

一种电气设备状态诊断方法

马 刚¹, 吴克河², 李 艺²

(1. 南京师范大学电气与自动化工程学院, 江苏 南京 210042)

(2. 华北电力大学控制与计算机工程学院, 北京 102206)

[摘要] 随着电网技术的不断发展和电网规模不断扩大, 电气设备数量激增、智能化程度越来越高; 同时, 终端用户对用电可靠性越来越重视, 借助智能技术基于设备运行数据对设备进行故障诊断势在必行。本文以基于范例推理的理论(CRB)与支持向量机技术(SVM)为主要工具, 提出了一种基于范例推理的电气设备状态智能诊断模型, 试图通过电气设备已有数据的挖掘, 获取电气设备故障的潜在发生规律, 进而作为依据及时发现并排除电气设备的潜伏性故障。首先研究CRB和SVM在电气设备状态诊断中的应用; 然后建立电气设备状态智能诊断模型, 以电气设备的海量运行数据、历史数据、测试数据以及环境因素等为基础, 建立电气设备的状态范例库, 应用SVM回归对设备状态范例库进行深度的挖掘与分析, 建立设备状态指纹, 并以此为据进行电气设备运行状态的诊断分析; 最后以油浸式变压器状态诊断为例, 对实际数据进行分析诊断, 并与三比值法的诊断结果进行比较。诊断结果表明, 智能诊断模型诊断范围更广, 诊断结果更准确。

[关键词] 电气设备状态诊断, 范例推理, SVM 回归分析, 核函数, 状态指纹

[中图分类号] TM407 **[文献标志码]** A **[文章编号]** 1672-1292(2014)03-0007-08

An Intelligent Fault Diagnosis Model of Power Equipment

Ma Gang¹, Wu Kehe², Li Yi²

(1. School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210042, China)

(2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: With the rapid development of power system technology and increasing expansion of the grid size, the number of electrical equipment surges and the degree of intelligentization becomes higher and higher; meanwhile, the consumers pay more and more attention to the reliability of power utilization, and thus it is imperative that equipment running data-based fault diagnosis is made on equipment with the help of intelligent technology. An intelligent fault diagnosis model of transmission and transformation equipment based on CRB and SVM is proposed in this paper. The model tries to find the potential rules of equipment fault by digging the existing data. The intelligent model sets up condition case base of equipment based on online recording data, history data, basic test data and environmental data. SVM regression analysis is used to mine the case base so that the equipment condition fingerprint is established. The running data of equipment can be diagnosed by the condition fingerprint to determine whether there is a fault. At last, we diagnose a set of practical data with the intelligent model and three-ratio method. The result shows that intelligent model is more effective and accurate.

Key words: diagnosis of power equipment, case-based reasoning, SVM regression analysis, kernel function, condition fingerprint

智能电网的发展给电力工业的发展带来了机遇的同时也带来了挑战: 电网规模不断壮大、大量智能化电气设备不断应用到电网中; 同时, 电力市场化要求电力企业在保证用户用电质量的前提下降低企业的生产成本, 以增强企业竞争力。我国“九五”期间发生的电网稳定及大面积停电事故中有3起的直接原因是电气设备自身故障, 占事故总次数的23.1%, 且电气设备自身故障造成的事故呈上升趋势^[1]。及时发现电气设备潜在的故障隐患, 是保证电气设备安全工作、减少电力系统故障、提高电力系统可靠性的重要环节^[2,3]。

收稿日期: 2014-05-21。

基金项目: 江苏省自然科学基金(BK20141452)、江苏省高校自然科学研究项目(14KJB470006)、南京师范大学高层次人才科研启动研究项目(2014111XGQ0078)。

通讯联系人: 马刚, 博士, 讲师, 研究方向: 电力系统自动化, 人工智能及应用. E-mail: nnumg@njnu.edu.cn

电气设备的状态诊断以设备的实际健康状态为依据,具有极强的针对性和时效性,能够以最小的维护资源保障电力系统的安全稳定运行,可以显著降低电力企业的生产维护成本,改善电力服务质量和企业经济效益,已引起国内外电力工作者的普遍关注和高度重视^[4,5]. 电气设备状态检修对设备的实时监测信息和设备信息、测试数据等综合分析,评估设备的健康状态,根据实际的诊断结果决定设备是否需要检修维护. 运行状态良好的设备延长其检修期限,确保设备在最佳运行状态下长时间稳定运行;存在故障隐患的设备即时检修,及时消除故障隐患^[6-8].

