的多分类支持向量机以及多分类模糊支持向量机算法相比, 该算法具有较好的收敛性和良好的诊断效果。

关键词: 模糊支持向量机; 增量算法; 隶属度; 自适应; 变压器; 油中溶解气体

Application of adaptive fuzzy support vector machine with adjacent incremental algorithm of transformer fault diagnosis

LIU Tong-jie^{1, 2}, LIU Zhi-gang¹, HAN Zhi-wei¹

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;
2. Leshan Electricity Power Bureau, Leshan 614000, China)

Abstract: A new method of transformer fault diagnosis based on adaptive fuzzy support vector machine with adjacent incremental algorithm is proposed. Based on the concept of feature extraction in pattern recognition, a hierarchical structure is employed to extract the input features closely related to the model of classification, and it has effectively suppressed the interference of redundant information; the adaptive parameter optimization algorithm has both increased the flexibility of parameter selection for FSVM and enhanced the convergence speed. Besides, the adjacent incremental algorithm has both improved the precision of the diagnosis model and increased the learning abilities to new samples. Compared with the diagnosis model of multi-SVM and multi-FSVM, this method has a strong convergence and excellent diagnosis result.

Key words: fuzzy support vector machine; incremental algorithm; membership; adaptive; transformer; oil dissolved gases

中图分类号: TM71 文献标识码: A 文章编号: 1674-3415(2010)17-0047-06

0 引言

变压器是电力系统中比较贵重的枢纽设备, 其故障不仅影响到供电的可靠性, 而且对电力系统的运行安全构成严重威胁, 如何发现并判别变压器故障一直是电业部门的重要课题。油种溶解气体分析(DGA)是发现和判别变压器故障的有效手段, 它的实质是寻找一种能客观、准确地描述油中溶解气体的特征信息到变压器故障类型之间关系的映射。

虽然传统的三比值法(IEC)以及一些改进的比值方法已经使得这种映射从定性分析到具体操作, 但它们在描述这种具有高度非线性、高维数特征的复杂关系时仍有很多不足。

近年来, 人工智能的发展给上述问题带来了许多新的解决途径。如神经网络^[1-2]、模糊粗糙集^[3]、多专家融合^[4]、小波网络^[5]、证据推理^[6]、灰色理论^[7]、贝叶斯网络^[8]以及一些组合或改进的算法^[9-10], 它们的引入很大程度上提高了故障诊断的效果。然而由于缺少根据不同类型的故障对输入特征的提取和简约, 使得那些被误判的故障很难得到修正, 同时为了减少误判率, 在参数调整时, 很难

基金项目: 2008 教育部新世纪优秀人才支持项目 (NECT-08-0825); 教育部霍英东青年教师基金 (101060); 四川省杰出青年基金 (07ZQ026-012)

把握机器学习过程中是否充分或过量，一定程度上削弱了算法的推广性能。

支持向量机 (support vector machine, SVM) 是由 Vapnik 等提出的，它已在许多领域取得了成功的应用。在传统 SVM 中，对所有训练样本都是同等对待的^[11-12]，但在很多实际问题中，不同的训练点对分类结果的影响是不同的。一般来说，训练集中存在某些点对分类结果的影响很大，它们对分类面的构造起决定性作用，同时存在一些点对分类结果影响小，甚至微不足道。在处理分类问题时，应降低甚至忽略它们的作用。模糊支持向量机^[13]方法将模糊技术应用于 SVM 中，通过根据每个数据点对分类结果的不同影响，对不同的样本给予不同的隶属度，从而降低噪音和孤立点对样本的影响。

本文在深入挖掘油中溶解气体所含故障特征信息的基础上，通过比较选取对故障诊断较敏感的输入量，排除了一些不敏感信息的干扰。利用分层决策有效地实现了对故障信息的提取，结合模糊支持向量机在小样本、非线性、高维数方面的学习优势，引进自适应优化算法^[14]确定 FSVM 参数，由诊断效果的比较和支持向量分析得出，该算法具有较高的准确率和良好的泛化能力。

