

基于自适应 PSO 算法的 LS-SVM 牵引 变压器绝缘故障诊断模型

方 科,黄元亮,刘新东

(暨南大学 电气自动化研究所,广东 珠海 519070)

摘要: 结合罗杰斯比值法,基于自适应 PSO 算法和最小二乘支持向量机(LS-SVM),提出一种牵引变压器绝缘故障诊断模型。该模型提出一种自适应 PSO 算法,即根据群体的收敛程度和个体的适应值来调整惯性权重,加快训练速度,利用该算法迭代求解 LS-SVM 中出现的矩阵方程,避免矩阵求逆,节省内存;为了快速和准确地区分牵引变压器 12 种绝缘故障,该模型构建 12 个自适应 PSO 的 LS-SVM 分类器。通过对 600 组牵引变压器的故障数据的处理表明,所提出的基于自适应 PSO 优化的 LS-SVM 算法优于经典 SVM 算法和标准 PSO 的 LS-SVM 算法,收敛速度快,识别精度高。

关键词: 故障诊断;牵引变压器;最小二乘支持向量机;粒子群优化;罗杰斯比值法;多分类

中图分类号: TM 855;TP 277

文献标识码: A

文章编号: 1006-6047(2011)03-0085-04

0 引言

牵引变压器作为牵引供电系统的核心设备,其可靠性决定着整个牵引供电系统的安全运行。牵引变压器由于牵引负荷不同于普通电力变压器,有着下列特征:负载幅值变化大、平均负荷率低、负载周期变化频繁、随机性强、非线性等特点^[1]。变压器油中溶解气体分析(DGA)作为一种常见的变压器故障诊断方法,其特点是能发现通过电器试验不易发现的潜伏性故障,进行早期和实时的诊断非常有效。目前,利用 DGA 方法来诊断变压器故障的方法较多,最基本的是 IEC 三比值法,但是大量的统计资料表明,三比值法对充油变压器导电回路和磁回路的铁心多点接地等过热故障的论断准确度不高,因此,英国中央电力局提出了应用溶解气体体积分数的 4 组比值来构成 1 组代码以确定故障的性质,即罗杰斯(Rogers)比值法^[2-4]。

随着计算智能的兴起,许多学者致力于用神经网络、进化计算等计算智能技术对变压器进行故障诊断,取得了良好的效果^[5-6]。支持向量机(SVM)建立在统计学习理论的 VC 维理论和结构风险最小原理基础上,能较好解决小样本、非线性、高维数和局部极小点等实际问题,能有效避免“过拟和”,已成功应用于各种分类问题^[7-8]。为了提高效率,克服大规模问题存在训练较慢的特点,Suyken 提出的最小二

乘支持向量机(LS-SVM)^[9-10]将不等式约束改为等式约束,并将经验风险由偏差的一次方转化为二次方,经典 SVM 的学习问题被转化为求解线性方程组问题,避免了二次优化问题,提高了运算速度。但是 LS-SVM 在求解过程中总会出现矩阵求逆,对于实际工程中的大规模问题,难以应用。为此,采用粒子群优化算法(PSO)来求解任意维线性方程组,不仅避免了矩阵求逆,而且加快了计算速度。

本文在研究 PSO、LS-SVM 的基础上,提出了一种基于自适应 PSO 算法的 LS-SVM 牵引变压器故障诊断模型,并进行了详细的描述;并同时采用经典 SVM、标准 PSO 的 LS-SVM 对数据进行处理、比较,得出结论。

1 LS-SVM 和自适应 PSO

1.1 LS-SVM 的基本理论

设训练集 $S = \{(\mathbf{x}_i, y_i) | i = 1, 2, \dots, l\}$, 其中 $\mathbf{x}_i \in \mathbf{R}^n$ 和 $y_i \in \mathbf{R}$ 分别为输入和输出数据,LS-SVM 利用 SRM 准则构造的最小化目标函数及其约束条件为

$$\begin{aligned} \min J(\mathbf{w}, \mathbf{e}) &= \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 \\ \text{s.t. } y_i &= \mathbf{w}^T \Phi(\mathbf{x}_i) + b + e_i \end{aligned} \quad (1)$$

其中, $i=1, 2, \dots, l$; $\mathbf{w}$ 为权重向量; γ 为常数; b 为常数偏差。

为了求解式(1)的优化问题,转化为求解如下线性方程组:

$$\begin{bmatrix} 0 & \mathbf{L}^T \\ \mathbf{L} & \mathbf{Q} + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (2)$$

其中, $\mathbf{y} = [y_1, y_2, \dots, y_l]^T \in \mathbf{R}^l$, $\mathbf{L} \in \mathbf{R}^l$ 为元素 1 的向量, $\boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_l]^T \in \mathbf{R}^l$, $\mathbf{Q} = [q_{ij}]_{l \times l}$, $q_{ij} = y_i y_j K(\mathbf{x}_i, \mathbf{x}_j)$ 。

收稿日期:2010-05-22;修回日期:2010-11-24

基金项目:国家自然科学基金项目(51007030);铁道部科技研究开发计划课题(2008J002)

Project supported by the National Natural Science Foundation of China(51007030) and the Technological Research and Development Programs of the Ministry of Railways (2008J002)