电气设备状态诊断与设备实时运行数据、环境数据以及设备历史运行数据等紧密相关,并且不同相或者同型号设备的运行状态可以作为设备诊断的辅助依据. 电气设备状态诊断需要大量的数据作支撑,而近年来大量智能化设备的广泛应用以及电力信息化建设的深入为电气设备状态诊断创造了有利条件^[9]. 本文基于 CRB 和 SVM, 提出一种满足智能电网新需求的电气设备状态诊断模型,设计了相关的算法,并通过实例数据比较验证模型的有效性和准确性,具有重要的现实意义与实践价值.

1 基于范例推理的理论及应用研究

1.1 基于范例的推理

CRB 是人工智能领域一种重要的学习方法,其主要思想是利用过去的经验解决当前遇到的相似问题^[10-12],并通过已解决问题的经验来学习,不断提升解决问题的能力. 特别是在类似电气设备诊断等领域,没有适合的算法和模型可以被借鉴使用,范例推理系统可利用范例库的知识和经验解决问题^[13-16].

其原理如图 1 所示. 当一组电气设备的状态数据被作为目标范例(黑方格)输入时,基推理系统首先在问题空间检索与之“类似的”源范例(空白方格),并取出该范例对其问题的解答;然后在解答空间中直接适用或改编该解答到适用于该组状态数据的诊断(黑圆点).

由范例求解的原理可知,求解的关键点是:(1)如何在问题空间检索出与目标范例“类似”的源范例;(2)如何在解答空间中改编该解答到适用于新问题. 由此,本文将 SVM 回归分析引入到 CRB 中,解决上述关键问题.

1.2 SVM 回归分析

回归分析是确定 2 种或 2 种以上变数间相互依赖的定量关系的一种统计分析方法^[17,18]. 根据 CRB 理论,对电气设备的状态诊断,就是基于设备的历史运行数据样本集寻求一个反映设备运行数据与设备状态的最优函数关系 $y=f(X)$,本质上就是对设备的实时状态数据依据函数关系 $y=f(X)$ 进行分类^[19].

设 $x_i \in RD$ 为电气设备状态样本数据,总共分为 2 类,用 +1 和 -1 来表示类别,即 $y_i \in \{+1, -1\}$ ($i=1, \dots, n$) 为相应数据样本的类别编号, n 为样本数. 在线性可分情况下线性可分函数的一般形式为:

$$g(x) = \omega x + b, \quad (1)$$

其中, $\omega \in \mathbf{R}^n$, ω 是 n 维向量, b 为偏移量.

SVM 回归问题就是利用 $g(x) = \omega x + b$ 拟合数据 (x_i, y_i) , 其中 $i=1, 2, \dots, k, x_i \in \mathbf{R}^n, y_i \in \mathbf{R}$. 引入松弛变量 ξ_i 和惩罚因子 C 后, 基于 ε 不敏感误差函数^[20], 寻求最优回归超平面问题就转化为凸约束条件下的二次凸规划问题:

$$\begin{aligned} \min_{\omega, \xi} J(\omega, \xi) &= \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^k \xi_i, \\ \text{s. t. } &|y_i - \omega x_i - b| \leq \varepsilon + \xi_i, \\ &\varepsilon, \xi_i \geq 0, i=1, 2, \dots, k, C > 0, \end{aligned} \quad (2)$$

其中,

$$\xi_i = \begin{cases} 0 & |y_i - g(x_i)| \leq \varepsilon, \\ ||y_i - g(x_i)|| - \varepsilon & |y_i - g(x_i)| > \varepsilon. \end{cases} \quad (3)$$




图 1 基于范例求解

Fig. 1 Solving based on cases

C 为事先给定的惩罚系数,一般由试验确定,当所有离群点的松弛变量的和一定时,惩罚因子 C 越大,对目标函数的损失也越大.

