

# 代价敏感相关向量机的研究及其在变压器故障诊断中的应用

尹金良<sup>1</sup>, 刘玲玲<sup>2</sup>

(1. 天津理工大学 自动化学院, 天津 300384; 2. 天津理工大学 工程训练中心, 天津 300384)

**摘要:** 实际中不同变压器故障类型的误分引发的危害程度往往不同, 仅追求正确率并不一定会带来符合实际意义的分类结果。针对此, 提出了代价敏感相关向量机(CS-RVM)。CS-RVM 以误分代价最小为目标, 按贝叶斯风险理论预测新样本类别。在用典型算例验证了 CS-RVM 具有代价敏感性的基础上, 尝试将其应用于变压器故障诊断。基于溶解气体分析(DGA)数据的变压器故障诊断实例分析表明, CS-RVM 全局诊断正确率略高于 BP 神经网络和支持向量机, 略低于多分类相关向量机(M-RVM), 但 CS-RVM 趋于提高误分代价高的故障类型的诊断正确率, 具有代价敏感性; CS-RVM 的诊断速度足以满足变压器故障诊断的工程要求。

**关键词:** 变压器; 代价敏感学习; 相关向量机; 误分类代价; 故障诊断

中图分类号: TM 41

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2014.05.017

## 0 引言

传统分类算法通常以全局分类正确率最高为目标, 默认各类误分代价相等<sup>[1-5]</sup>。而实际问题中, 误分代价通常存在差异, 不同类型的误分引发的危害程度往往不同<sup>[6]</sup>。如果将设备故障误诊为正常, 会延误故障处理, 并可能会导致故障进一步发展而危害设备及人身安全; 反之也需花费人力、物力处理该误报故障, 但相比前者损失代价较小。同样地, 将高危害故障误诊断为低危害故障要比相反情况的误诊代价更高。因此, 仅追求全局正确率已不足以满足诊断的实际要求, 需要考虑误分代价差异。

多分类相关向量机(M-RVM)可有效解决小样本、高维、非线性等复杂多分类问题, 更重要的是 M-RVM 可以以概率的形式输出分类结果<sup>[7-10]</sup>。而代价敏感学习是机器学习的一个新的研究领域, 它的主要特点是考虑误分类代价差异性, 以代价最小为目标, 趋于提高高误分代价类别的正确率, 具有代价敏感性。面向实际问题的代价敏感诊断已被看作是未来诊断领域的重要研究方向<sup>[11]</sup>。

鉴于此, 本文将代价敏感机制引入 M-RVM, 提出了基于贝叶斯风险理论的代价敏感相关向量机 CS-RVM(Cost-Sensitive Relevance Vector Machine), 并尝试将其应用于变压器故障诊断, 以克服现有变压器故障诊断方法未考虑误诊代价差异性的问题<sup>[12-19]</sup>。

## 1 CS-RVM

### 1.1 代价敏感学习

代价敏感学习算法的研究主要有 3 类: 直接构

造代价敏感分类模型; 按照传统方法学习分类模型, 然后按照贝叶斯风险理论对其结果进行调整, 以使损失代价最小; 基于传统的学习模型, 通过改变原始训练数据的分布来训练得到代价敏感分类模型。本文提出的 CS-RVM 属于第 2 类。

### 1.2 CS-RVM 原理

CS-RVM 首先按照传统方法学习 M-RVM 的分类模型, 然后按照贝叶斯风险理论对其结果进行调整, 以达到损失代价最小的目的。

设训练集  $\mathbf{X} = \{\mathbf{x}_i, c_i\}_{i=1}^N$ , 其中,  $\mathbf{x} \in \mathbf{R}^D$  ( $D$  为样本维数),  $c_i$  为类别标签,  $N$  为样本总数。CS-RVM 算法描述如下。

a. 以  $\mathbf{X}$  作为 M-RVM 输入, 采用快速 type-II 最大似然(Fast Type-II ML)和最大期望估计(EM)方法进行模型推断, 确定 M-RVM 模型<sup>[7-8]</sup>。

b. 以待测样本  $\mathbf{x}_*$  作为由步骤 a 得到的 M-RVM 模型的输入, 输出后验概率  $P(c_i|\mathbf{x}_*)$ 。