1 诊断模型的建立

1.1 故障分类

变压器的内部故障，就其故障现象来看，主要有热性故障和电性故障。根据热点温度的高低，又可以将热性故障具体分为：低温过热 T1 ($\leq 300^\circ\text{C}$)、中温过热 T2 ($>300^\circ\text{C}$ 且 $\leq 700^\circ\text{C}$) 和高温过热 T3 ($\geq 700^\circ\text{C}$)；而电性故障是在高电应力作用下所造成的绝缘劣化，由于能量密度的不同，可分为局部放电 PD、低能放电 D1 和高能放电 D2。同时，为降低分类的复杂度，根据故障的严重程度以及主要引起因素将具有多重故障的样本划为单一故障处理。

1.2 分层决策特征提取

(1) 有无故障特征。目前，对变压器有无故障的判别主要是根据 DGA 气体各组分是否超过极限值^[1]，但由于油中溶解气体随变压器运行时间和电压等级等的不同气体含量差异较大，因此即使超过极限值也不能完全判定为有故障，但它仍然是判定有无故障的主要依据。

(2) 不同故障类型特征。变压器故障类型与油中溶解气体的组成、含量和气体之间的比值之间有着密切的关系，信息损失或者冗余都会给故障分类效果带来不利影响。文献[15]的统计分析结论，

在对电性和热性故障判别时，比值 $\phi(\text{C}_2\text{H}_2)/\phi(\text{C}_2\text{H}_4)$ 能有较好的效果。IEC 法是根据热力学原理发展而来的，对于热性故障判别的效果较好，因此在考虑对热性故障进行细分时，采用三比值法输入。对电性故障具体判别时，仍采用与判别电性和热性故障一样的方法。因为不同的电性故障 H_2 和 C_2H_2 气体的含量存在明显差异。

1.3 分层诊断模型

基于决策特征提取的 FSVM 分层诊断模型如下 (图 1)，其中有无故障判别采用的是 FSVM 一对一算法，热性故障判别和电性故障判别采用的是 FSVM 多分类算法。

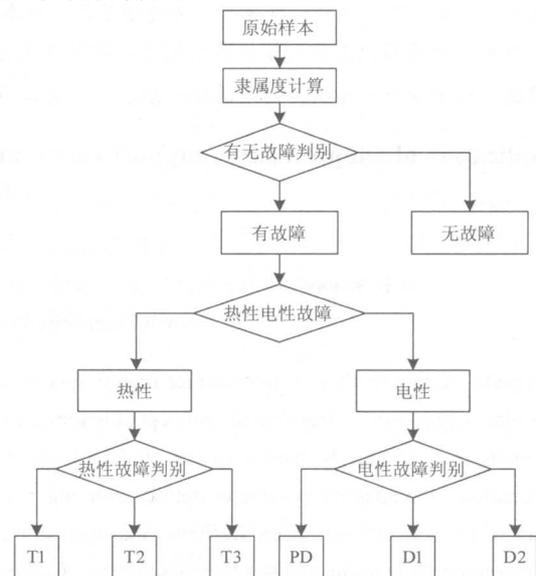


图 1 FSVM 分层诊断模型

Fig.1 Hierarchical FSVM model

2 模糊支持向量机

2.1 模糊支持向量机

假设训练样本为： $(x_1, y_1, \mu_1), (x_2, y_2, \mu_2), \dots, (x_n, y_n, \mu_n)$ ，其中输入训练向量 $x_i \in R^d (i = 1, 2, \dots, n)$ ， x_i 属于两类中的一类 y_i ，且 $y_i \in \{-1, 1\}$ ， μ_i 是隶属度，表明 x_i 属于 y_i 的程度， $0 \leq \mu_i \leq 1$ ， $(i = 1, 2, \dots, n)$ 同 SVM 一样，目标是建立超平面，它能把两类分开，且使超平面到两类的距离最大。优化问题变为：

$$\min \frac{1}{2} \|w^2\| + C \cdot \sum_{i=1}^n \mu_i \xi_i \quad (1)$$

约束条件：

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i \quad \xi_i \geq 0, (i = 1, 2, \dots, n) \quad (2)$$