对于这个二次凸规划问题,引入 Lagrange 函数^[21],从而得到最优回归超平面为:

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) (x_i \cdot x) + b. \quad (4)$$

电气设备的状态诊断为非线性回归问题,SVM 的基本思想是引入核函数 Θ 将原数据空间的非线性问题转化为高维特征空间的线性问题,即将 x_i 替换为 $\Theta(x_i)$,即

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) (\Theta(x_i) \cdot \Theta(x)) + b.$$

根据核函数定义 $K(x, x_i) = \Theta(x) \cdot \Theta(x_i)$,整理后得 SVM 非线性回归函数为:

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) K(x, x_i) + b. \quad (5)$$

1.3 核函数构造

核函数的确定并不困难,满足 Mercer 定理的函数都可以作为核函数. 常用核函数有多项式核函数、径向基核函数等 4 类. 针对电气设备故障诊断的特点,本文基于常见的核函数构造兼顾核函数的全局性与局部性的函数^[22].

径向基核函数是对局部数据敏感的核函数的典型代表,多项式核函数对全局数据的泛化能力较强. 本文以上述 2 种核函数为基础,构造新的核函数:

$$\hat{K}(x, y) = \alpha \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) + \beta(\langle x, y \rangle + d)^n \quad (\alpha, \beta \geq 0, \alpha+\beta=1). \quad (6)$$

其中, α 和 β 是调节径向基核函数与多项式核函数对复合核函数影响的系数,通过对 α 和 β 的调节可以使复合核函数对不同的数据分布保持较好的拟合能力和泛化能力. 设置参数 $y=0.1, \sigma=0.5, d=1, n=1, \beta=0.1, 0.3, 0.5, 0.7, 0.9$, 核函数的特性如图 2 所示. 根据核函数特性曲线可以看出,复合核函数兼具径向基核函数和多项式核函数特性,具有较好的拟合能力和泛化能力. 通过对 α 和 β 的调节,可以使复合核函数适应不同的数据分布.

将构造的核函数代入式(5)中,整理后得 SVM 非线性回归函数为:

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) \left(\alpha \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) + \beta(\langle x, y \rangle + d)^n \right) + b. \quad (7)$$

其中, α, α^* 为 Lagrange 乘子, $\alpha, \beta \geq 0, \alpha+\beta=1$.

2 电气设备状态智能诊断模型

2.1 数据模型

电气设备状态诊断基于大量数据,需要建立统一的数据模型;统一的数据模型是基于范例推理进行诊断的基础,可以实现电气设备状态信息共享,满足对电气设备进行宏观状态分析诊断的需求^[23].

定义 1 电气设备信息模型为 $E = \{B, F, G, P, M\}$:

$B = \{b_1, b_2, b_3, \dots, b_n\}$, 表征电气设备的通用固有属性,如设备的名称、型号、出厂编号、制造厂家等.

$F = (f_1, f_2, f_3, \dots, f_n)$ 为由设备特征量组成的向量.

G 为表征设备特征量之间的关系的集合,如电压(U)=电流(I) \times 电阻(R),则可表示为 $g(U, I \times R)$.

$P = (\langle f_1, d_1 \rangle, \langle f_2, d_2 \rangle, \dots, \langle f_n, d_n \rangle)$,是由设备特征量及其额定值组成的有序数据对的集合.

$M = (m_1, m_2, \dots, m_n)$,为由环境因素组成的集合.