c. 按式(1)计算将待测样本  $\mathbf{x}_*$  预测为类别  $c_j$  的条件代价  $R(c_j|\mathbf{x}_*)$ 。

$$R(c_j|\mathbf{x}_*) = \sum_i c(i, j)P(c_i|\mathbf{x}_*) \quad (1)$$

其中,  $\mathbf{C}$  为代价矩阵, 用来描述误分类代价,  $\mathbf{C}$  中的元素  $c(i, j)$  表示将类别  $c_i$  误分为类别  $c_j$  的代价。

d. 根据贝叶斯风险理论, 按式(2)确定待测样本  $\mathbf{x}_*$  的类别  $c_{j^*}$ 。

$$R(c_j|\mathbf{x}_*) = \min_j R(c_j|\mathbf{x}_*) \quad (2)$$

### 1.3 CS-RVM 性能分析

分别采用 Ripley 给出的典型数据集 synthetic<sup>[20]</sup> 以及林智仁提供的典型数据集 breast cancer<sup>[21]</sup>, 对 CS-RVM 的性能进行分析。由于实际故障诊断中故障样本数据比较少, 因此只针对 CS-RVM 在学习

收稿日期: 2013-03-14; 修回日期: 2014-03-28

基金项目: 河北省自然科学基金资助项目(E2009001392)

Project supported by the Natural Science Foundation of Hebei Province(E2009001392)

小样本数据集情况下的分类性能进行分析。文中给出的结果都是在配置奔腾双核 CPU(E5200,核主频分别为 2.5 GHz、2.49 GHz)、内存为 2 GB 的联想台式机上运行得到的。

文中采用的误诊代价矩阵为:将负类误分为正类的代价为 1(简记为误报),将正类误分为负类的代价为 1.2(简记为漏诊),正确分类的代价为 0。漏诊代价高于误报,即期望尽量避免漏诊。

表 1 给出了 M-RVM 和 CS-RVM 方法在 100 次试验中的平均正判率、误报的平均样本数、漏诊的平均样本数以及平均测试时间的对比情况。

表 1 M-RVM 和 CS-RVM 的诊断性能对比  
Tab.1 Comparison of diagnostic performance between M-RVM and CS-RVM

数据集	训练样本数	方法	正判率/%	误报样本数	漏诊样本数	测试时间/s
synthetic	20	M-RVM	88.0730	62.23	52.33	0.1624
		CS-RVM	87.5274	74.20	45.60	0.1682
	30	M-RVM	88.2990	61.65	48.54	0.1637
		CS-RVM	87.8668	71.82	42.44	0.1693
	40	M-RVM	87.8668	71.82	42.44	0.1693
		CS-RVM	88.5001	56.55	49.61	0.1564
breast cancer	20	M-RVM	96.1147	12.79	12.24	0.0920
		CS-RVM	95.7205	19.63	7.94	0.0957
	30	M-RVM	96.4577	12.77	9.40	0.0808
		CS-RVM	96.2083	17.55	6.18	0.0844
	40	M-RVM	96.6714	12.32	7.91	0.0803
		CS-RVM	96.3457	16.52	5.69	0.0838

图 1 给出训练样本数据数为 30 时,100 次试验中 M-RVM 和 CS-RVM 方法在 synthetic 数据集上的漏诊样本数曲线图。

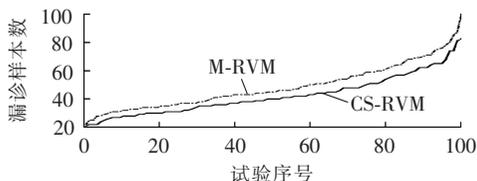


图 1 M-RVM 和 CS-RVM 方法的漏诊样本数量  
Fig.1 Amount of samples undiagnosed by M-RVM and CS-RVM

由表 1 以及图 1 分析可知,在训练样本集为小样本数据集的情况下,CS-RVM 方法在典型数据集上的全局正判率略低于未计及误诊代价差异的 M-RVM,但 CS-RVM 趋向于提高高误诊代价类别的正确率,同期望的分类结果相同。可见 CS-RVM 具有代价敏感性,2 种方法都具有较快的测试速度。