式中: C 为常数; 参数 ξ_i 表示 SVM 解的错误度量, 而 $\mu_i \xi_i$ 是具有不同权值的错误度量。求解上面的优化问题, 可以先构造 Lagrange 函数, 即

$$L(w, b, \alpha, \beta) = \frac{1}{2} \|w\|^2 + C \cdot \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \alpha_i [y_i (w \cdot x_i + b) - 1 + \xi_i] - \sum_{i=1}^n \beta_i \xi_i \quad (3)$$

其中, $\alpha_i \geq 0, \beta_i \geq 0$ 。

要求解 Lagrange 函数的鞍点, L 分别对 w, b, ξ 求偏导, 并令其等于 0, 即:

$$\begin{aligned} \frac{\partial L}{\partial w} &= w - \sum_{i=1}^n \alpha_i y_i x_i = 0; \\ \frac{\partial L}{\partial b} &= -\sum_{i=1}^n \alpha_i y_i = 0; \\ \frac{\partial L}{\partial \xi} &= \mu_i C - \alpha_i - \beta_i = 0 \end{aligned} \quad (4)$$

得到: $w = \sum_{i=1}^n \alpha_i y_i x_i$; $\sum_{i=1}^n \alpha_i y_i = 0$;

$$\mu_i C = \alpha_i + \beta_i. \quad (5)$$

将以上三式代入 Lagrange 函数式 (3), 上述的问题变成如下的二次优化问题:

$$\max Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (6)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq \mu_i C, \quad i=1, 2, \dots, n$$

满足约束条件:

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

$0 \leq \alpha_i \leq \mu_i C, \quad i=1, 2, \dots, n$; α_i 为与每个样本对应的 Lagrange 乘子。

$$\text{若 } \alpha_i^* \text{ 为最优解, 则: } w^* = \sum_{i=1}^n \alpha_i^* y_i x_i \quad (8)$$

b^* 为分类阈值, b^* 可用任意一个支持向量 x^* 求得, 满足式 (8) 中的等号成立, 可求得:

$$b^* = \frac{1 - \xi_i}{y_i} - w^* \cdot x_i \quad (9)$$

式 (6) 和式 (7) 所示的优化问题, 是一个不等式约束下的二次函数极值问题, 存在唯一解。解中将只有一部分 (通常是少部分) α_i 不为零, 这些 α_i 对应的样本就是支持向量。

最终得到的决策函数为:

$$f(x) = \text{sgn} \left[\sum_{i=1}^n \alpha_i^* y_i K(x_i \cdot x) + b^* \right] \quad (10)$$

样本到类中心的距离是衡量样本对所在类贡献大小的依据之一。目前, 在模糊支持向量机中, 基于距离的函数的确定是样本的隶属度看作是特征空间中样本与其所在中心之间的距离的函数。依据距离确定隶属度时, 类中各样本的隶属度为:

$$\mu(x_i) = 1 - \frac{\|x_i - \bar{x}\|}{\max_i \|x_i - \bar{x}\|} + \delta \quad (11)$$

其中, $\delta > 0$ 是预设的一个很小的常数, 避免出现 $\mu(x_i) = 0$ 的情况。

2.2 邻近聚类增量算法

尽管 FSVM 在很多方面都具有其他学习算法难以比拟的优越性。但在离线建模时, 往往从测量数据中选出具有代表性的数据, 建立系统输入输出之间的映射关系, FSVM 模型建立后一般不再变化。这种模型简单、易用, 但将这种模型应用于不断更新的样本数据时, 存在一些缺点。随着样本数量的增多, SVM 缺乏对增量式学习的支持, 当新增样本与训练好的数据集相差甚远时, 模型的预测准确度将非常低。要想使模型具备增量学习能力, 也就是要求训练好的模型不仅能准确地预测出新的数据, 而且也不能忘记原来的知识。

设给定本集为 $D = \{x_i | i=1, 2, \dots, l\}$, $O = \{y_i | i=1, 2, \dots, l\}$, 其中 $x_i \in R^N$ 为输入值, $y_i \in R$ 为对应的目标值, l 为样本数。