图 2 诊断模型核函数特性图

Fig. 2 Feature figure of diagnostic kernel function

电气设备的运行数据是按时间点采集存储的,与采集时刻 t 密切相关,以某个信号监测点 A 的监测值为 Y 轴,以时间为 t 轴,构造设备监测点 A 的抽象空间数据模型. 在时刻 t_i 沿 y 对数据进行切片,则可得到在 t_i 时刻设备的监测点数据样本 $K = (t_i, y_i)$.

由上文中设备信息模型与设备运行数据的抽象空间数据模型,本文定义电气设备状态范例.

定义 2 电气设备状态范例 $C = \langle K_t, E_M, \varphi \rangle$:

K_t 表示 t 时刻电气设备的监测点数据样本;

E_M 为时间戳 t 下各环境因素的状态值;

φ 为设备在 t 时刻,在 E_M 表征的环境中,各特征变量值为 K_t 时的状态. 一般情况, φ 是常数,是设定设备状态分类的阈值标准,是范例训练的重要依据;待检范例中 φ 不能确定,表示为 null,在推理后确定 φ 的值.

2.2 电气设备状态指纹

假设电气设备状态范例库为 T ,其中设备状态共分为 $\{A, B, C, D, E\}$ 5 类,按照状态范例的状态类型进行分类,建立 5 个子范例库,分别为 T_A, T_B, T_C, T_D 和 T_E . 根据式(7) SVM 非线性回归函数,对范例进行学习训练,建立状态指纹识别器 $f(x)$.

令: T_A, T_B, T_C, T_D, T_E 的状态指纹识别器 $f(x)$ 的训练目标分别为 $\Phi(A), \Phi(B), \Phi(C), \Phi(D), \Phi(E)$. 通过对样本范例集的学习训练建立状态指纹识别器,令:

$$\begin{aligned} f(C_i) &= \Phi(A), (C_i \in T_A); \\ f(C_i) &= \Phi(B), (C_i \in T_B); \\ f(C_i) &= \Phi(C), (C_i \in T_C); \\ f(C_i) &= \Phi(D), (C_i \in T_D); \\ f(C_i) &= \Phi(E), (C_i \in T_E). \end{aligned} \quad (8)$$

通过训练得到 $\hat{f}(x), \hat{f}(x)$ 可将 5 类状态的范例样本子集映射到不同的数据区间上,如图 3 所示.

本文定义 $(\hat{f}(x), (\Phi(X) - \delta, \Phi(X) + \delta))$ 为电气设备状态类型 X 的状态指纹,称 $\hat{f}(x)$ 为设备状态 X 指纹识别器, $(\Phi(X) - \delta, \Phi(X) + \delta)$ 为状态指纹标识, $\Phi(X)$ 为指纹标识值, δ 为容忍误差. 电气设备状态指纹如表 1 所示.

表 1 设备状态指纹

Table 1 Device status fingerprint

序号	设备状态指纹识别器	指纹标识	设备状态
1		$(\Phi(A) - \delta, \Phi(A) + \delta)$	A 类
2		$(\Phi(B) - \delta, \Phi(B) + \delta)$	B 类
3		$(\Phi(C) - \delta, \Phi(C) + \delta)$	C 类
4		$(\Phi(D) - \delta, \Phi(D) + \delta)$	D 类
5		$(\Phi(E) - \delta, \Phi(E) + \delta)$	E 类




图 3 范例样本的分类映射

Fig. 3 Classification mapping of cases

2.3 诊断模型

基于范例推理的电气设备状态智能诊断模型基于设备状态范例库,通过对范例的训练学习,形成设备状态指纹,并以此为据,对电气设备健康状态进行判定. 模型包含训练和诊断 2 个阶段. 在训练阶段,建立设备状态范例库,并利用 SVM 非线性回归函数进行训练学习,形成设备状态指纹;在诊断阶段,应用设备状态指纹识别器,诊断设备的状态. 电气设备状态智能诊断范例训练模型如图 4 所示.