## 2 基于 CS-RVM 的变压器故障诊断方法

现有变压器故障诊断方法默认各类误诊代价相等,仅追求诊断正确率<sup>[12-19]</sup>。然而在实际变压器故障诊断中,将故障状态诊断为正常状态的代价高于将正常状态诊断为故障状态的代价,将高危故障诊断

为低危故障的代价高于将低危故障诊断为高危故障的代价。

因此,本文尝试将代价敏感学习引入变压器故障诊断,提出了基于 CS-RVM 的变压器故障诊断新方法,其实现的主要过程如下。

a. 选取可以反映变压器运行状态的离线或在线监测数据等,进行特征提取,确定特征变量,如变压器溶解气体含量、气体含量比值(三比值、四比值等)、产气率等。

b. 依据待解决问题的需要,划分变压器的故障类型,确定各种故障类型的表示方法。

c. 确定 M-RVM 输出的变压器处于各种故障状态的概率表达形式。

d. 选取变压器训练样本数据  $X$ 。为避免数据集偏斜问题,样本数据选取时各类数据所占比例应尽量相近。如果变压器故障数据很少,全部采用;如果样本数据差异大,为了减少计算误差,需对样本数据进行标准化处理。

e. 选取核函数。本文采用变压器故障诊断中通常采用的 RBF 核函数,如式(3)所示。

$$K(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right) \quad (3)$$

其中,  $\sigma$  为核函数的高宽参数,按  $1/D$  确定<sup>[8]</sup>。

f. 利用训练样本数据  $X$  进行 M-RVM 模型学习,确定 M-RVM 模型。

g. 输入待诊断的变压器样本数据  $\mathbf{x}_*$ , 得出后验概率  $P(c_i|\mathbf{x}_*)$ 。

h. 实际调研变压器各故障之间的误诊代价,确定代价矩阵  $C$ 。误诊代价需要领域专家综合领域知识给出。在实际问题中,各故障之间误诊代价的绝对数值很难准确给出,而误诊代价的根本目的是为了反映各故障之间的误诊带来的相对代价差异,因此只需要给出误诊的相对代价即可。确定的基本原则为:正确诊断代价为 0,误诊代价大于 0,且在最小误诊代价与最大误诊代价之间有足够的相对代价等级。

i. 按式(1)计算将待测变压器样本  $\mathbf{x}_*$  预测为故障类别  $c_j$  的条件代价  $R(c_j|\mathbf{x}_*)$ 。

j. 按式(2)确定待测样本  $\mathbf{x}_*$  的故障类别  $c_{j^*}$ 。

基于 CS-RVM 的变压器故障诊断方法的实现流程图如图 2 所示。

## 3 实例分析

以基于溶解气体分析(DGA)数据的变压器故障诊断实例说明 CS-RVM 在故障诊断中的应用,选用 489 组变压器 DGA 数据进行实例分析,其中部分数据为河北省衡水市和上海市供电公司提供的实测数据,其他为从文献中下载。其中正常样本数据 90