1) 计算 D 中的所有样本的隶属度:

$$\mu(x_i) = 1 - \frac{\|x_i - \bar{x}\|}{r} + \delta;$$

2) 计算 D 样本的欧氏距离中心:

$$D_{\text{center}} = \frac{\sum_{i=1}^l x_i}{l};$$

3) 计算 D 样本的最大边缘距离:

$$D_{\text{max}} = \max \|x_i - D_{\text{center}}\|, \quad i=1, 2, 3, \dots, l;$$

4) 筛选样本建立新的训练样本: 计算原样本中 x_i 到新中心的距离 d_{xi} , 如果 $d_{xi} \leq D_{\text{max}}$, 则选取所有的满足条件的 d_{xi} , 建立新的诊断模型。

5) 重新计算新训练样本和样本 D 的隶属度, 按照图 1 所示流程完成对 D 的判别。

2.3 参数自适应优化

FSVM 常用的核函数主要有线性核、多项式核、径向基核以及感知器核^[14]。本文选择径向基核为核函数，其表达式为： $K(x_i, x_j) = \exp(-g\|x_i - x_j\|^2)$ 。在 SVM 建模过程需要确定的参数有：学习参数惩罚因子 C ，松弛因子 ϵ 以及核函数参数 g 。

本文取 $\epsilon = 10^{-3}$ ，参数 C 和 g 的确定采用的是自适应优化算法^[16]，步骤如下：①选取 C 和 g 的范围， $C = (C_1, C_2, \dots, C_m)$ ， $g = (g_1, g_2, \dots, g_n)$ ；②利用网格搜索得到参数对 (C_i, g_j) ， $i = 1, 2, \dots, m$ ； $j = 1, 2, \dots, n$ ；③训练、测试及调试参数，若不满足要求，则返回②修改取值范围，直到得到最优参数对 (c, g) ；④利用③的结果训练、测试，查看支持向量和诊断效果，若不满意返回②继续调整。

3 算例仿真

本文将收集整理好的 430 组 DGA 数据，其中 205 组作为训练样本 T_r ，225 组作为测试样本 T_e 。训练样本中包括：无故障 23 个，低温过热 22 个，中温过热 21 个，高温过热 35 个，局部放电 19 个，低能放电 35 个，高能放电 50 个。

在计算样本隶属度时候为了使得样本的隶属度 $\mu(x_i)$ 属于 $[0, 1]$ ，针对不同故障类别的 δ 取值分别为： $[0.1250 \ 0.2622 \ 0.0389 \ 0.0366 \ 0.0202 \ 0.0237 \ 0.0264]$ ，此时，样本中最大隶属度正好为 1。选取高斯核函数，误差精度 ξ 取 10^{-3} 。在分层结构中，有无故障识别效果如图 2 所示，电性和热性的故障识别效果如图 3 所示，由热性故障到高、中、低温过热的识别效果如图 4 所示。具体电性故障的识别效果见图 5。