由图 4 可知,电气设备状态智能诊断模型的基础是设备状态范例建模. 设备的基础数据、设备历史运行数据以及设备标定数据等,按电气设备数据模型进行设备范例建模,生成设备的状态范例库;然后使用 SVM 对状态范例集进行学习,训练设备状态指纹识别器,形成设备状态指纹. 至此,模型的训练完成.

在诊断阶段,设备的监测数据经过设备范例建模,形成待测样本;再使用设备状态指纹识别器进行指纹识别,形成待测样本的待测状态指纹;接下来进行指纹的比对,与待测状态指纹拟合度最高的标识指纹,即为其状态类型,得出诊断结果;模型给出诊断结果后,可对诊断结果进行评估,从而优化指纹识别器,同时完善待测设备状态范例并存入范例库,完善设备状态指纹,如图 5 所示.




图 4 模型训练

Fig. 4 Model training




图 5 模型诊断

Fig. 5 Model diagnostic

3 实证分析

电气设备种类繁多,本文以变压器状态诊断为例,验证电气设备状态智能诊断模型。本文用 Matlab 语言编制了相应程序,对油浸式电力变压器的状态数据进行分析诊断,并与应用三比值法进行诊断的结果进行比较,验证模型的正确性和有效性。

3.1 变压器状态分类

为了平衡分类的复杂性和诊断精度,避免范例的欠学习或过学习现象的出现,设计合理的设备状态分类模型是十分重要的。在分析变压器故障特点的基础上,根据变压器绝缘油中溶解气体分析结果所提供的有效信息^[24],将变压器状态类型分为 6 类^[25],如表 2 所示。

以某电力公司额定电压为 220 kV 的油浸式变压器作为研究对象,通过接入 PMS 系统和油色谱在线监测系统,收集 2 149 条变压器油中气体浓度的完整数据,并加入温度、湿度等环境数据,对数据进行规约整理后,去掉冗余与重复的噪声数据,共得到 1 978 条可用数据。其中,1 521 条为变压器正常运行数据,457 条为故障数据,以此作为实验研究的数据基础,数据状态分类分布如表 3 所示。

表 2 变压器状态分类

Table 2 Classification of transformer status

序号	状态类型	代码
1	正常	S ₁
2	低能放电	S ₂
3	高能放电	S ₃
4	局部放电	S ₄
5	中低温过热	S ₅
6	高温过热	S ₆

表 3 数据分布

Table 3 Distribution of data

序号	状态类型	数据条数
1	正常	1 521
2	低能放电	54
3	高能放电	98
4	局部放电	101
5	中低温过热	81
6	高温过热	123
	总计	1 978

3.2 学习阶段

根据实验数据建立设备状态范例库 T ,正常状态范例子集为 T_1 ,低能放电故障范例子集为 T_2 ,高能放电故障范例子集为 T_3 ,局部放电故障范例子集为 T_4 ,中低温过热故障范例子集为 T_5 ,高温过热故障范例子集为 T_6 。

电气设备状态诊断模型的关键是状态指纹的生成及优化,本文采用变量轮换法进行^[25],各参数的取值情况如表 4 所示。

表 4 变量轮换法取值

Table 4 Cyclic variable method

取值	参数				
	σ	d	n	e	C
取值范围	0.2 ~ 30	0.5 ~ 50	0.005 ~ 1	0.005 ~ 2	0.5 ~ 300
初始值	0.2	0.5	0.005	0.005	0.5
循环步长	0.2	0.5	0.005	0.005	0.5
最优值	7.6	5	0.66	1.455	146

通过变量轮换法,最终得到当状态分类器参数为:核函数参数 $\sigma=7.6,d=5,n=0.66,e=1.455,C=146$ 时,对正常和故障数据的分类效果最好.

对收集到的 1 978 条数据应用 Matlab 程序进行多次的训练优化,得到设备状态指纹如表 5 所示.