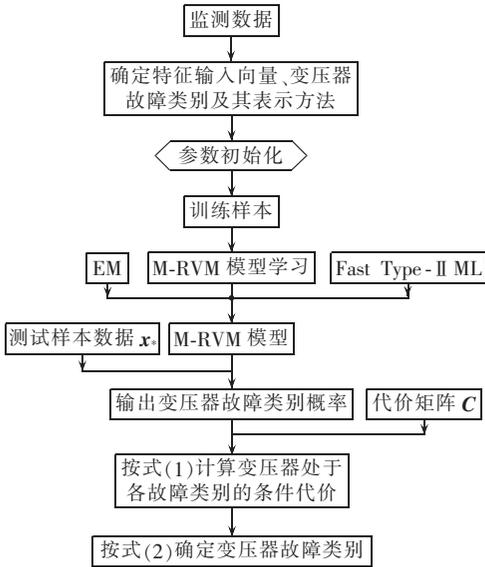


图 2 基于 CS-RVM 的变压器故障诊断方法

Fig.2 Transformer fault diagnosis based on CS-RVM

组,故障样本数据 399 组,选取变压器在各种状态下的样本数据各 25 组作为训练样本集,其余作为测试样本集。

分别采用 BP 神经网络(BPNN)、支持向量机(SVM)、M-RVM 和 CS-RVM 方法建立变压器故障诊断模型。BPNN 使用 MATLAB 自带的工具箱,SVM 选用台湾大学林智仁等开发的 Libsvm。BPNN 输入层神经元数为 5、隐层神经元数为 15、输出层神经元数为 6,隐层激励函数选用 tansig,输出层激励函数选用 purelin,训练函数选用 trainlm,权重学习函数选用 learnngdm,性能评价函数选用 mse;SVM 核函数选用 RBF,采用“一对一”的分类方法,应用网格搜索与 10 折交叉验证相结合的方法选取规则化系数和核函数参数。

特征输入变量选取 H<sub>2</sub> 占总气体含量的比值,记为 x<sub>1</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> 占总烃量的比值分别记为 x<sub>2</sub>、x<sub>3</sub>、x<sub>4</sub>、x<sub>5</sub>,输入向量为 [x<sub>1</sub> x<sub>2</sub> x<sub>3</sub> x<sub>4</sub> x<sub>5</sub>];变压器故障类型分为正常(N)、低能放电(D<sub>1</sub>)、高能放电(D<sub>2</sub>)、中低温过热(T<sub>12</sub>)、高温过热(T<sub>3</sub>)、局部放电(PD) 6 种状态。

M-RVM 和 CS-RVM 采用向量 [0 0 0 0 0 1]<sup>T</sup>、[0 0 0 0 1 0]<sup>T</sup>、[0 0 0 1 0 0]<sup>T</sup>、[0 0 1 0 0 0]<sup>T</sup>、[0 1 0 0 0 0]<sup>T</sup>、[1 0 0 0 0 0]<sup>T</sup> 表示变压器的 6 种状态。

CS-RVM 诊断方法采用的误诊代价矩阵如表 2 所示。由表 2 可知将故障状态误诊为正常状态的代价(漏诊)高于将正常状态误诊为故障状态(误报),即期望的诊断结果是尽量避免将故障状态漏诊为正常状态。

M-RVM 诊断方法的概率输出向量为 [p<sub>PD</sub> p<sub>T<sub>3</sub></sub> p<sub>T<sub>12</sub></sub> p<sub>D<sub>2</sub></sub> p<sub>D<sub>1</sub></sub> p<sub>N</sub>],其中 p<sub>PD</sub>、p<sub>T<sub>3</sub></sub>、p<sub>T<sub>12</sub></sub>、p<sub>D<sub>2</sub></sub>、p<sub>D<sub>1</sub></sub>、p<sub>N</sub> 分别代表变

表 2 变压器误诊代价敏感矩阵

Tab.2 Sensitivity matrix of transformer fault misdiagnosis cost

实际故障	诊断结果						
	PD	T <sub>3</sub>	T <sub>12</sub>	D <sub>2</sub>	D <sub>1</sub>	N	
PD	0	1	1	1	1	1	1.5
T <sub>3</sub>	1	0	1	1	1	1	1.5
T <sub>12</sub>	1	1	0	1	1	1	1.5
D <sub>2</sub>	1	1	1	0	1	1	1.5
D <sub>1</sub>	1	1	1	1	0	1	1.5
N	1	1	1	1	1	1	0

器的状态为 PD、T<sub>3</sub>、T<sub>12</sub>、D<sub>2</sub>、D<sub>1</sub>、N 的概率,概率值最大的状态为 M-RVM 的诊断结果。

CS-RVM 输出的条件代价向量为 [r<sub>PD</sub> r<sub>T<sub>3</sub></sub> r<sub>T<sub>12</sub></sub> r<sub>D<sub>2</sub></sub> r<sub>D<sub>1</sub></sub> r<sub>N</sub>],其中 r<sub>PD</sub>、r<sub>T<sub>3</sub></sub>、r<sub>T<sub>12</sub></sub>、r<sub>D<sub>2</sub></sub>、r<sub>D<sub>1</sub></sub>、r<sub>N</sub> 分别代表变压器的状态为 PD、T<sub>3</sub>、T<sub>12</sub>、D<sub>2</sub>、D<sub>1</sub>、N 的条件代价,条件代价最小的状态为 CS-RVM 的诊断结果。