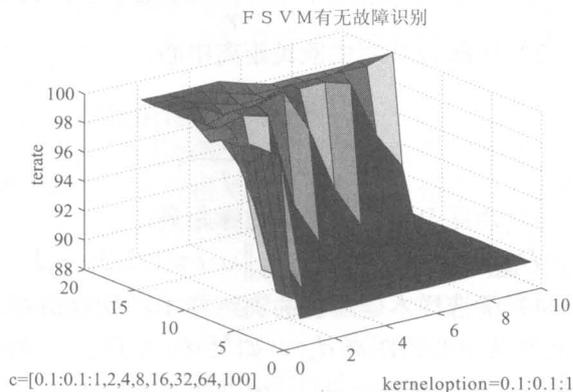


图 2 FSVM 有无故障识别
Fig.2 Recognition of electrical and thermal faults

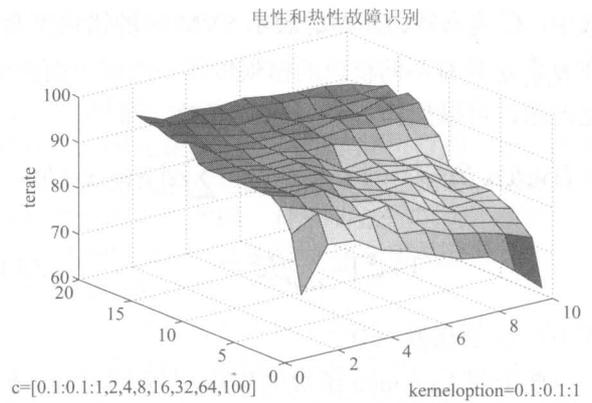


图 3 电性和热性故障识别
Fig.3 Fault recognition of FSVM

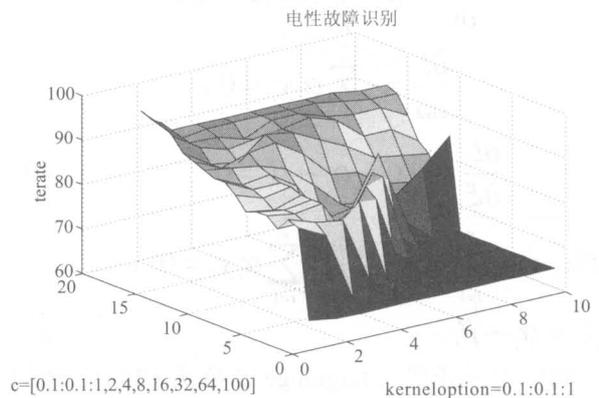


图 4 热性故障识别
Fig.4 Result of thermal fault recognition

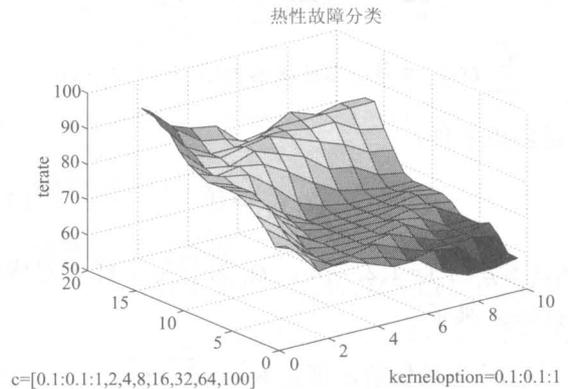


图 5 电性故障识别
Fig.5 Result of discharge fault recognition

图 2 可以看出，此 FSVM 有无故障诊断模型对于有无故障判别具有很好的效果和收敛性。图 3 中，在判别电性和热性故障时，虽然 FSVM 的参数收敛效果不是很理想，但是整个模型的参数对于正判率具有较好的鲁棒性，与 SVM 诊断模型相比较，很大程度上提高了模型的推广能力。变压器热性故障是具有连续性的，加上不同气体的脱气率，测量精

度等的影响, 虽然硬性地将其划分为低温过热、中温过热和高温过热, 但其实它们的界限却不是那么严格。因此, 继续采用二分类算法也缺乏一定的合理性。

选取分层诊断模型的最佳诊断效果见表 1, 可以看出各种故障经特征提取之后, 都能有较高的准确率。在 FSVM 分层分类中, 诊断效果很难达到 100%, 错误的分类会一直保留到最终判定结果。但是这种分类结果有效地减少了 FSVM 分类器的数量, 提高了整个模型的速度。

表 1 FSVM 分层识别训练时间和诊断效果

Tab.1 Training time and diagnosis result of hierarchical FSVM

诊断类别	参数对	训练时间/s	正判数	正判率
有无故障	170	36.593	222/225	99.5%
热性电性故障	170	68.25	198/201	98.51%
热性	170	50.828	96/100	96.0%
电性	170	43.188	98/101	97.02%

由表 2 诊断效果比较可以看出模糊支持向量机的诊断效果略优于普通的传统的 SVM, 两者差别不大, 在程序运行中, 只有在 DGA 样本过于分散或者存在明显坏值或奇点的时候, 模糊支持向量机才能显示一定的优越性。因此, 模糊支持向量机使得对原始的输入要求降低。但是分层结果, 由于采用了由粗到细的结果, 减少了 FSVM 分类器数目, 同时建立了针对具体故障更加精确的诊断模型, 提高了整个模型的判别效果。