3.3 结果分析

为了保证模型的准确性与合理性,在模型训练时,样本数据以 5:1 的比例随机分为两部分,将其中 5/6 的数据作为模型训练使用,1/6 的数据作为测试诊断使用. 其中测试分类正确率最高的为 95.19%, 最低的为 75%, 平均为 82.19%, 如表 6 所示.

表 6 实验数据测试结果

Table 6 Test results of the experimental cases

序号	训练数据	测试数据	测试正确条数	正确率/%	状态
1	1 268	253	239	94.47	正常
2	45	9	6	66.67	低能放电
3	82	16	12	75	高能放电
4	85	16	13	81.25	局部放电
5	68	13	11	84.62	中低温过热
6	103	20	17	85	高温过热
平均				81.17	

表 7 中为 5 条待测数据应用三比值法与诊断模型诊断后的结果. 应用三比值法得不到诊断结果或者出现误判^[26], 而用电气设备状态智能诊断模型进行诊断, 诊断结果均与实际情况相符. 这表明, 诊断模型具有较高的有效性与准确性.

表 7 实例数据诊断结果比较

Table 7 Comparison of diagnosis results

字段	数据 1	数据 2	数据 3	数据 4	数据 5
H ₂	36	1 651	97	42	132.9
CH ₄	30	90	405	62	20.38
C ₂ H ₆	10	33	590	5	8.09
C ₂ H ₄	93	45	583	63	0.63
C ₂ H ₂	7.1	2	34	73	0.16
TOTLE	140.1	170	1612	203	29.26
C ₂ H ₂ /C ₂ H ₄	0.076 3	0.044 4	0.058 3	1.158 7	0.253 9
C ₂ H ₄ /H ₂	2.583 3	0.027 2	6.010 33	1.5	0.004 7
C ₂ H ₄ /C ₂ H ₆	9.3	1.363 6	0.988 1	12.6	0.077 9
三比值法编码组合	0 2 2	0 1 2	0 1 1	1 2 2	1 1 0
三比值法故障判断	高温过热	高温过热	无对应编码	低能放电兼过热	低能放电
诊断结果	S ₆	S ₄	S ₆	S ₃	S ₁
实际故障	重度高温过热	轻度局部放电	重度高温过热	中度高能放电	正常

4 结语

本文基于范例推理的理论与 SVM 思想, 基于电气设备的海量运行数据、历史数据以及环境数据等, 建立设备状态范例库; 利用 SVM 回归分析对数据样本进行学习训练, 建立设备的状态指纹和电气设备智能诊断模型; 最后以变压器状态诊断为例, 应用模型对变压器实际数据进行分析诊断, 并与三比值法诊断结果相比较. 实验结果表明, 诊断模型具有较高的准确性和更广泛的适用性, 且有效性与准确性会随着模型学习经验的增加而进一步提高, 为及时发现并排除电气设备的潜伏性故障提供了一种可行的方案. 然而, 诊断模型的自学习性、自优化性以及对诊断结果的评估方面仍面临不少挑战, 需要进一步的研究.

[参考文献](References)

- [1] 屈靖, 郭剑波. “九五”期间我国电网事故统计分析[J]. 电网技术, 2004, 28(21):60–62.