表 3 给出了 5 组基于 M-RVM 和 CS-RVM 方法的变压器故障诊断典型实例。

表 3 基于 M-RVM 和 CS-RVM 方法的变压器故障诊断典型实例

Tab.3 Typical cases of diagnosis based on M-RVM and CS-RVM

实际故障	气体含量比值					诊断结果	
	x <sub>1</sub>	x <sub>2</sub>	x <sub>3</sub>	x <sub>4</sub>	x <sub>5</sub>	M-RVM	CS-RVM
D <sub>1</sub>	0.6214	0.2342	0.0650	0.6085	0.0923	N	D <sub>1</sub>
D <sub>2</sub>	0.8732	0.1134	0.6739	0.0767	0.1359	N	D <sub>2</sub>
T <sub>12</sub>	0.1112	0.2128	0.7447	0.0426	0	N	T <sub>12</sub>
T <sub>3</sub>	0.2098	0.1439	0.3507	0.3665	0.1389	N	T <sub>3</sub>
D <sub>1</sub>	0.6553	0.2465	0.2606	0.3028	0.1901	N	PD

表 4 给出了 BPNN、SVM、M-RVM 和 CS-RVM 方法在 100 次随机试验中的平均正判率、将正常状态误诊为故障(误报)的平均样本数,将故障误诊为正常状态(漏报)的平均样本数、平均训练时间以及平均诊断时间的对比情况。

表 4 BPNN、SVM、M-RVM 和 CS-RVM 的变压器故障诊断性能对比

Tab.4 Comparison of transformer fault diagnostic performance among BPNN,SVM, M-RVM and CS-RVM

方法	正判率/%	误报样本数	漏诊样本数	训练时间/s	诊断时间/s
BPNN	85.4897	5.35	20.11	0.4507	0.0095
SVM	86.5900	4.47	14.33	0.0021	0.0640
M-RVM	89.2183	2.64	13.64	41.3895	0.0824
CS-RVM	88.5841	7.32	4.47	41.3982	0.0869

图 3 为 100 次随机试验中 BPNN、SVM、M-RVM 和 CS-RVM 方法的诊断正确率曲线图。

图 4 为 100 次随机试验中 BPNN、SVM、M-RVM 和 CS-RVM 方法将变压器故障状态漏诊为正常状态的样本数曲线图。

由表 4 可知,与 BPNN、SVM 方法相比,CS-RVM 模型训练时间相对较长,但 100 次随机试验中,最长

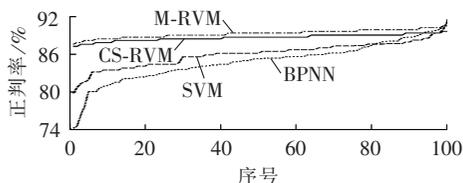


图3 BPNN、SVM、M-RVM 和 CS-RVM 方法的变压器故障诊断正确率曲线图

Fig.3 Correctness curves of transformer fault diagnosis for BPNN, SVM, M-RVM and CS-RVM

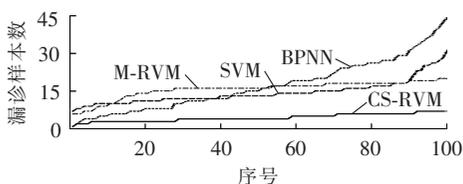


图4 BPNN、SVM、M-RVM 和 CS-RVM 方法变压器漏诊样本数量

Fig.4 Amount of samples undiagnosed by BPNN, SVM, M-RVM and CS-RVM

训练时间也仅为 105.2628 s;BPNN、SVM、M-RVM 和 CS-RVM 都具有较快的测试速度,并且 100 次随机试验中,CS-RVM 最长测试时间仅为 0.1222 s。天威新城 OLM600 油色谱在线监测单元最小检测周期为 1 h,可见 CS-RVM 诊断速度足以满足工程需求。

由表 4 和图 3、4 分析可知,与 BPNN、SVM 方法相比,CS-RVM 诊断正确率略高,误报代价低的误报样本数相对较多,但误诊代价较高的漏诊样本数相对较少。