表 2 分类结果比较

Tab.2 Comparison of classification result

分类方法	有无故	故障类	训练时	训练时	准确率
	障识别	型识别	间 I/s	间 II/s	
M-SVM	221/225	185/201	40.4530	158.062	91.11%
M-FSVM	222/225	187/201	36.593	141.641	92.44%
H-FSVM	222/225	191/201	36.593	103.452	94.22%

综上所述, 因为 DGA 样本数据的分散性, 合理规范的样本很难收集, 所以本文在训练增量学习算法时仅选取故障类别明确的样本。通过诊断效果图和离线多分类 SVM 及 FSVM 离线算法可以看出, 以通过 SVM 不同故障识别率的比较, 选取由粗到细的分层结构, 同时针对分类模式提取与分类联系紧密的输入参数, 对改善算法的诊断效果具有很大的积极作用。图 4 及图 5 诊断效果明显优于 SVM 和 FSVM 多分类离线诊断模型。

4 结论

变压器油中溶解气体分析是变压器故障诊断的

重要手段, 如何及时有效地发现变压器内部故障对于电力系统的安全运营有着重要作用。由于油中溶解气体种类多样, 且具有很强的分散性和模糊性, 因此在建立诊断模型时, 必须充分考虑到边缘样本对于模型稳定性的影响。本文提出的模糊支持向量机增量算法, 对于边缘数据的影响具有很大的抑制效果, 自适应优化算法使得在模糊支持向量机的参数选择上具有很强的灵活性, 邻近增量算法有效地避免了离线学习的不足, 使得诊断模型的建立更加精确。从最终的分层诊断结果来看, 此种由粗到细的诊断方法取得了较理想的效果。

参考文献

- [1] Naresh R, Veena Sharma, Manisha Vashisth. An integrated neural fuzzy approach for fault diagnosis of transformers[J]. IEEE Transactions on Power Delivery, 2008, 23 (4) .
- [2] Mohamed Ahamed Abdel Wahab. Artificial neural network-based prediction technique for transformer oil breakdown voltage[J]. Electric Power System Research, 2004, 71 (1): 73-84.
- [3] 熊浩, 李卫国, 畅广辉, 等. 模糊粗糙集理论在变压器故障诊断中的应用[J]. 中国电机工程学报, 2008, 28 (7): 141-147.
XIONG Hao, LI Wei-guo, CHANG Guang-hui, et al. Application of fuzzy rough set theory to power transformer faults diagnosis[J]. Proceedings of the CSEE, 2008, 28 (7): 141-147.
- [4] 梁小冰, 王耀荣, 黄萍, 等. 基于 DGA 的变压器故障诊断多专家信息融合策略[J]. 电力系统自动化, 2005, 29 (8): 80-84.
LIANG Xiao-bing, WANG Yao-rong, HUANG Ping, et al. Synthetic multi-expert in transformer fault diagnosis based on DGA[J]. Automation of Electric Power Systems, 2005, 29 (18): 80-84.
- [5] 陈伟根, 潘翀, 云玉新, 等. 基于小波网络及油中溶解气体分析的电力变压器故障诊断方法[J]. 中国电机工程学报, 2008, 28 (7): 121-126.
CHEN Wei-gen, PAN Chong, YUN Yu-xin, et al. Fault diagnosis method of power transformers based on wavelet networks and dissolved gas analysis[J]. Proceedings of the CSEE, 2008, 28 (7): 121-126.
- [6] 董明, 严璋, 杨莉, 等. 基于证据推理的电力变压器故障诊断策略[J]. 中国电机工程学报, 2006, 26 (1): 106-114.
DONG Ming, YAN Zhang, YANG Li, et al. An evidential reasoning approach to transformer fault diagnosis[J]. Proceedings of the CSEE, 2006, 26 (1): 106-114.