- Qu Jing, Guo Jianbo. Statistics and analysis of faults in main domestic power systems from 1996 to 2000 [J]. *Power System Technology*, 2004, 28(21): 60–62. (in Chinese)
- [2] 苏鹏声,王欢. 电力系统设备状态监测与故障诊断技术分析[J]. *电力系统自动化*,2003,27(1):61–65,82.
Su Pengsheng, Wang Huan. Technology analysis of state monitoring and fault diagnosis in electric power systems [J]. Automation of Electric Power Systems, 2003, 27(1): 61–65,82. (in Chinese)
- [3] 张怀宇,朱松林,张扬,等. 电气设备状态检修技术体系研究与实施[J]. *电网技术*,2009,33(13):70–73.
Zhang Huaiyu, Zhu Songlin, Zhang Yang, et al. Research and implementation of condition-based maintenance technology system for power transmission and distribution equipments [J]. *Power System Technology*, 2009, 33 (13) : 70–73. (in Chinese)
- [4] 李明,韩学山,杨明,等. 电网状态检修概念与理论基础研究[J]. *中国电机工程学报*,2011,31(34):43–52.
Li Ming, Han Xueshan, Yang Ming, et al. Basic concept and theoretical study of condition-based maintenance for power transmission system[J]. *Proceedings of the CSEE*, 2011 ,31(34):43–52. (in Chinese)
- [5] Solomon R,Sandborn P A,Pecht M G. Electronic part life cycle concepts and obsolescence forecasting[J]. *Components and Packaging Technologies*,2000,23(4):707–717.
- [6] 王佳明,刘文颖,魏帆,等. 基于寿命周期成本管理的电气设备状态检修策略研究[J]. *电力系统保护与控制*,2011,39(5):77–80.
Wang Jiaming, Liu Wenying, Wei Fan, et al. Study on policies of condition based maintenance of transmission and distribution equipments combined with life cycle cost management[J]. *Power System Protection and Control*, 2011 ,39 (5) : 77–80. (in Chinese)
- [7] 董明,张勇,张岩,等. 含电气量信息的电力系统故障诊断解析模型[J]. *电力系统自动化*,2013,37(6):55–62.
Dong Ming, Zhang Yong, Zhang Yan, et al. An analytic model for power system fault diagnosis employing electrical data[J]. Automation of Electric Power Systems, 2013, 37(6): 55–62. (in Chinese)
- [8] Wu X, Chen J, Li R, et al. Modeling a web-based remote monitoring and fault diagnosis system with UML and component technology[J]. *Journal of Intelligent Information Systems*, 2006, 27(1): 5–19.
- [9] Ma Gang, Wu Kehe, Zhang Tong, et al. A method of workflow model structure verification based on graph theory[J]. *Journal of Convergence Information Technology*, 2012, 7 (17) : 350–356.
- [10] Schank R, Abelson R P. Scripts, Plans, Goals and Understanding[M]. New Jersey: Edbaum, Hillsdale, 1977.
- [11] Schank R. Dynamicmemory:A Theory of Reminding and Learning in Computers and People[M]. Cambridge, UK: Cambridge University Press, 1982.
- [12] Althoff K D. Case-based reasoning[J]. *Handbook on Software Engineering and Knowledge Engineering*, 2001, 1: 549–587.
- [13] Hong Sheng,Zhao Sufeng. A novel substation fault diagnosis approach based on RS and ANN and ES[C]//Proceedings of 2006 International Conference on Communications, Circuits and Systems Proceedings. Guilin,2006:2 124–2 127.
- [14] Ibrahim W R A, Morcos M M. An adaptive fuzzy self-learning technique for prediction of abnormal operation of electrical systems[J]. *IEEE Transactions on Power Delivery*, 2006, 21(4):1 770–1 777.
- [15] Yi D, Peichao Z, Weiyong Y. A substation fault diagnosis system based on case-based reasoning and rule-based reasoning[J]. *Power System Technology*, 2004, 28(1): 34–37.
- [16] Smyth B, Keane M T, Cunningham P. Hierarchical case-based reasoning:integrating case-based and decompositional problem-solving techniques for plant-control software design[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2001, 13(5): 793–812.
- [17] Cheong S, Oh S H, Lee S Y. Support vector machines with binary tree architecture for multi-class classification[J]. *Neural Information Processing-Letters and Reviews*, 2004, 2(3): 47–51.
- [18] 刘继东,韩学山,韩伟吉,等. 分时电价下用户响应行为的模型与算法[J]. *电网技术*,2013,(10):2 973–2 978.
Liu Jidong, Han Xueshan, Han Weiji, et al. Model and algorithm of customers' responsive behavior under time-of-use price[J]. *Power System Technology*, 2013, 37 (10) : 2 973–2 978. (in Chinese)
- [19] 王国胜. 核函数的性质及其构造方法[J]. *计算机科学*,2006,33(6):172–174,178.
Wang Gousheng. Properties and construction methods of kernel in support vector machine[J]. *Computer Science*, 2006 ,33 (6) : 171–174,178. (in Chinese)
- [20] Vapnik V N. *The Nature of Statistical Learning Theory*[M]. New York: Springer Verlag, 2000:123–266.
- [21] Scholkopf B,Smola AJ. *Learning with Kernel*[M]. MA:Cambridge Press,2000.