由表 3、4 及图 3、4 分析可知,同未计及变压器误诊代价差异的 M-RVM 相比,CS-RVM 诊断正确率略有下降,代价低的误报样本数有所增多,但误诊代价较高的漏诊样本数有所减少。由此可见 CS-RVM 诊断趋向于提高误诊代价高的类别的正确率,具有代价敏感性。

## 4 结论

**a.** 针对传统分类算法通常忽略误分类代价差异,而实际问题中误诊代价通常不等的问题,提出了基于贝叶斯风险理论的 CS-RVM。该方法考虑了误分类的代价差异,用误分代价最小取代误分率最小为目标,克服了仅追求分类精度并不一定带来符合实际意义的分类结果的问题。

**b.** 用典型算例对 CS-RVM 性能进行了分析,验证了 CS-RVM 具有代价敏感性,并将其应用于变压器故障诊断,克服了现有变压器故障诊断方法未考虑误诊代价差异的问题。

**c.** 基于 DGA 数据的变压器故障诊断实例分析表明,CS-RVM 全局诊断正确率略高于 BPNN 和 SVM,略低于 M-RVM,但 CS-RVM 趋于提高高误诊代价类别的诊断正确率,具有代价敏感性,且 CS-RVM

诊断速度足以满足变压器故障诊断的工程需求。

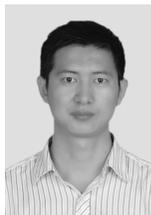
本文尝试将代价敏感机制引入变压器故障诊断,而变压器误诊代价敏感矩阵的确定需要领域专家综合领域知识以及反复的试验。综合考虑不同程度的故障之间误诊代价、不同故障性质之间的误诊代价进行变压器故障诊断有待进一步的研究。

## 参考文献:

- [1] BISHOP C M. Pattern recognition and machine learning [M]. Singapore:Springer,2006.
- [2] 孙即祥. 现代模式识别[M]. 北京:高等教育出版社,2008:454-494.
- [3] DEMIR B,ERTURK S. Hyperspectral image classification using relevance vector machines[J]. IEEE Geoscience and Remote Sensing Letters,2007,4(4):586-590.
- [4] GHOLAMI B,HADDAD W M,TANNENBAUM A R. Relevance vector machine learning for neonate pain intensity assessment using digital imaging[J]. IEEE Transactions on Biomedical Engineering,2010,57(6):1457-1466.
- [5] TIPPING M E. Sparse Bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research,2001,1:211-244.
- [6] RASMUSSEN C E,WILLIAMS C K I. Gaussian processes for machine learning[M]. London,UK:The MIT Press,2006:1-6.
- [7] DAMOULAS T,YING Y,GIROLAMI M A,et al. Inferring sparse kernel combinations and relevance vectors:an application to subcellular localization of proteins[C]//Proceedings of the 7th International Conference on Machine Learning and Applications (ICMLA2008). San Diego,USA:[s.n.],2008:577-582.
- [8] PSORAKIS I,DAMOULAS T,GIROLAMI M A. Multiclass relevance vector machines:sparsity and accuracy[J]. IEEE Transactions on Neural Networks,2010,21(10):1588-1598.
- [9] DAMOULAS T,GIROLAMI M A. Probabilistic multi-class multi-kernel learning:on protein fold recognition and remote homology detection[J]. Bioinformatics,2008,24(10):1264-1270.
- [10] DAMOULAS T,GIROLAMI M. A. Combining feature spaces for classification[J]. Pattern Recognition,2009,42(11):2671-2683.
- [11] SAITTA L. Machine learning:a technological roadmap[R]. Amsterdam,The Netherlands:University of Amsterdam,2000.
- [12] 赵文清,朱永利,张小奇. 应用支持向量机的变压器故障组合预测[J]. 中国电机工程学报,2008,28(25):14-19.  
ZHAO Wenqing,ZHU Yongli,ZHANG Xiaoqi. Combinational forecast for transformer faults based on support vector machine [J]. Proceedings of the CSEE,2008,28(25):14-19.
- [13] 赵文清. 基于选择性贝叶斯分类器的变压器故障诊断[J]. 电力自动化设备,2011,31(2):44-47.  
ZHAO Wenqing. Transformer fault diagnosis based on selective Bayes classifier[J]. Electric Power Automation Equipment,2011,31(2):44-47.
- [14] 李中,苑津莎,张利伟. 基于自组织抗体网络的电力变压器故障诊断[J]. 电工技术学报,2010,25(10):200-206.  
LI Zhong,YUAN Jinsha,ZHANG Liwei. Fault diagnosis for power transformer based on the self-organization antibody net [J]. Transactions of China Electrotechnical Society,2010,25(10):200-206.
- [15] 刘卫华,廖瑞金,杨丽君. 基于点密度加权核模糊聚类的变压器故障诊断方法[J]. 电力自动化设备,2012,32(6):66-69,79.