- [7] 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 Yun-bai, et al. Fault diagnosis for power transformer based on grey relation entropy[J]. Automation of Electric Power Systems, 2005, 29 (18): 76-79.
- [8] 王永强, 律方成, 李和明. 基于贝叶斯网络和有种溶解气体分析的变压器故障诊断方法[J]. 电工技术学报, 2004, 19 (12): 74-77.
WANG Yong-qiang, Lü Fang-cheng, LI He-ming. Fault diagnosis for power transformer based on BN and DGA[J]. Transactions of China Electrotechnicals, 2004, 19 (12): 74-77.
- [9] 李俭, 孙才新, 陈伟根, 等. 灰色聚类和模糊聚类集成诊断变压器内部故障的方法研究[J]. 电机工程学报, 2003, 23 (2): 112-115.
LI Jian, SUN Cai-xin, CHEN Wei-gen, 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.
- [10] Werner Feilhauer, Edmund Handschin. Interpretation of dissolved gas analysis using dempster-shafer's theory of evidence[C]. //9th International Conference on Probabilistic Methods Applied to Power Systems. Stockholm (Sweden) : 2006.
- [11] 董明, 孟源源, 徐长响, 等. 基于支持向量机和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]. 电机工程学报, 2003, 23 (7): 88-92.
DONG Ming, MENG Yuan-yuan, XU Chang-xiang, 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.
- [12] Tang Wenhui, Shintemirov Almas, Wu Q H. Transformer dissolved gas analysis using least square support vector machine and bootstrap[C]. //Proceeding of the 26th Chinese Control Conference. 2007.
- [13] Lin C F, Wang S D. Fuzzy support vector machines[J]. IEEE Trans Neural Networks, 2002, 13 (2): 464-471.
- [14] 张全明, 刘会金. 最小二乘支持向量机在电能质量扰动分类中的应用[J]. 中国电机工程学报, 2008, 28 (1): 106-110.
ZHANG Quan-ming, LIU Hui-jin. Application of LS-SVM in classification of power quality disturbance[J]. Proceedings of the CSEE, 2008, 28 (1): 106-110.
- [15] 张蕊, 郭瑞君, 李华, 等. 基于变压器故障分类的 DGA 特征提取[J]. 高电压技术, 2005, 31(4): 32-33.
ZHANG Rui, GUO Rui-jun, LI Hua, et al. Feature Selection of DGA data based on transformer fault classification[J]. High Voltage Engineering, 2005, 31(4): 32-33.
- [16] Inoue T, Abe S. Fuzzy support vector machines for pattern classification[C]. // Proceedings of International Joint Conference on Neural Networks. Washington DC: 2001: 1449-1454.

收稿日期: 2009-09-15; 修回日期: 2009-10-20

作者简介:

刘同杰 (1984-), 男, 博士, 研究方向为大电网故障诊断项目; E-mail: liutongjie1984@163.com

刘志刚 (1975-), 男, 教授, 博导, 研究方向为现代信号处理技术及其在电力系统中的应用。

(上接第 46 页 continued from page 46)

- [5] 丁伟, 袁家海, 胡兆光. 基于用户价格响应和满意度的峰谷分时电价决策模型[J]. 电力系统自动化, 2005, 29 (20) : 10-14.
DING Wei, YUAN Jia-hai, HU Zhao-guang. Time-of-use price decision model considering users reaction and satisfaction index[J]. Automation of Electric Power Systems, 2005, 29 (20) : 10-14.
- [6] 丁宁, 吴军基, 邹云. 基于 DSM 的峰谷时段划分及分时电价研究[J]. 电力系统自动化, 2001, 25(10): 9-12.
DING Ning, WU Jun-ji, ZOU Yun. Research of peak and valley time period partition approach and time-of-use price on DSM[J]. Automation of Electric Power Systems, 2001, 25 (10) : 9-12.
- [7] 唐捷, 任震, 高志华, 等. 峰谷分时电价的成本效益分析模型及其应用[J]. 电网技术, 2007, 31(6): 61-66.
TANG Jie, REN Zhen, GAO Zhi-hua, et al. Cost-benefit analysis model and its application of peak-valley time-of-use electricity price[J]. Power System Technology, 2007, 31 (6) : 61-66.

收稿日期: 2009-10-13; 修回日期: 2009-12-26

作者简介:

朱连波 (1960-), 男, 本科, 高级经济师, 主要从事电网线损管理工作;

孙松强 (1984-), 男, 硕士生, 主要研究方向为电力系统经济运行与控制; E-mail:sunysu888@163.com

常磊 (1964-), 女, 高级经济师, 主要从事电网经济管理。