- [22] Ma Gang, Wu Kehe, Zhang Tong, et al. A Flexible Policy-Based Access Control Model for Workflow [J]. Electric review, 2012, 88(3b): 67–71.
- [23] 孙才新,陈伟根,李俭,等.电器设备油中气体在线监测与故障诊断技术[M].北京:科学出版社,2003;239–241.
Sun Caixin, Chen weigen, Li Jian, et al. Gis Monitoring On-Line and Fault Diagnosis Technology Electric Equipment [M]. Beijing: Science Press, 2003; 239–241. (in Chinese)
- [24] 国家质量监督检验检疫总局. GB/T7252—2001 标准变压器油中溶解气体分析和判断导则[S]. 北京:中国标准出版社,2002.
AQSIQ. GB/T7252—2001 Guide to the Analysis and the Diagnosis of Gases Dissolved in Transformer Oil [S]. Beijing: Standards Press of China, 2002.
- [25] 马刚. 输变电设备在线状态分析与智能诊断系统的研究[D]. 北京:华北电力大学控制与计算机工程学院,2013.
Gang Ma. Research on Power Transmission and Transformation Equipment Online Status Analysis and Intelligent Diagnosis System [D]. Beijing: School of Control and Computer Engineering, North China Electric Power University, 2013. (in Chinese)
- [26] 廖怀东. 变压器油色谱分析及故障判断[J]. 高电压技术,2006,32(1):112–113.
Liao Huaidong. Oil chromatographic analysis and fault diagnosis for transformers [J]. High Voltage Engineering, 2006, 32(1): 112–113. (in Chinese)

[责任编辑:严海琳]

(上接第6页)

- [7] 周扬忠,毛洁. 基于有效磁链概念的永磁同步电动机新型定子磁链滑模观测器[J]. 中国电机工程学报,2013,33(12): 152–158.
Zhou Yangzhong, Mao Jie. A novel sliding mode stator flux linkage estimator based on active flux principle for permanent magnet synchronous motors [J]. Proceedings of the CSEE, 2013, 33(12): 152–158. (in Chinese)
- [8] 冯江华,许峻峰. 永磁同步电机直接转矩控制系统转矩调节新方法[J]. 中国电机工程学报,2006,26(13):151–157.
Feng Jianghua, Xu Junfeng. A new torque adjustment method of permanent magnet synchronous machines direct torque control system [J]. Proceedings of the CSEE, 2006, 26(13): 151–157. (in Chinese)
- [9] 贾洪平,贺益康. 一种适合 DTC 应用的非线性正交反馈补偿磁链观测器[J]. 中国电机工程学报,2006,26(1):101–105.
Jia Hongping, He Yikang. A new nonlinear perpendicular flux observer with compensation feedback suitable for DTC application [J]. Proceedings of the CSEE, 2006, 26(1): 101–105. (in Chinese)
- [10] 杨建飞,胡育文. 永磁同步电机最优直接转矩控制[J]. 中国电机工程学报,2011,31(27):109–115.
Yang Jianfei, Hu Yuwen. Optimal direct torque control of permanent magnet synchronous motor [J]. Proceedings of the CSEE, 2011, 31(27): 109–115. (in Chinese)

[责任编辑:严海琳]