- LIU Weihua, LIAO Ruijin, YANG Lijun. Modeling and dynamic simulation of nuclear power plant secondary loop[J]. Electric Power Automation Equipment, 2012, 32(6): 66-69, 79.
- [16] 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.
- [17] TANG W H, WU Q H. Condition monitoring and assessment of power transformers using computational intelligence[M]. New York, USA: Springer-Verlag Press, 2011: 95-104.
- [18] SHENG Weifei, XIAO Binzhang. Fault diagnosis of power transformer based on support vector machine with genetic algorithm[J]. Expert Systems with Applications, 2009, 36(8): 11352-11357.
- [19] 郑元兵, 陈伟根, 李剑, 等. 基于 BIC 与 SVRM 的变压器油中气体预测模型[J]. 电力自动化设备, 2011, 31(9): 46-49.
- ZHENG Yuanbing, CHEN Weigen, LI Jian, et al. Forecasting model based on BIC and SVRM for dissolved gas in transformer oil[J]. Electric Power Automation Equipment, 2011, 31(9): 46-49.
- [20] BISHOP C M, TIPPING M E. Variational relevance vector machines[C]//Proceedings of the 16th Conference on Uncertainty in Artificial Intelligence. Burlington, Massachusetts, USA: Morgan Kaufmann, 2000: 46-53.
- [21] FAN Rong'en. LIBSVM data: classification, regression, and multi-label [EB/OL]. [2013-03-26]. <http://www.csie.ntu.edu.tw/~cjlin/libsvmtools/datasets/>.
- [22] SUKHBIR S, BANDYOPADHYAY M N. Dissolved gas analysis technique for incipient fault diagnosis in power transformers: a bibliographic survey[J]. Electrical Insulation Magazine, 2010, 26(6): 41-46.
- [23] NARESH R, SHARMA V, VASHISTH M. An integrated neural fuzzy approach for fault diagnosis of transformers[J]. IEEE Transactions on Power Delivery, 2008, 23(4): 2017-2024.
- [24] DUVAL M. A review of faults detectable by gas-in-oil analysis in transformers[J]. Electrical Insulation Magazine, 2002, 18(3): 8-17.

#### 作者简介:



尹金良(1982-),男,山东烟台人,讲师,博士,通讯作者,研究方向为人工智能在电力系统中的应用和电力系统运行、分析与控制(E-mail: yinjinliang2007@126.com)。

## CS-RVM and its application in fault diagnosis of power transformers

YIN Jinliang<sup>1</sup>, LIU Lingling<sup>2</sup>

(1. School of Automation Engineering, Tianjin University of Technology, Tianjin 300384, China;

2. Engineering Training Center, Tianjin University of Technology, Tianjin 300384, China)

**Abstract:** Since different severities of damage may be induced by misclassification of transformer faults, the classification correctness alone may not be practically meaningful, for which, the CS-RVM (Cost-Sensitive Relevance Vector Machine) is proposed. It takes the minimum misclassification cost as its objective and applies Bayesian risk theory to predict the class of new sample. A typical case is studied to verify its cost sensitivity, based on which, it is adopted to the transformer fault diagnosis. The transformer fault diagnosis based on DGA (Dissolved Gas Analysis) shows that, the global diagnosis correctness of CS-RVM is slightly higher than that of BPNN (BP Neural Network) or SVM (Support Vector Machine) and slightly lower than that of M-RVM, while the diagnosis correctness of CS-RVM for the fault class with higher misdiagnosis cost is higher, showing its cost sensitivity. The diagnosis speed of CS-RVM meets the requirement of projects for transformer fault diagnosis.

**Key words:** power transformers; cost-sensitive learning; relevance vector machine; misclassification cost; fault diagnosis