将方程式(2)改写为如下矩阵形式:

$$\mathbf{BG}=\mathbf{z} \quad (3)$$

由式(3)可知,求解 $\mathbf{G}$ 需要对 $\mathbf{B}$ 求逆。然而,对于实际工程的大规模问题,由于 $\mathbf{B}^T\mathbf{B}$ 维数较大,矩阵求逆效率很低,难以应用。为此,可以采用 PSO 算法进行迭代计算的方法求解矩阵方程。

1.2 PSO 的基本理论

PSO 算法模拟了鸟类的飞行^[11],每只鸟表示一个粒子或个体,粒子的位置表示问题空间的一个基本解。Kennedy 等人提出的 PSO 算法采用下列公式对粒子进行操作。

在 n 维空间中有 m 个粒子,设 $\mathbf{x}_i=(x_{i1},x_{i2},\dots,x_{in})$ 、 $\mathbf{v}_i=(v_{i1},v_{i2},\dots,v_{in})$ 分别为粒子 i 的当前位置、当前速度; $\mathbf{p}_i=(p_{i1},p_{i2},\dots,p_{in})$ 为粒子 i 所经历的最好位置, $\mathbf{g}_{\text{best}}$ 为群体中所有粒子所经历的最好位置。对于每一代粒子的速度和位置,根据式(4)~(6)进化:

$$\mathbf{v}_i^{t+1}=\omega_{\text{ps}}\mathbf{v}_i^t+\varphi_1r_1(\mathbf{p}_i^t-\mathbf{x}_i^t)+\varphi_2r_2(\mathbf{g}_{\text{best}}^t-\mathbf{x}_i^t) \quad (4)$$

$$\begin{cases} \mathbf{v}_i^{t+1}=\mathbf{v}_{\text{max}} & \mathbf{v}_i^{t+1}>\mathbf{v}_{\text{max}} \\ \mathbf{v}_i^{t+1}=-\mathbf{v}_{\text{max}} & \mathbf{v}_i^{t+1}<-\mathbf{v}_{\text{max}} \end{cases} \quad (5)$$

$$\mathbf{x}_{i+1}=\mathbf{x}_i+\mathbf{v}_{i+1} \quad (6)$$

其中, t 、 $t+1$ 分别表示当前的迭代次数; ω_{ps} 为惯性权重; φ_1 和 φ_2 是加速度常数,通常取 $\varphi_1=\varphi_2=2$; r_1 和 r_2 为 2 个在 $[0,1]$ 范围内变化的随机数; $\mathbf{v}_{\text{max}}$ 为最大飞行速度。

1.3 基于自适应 PSO 算法的 LS-SVM 求解

很多学者在研究 PSO 模型时发现,如果惯性权重 ω_{ps} 以及加速度常数 φ_1 和 φ_2 等参数太大,粒子群可能错过最优解,导致算法不收敛;而在收敛的情况下,所有的粒子都向最优解的方向飞去,所有粒子趋向同一化,使得后期收敛速度明显变慢,同时算法收敛到一定精度时无法继续优化,所能达到的精度也较低^[12-13]。为了解决此问题,可根据粒子适应度优劣来调整惯性权重 ω_{ps} ,即在算法的初期阶段,赋予 ω_{ps} 一个较大的正值,以获得较好的全局搜索能力;而在算法的后期阶段赋予 ω_{ps} 一个较小的值,可使算法更易于收敛。本文提出一种自适应 PSO 算法,可根据群体的收敛程度和个体适应值来动态调整惯性权重,具体方法如下。

当 $f(\mathbf{x}_i)<f(\mathbf{g}_{\text{best}})$ 时,满足此条件的粒子是群体中的较优的粒子,已经比较接近全局最优,所以应赋予较小的惯性权重,以加速向全局最优收敛。根据粒子适应值调整惯性权重:

$$\omega_{\text{ps}}=\omega_{\text{ps}}-(\omega_{\text{ps}}-\omega_{\text{min}})\left|\frac{f(\mathbf{x}_i)-f(\mathbf{p}_i)}{f(\mathbf{g}_{\text{best}})-f(\mathbf{p}_i)}\right| \quad (7)$$

其中, ω_{min} 为 ω 的最小值,本文取 $\omega_{\text{min}}=0.4$ 。粒子适应值越好,其惯性权重越小,有利于局部寻优。

当 $f(\mathbf{g}_{\text{best}})<f(\mathbf{x}_i)<f(\mathbf{p}_i)$,满足此条件的粒子是群体中的一般粒子,具有良好的全局寻优能力和局部寻优能力。惯性权重 ω_{ps} 随着搜索的进行按对数 S 型激活函数变化:

$$\omega_{\text{ps}}=\omega_{\text{min}}+(\omega_{\text{max}}-\omega_{\text{min}})\frac{1}{1+\exp(-t_{\text{max}}/t)} \quad (8)$$

其中, ω_{max} 为搜索开始时最大的 ω_{ps} ,设为 0.9; ω_{min} 为搜索结束时最小的 ω_{ps} ,设为 0.4; t 为迭代所进行的步数, t_{max} 为最大迭代次数。

这种自适应 PSO 算法,既保证了算法的收敛性,加快了收敛速度,又提高了求解精度。基于自适应 PSO 的 LS-SVM 算法流程有 7 步。

a. 初始化粒子群。设定粒子群参数,在 n 维空间中随机产生 m 个粒子 $(\mathbf{x}_1,\mathbf{x}_2,\dots,\mathbf{x}_m)$ 组成初始种群 $\mathbf{X}(t)$;随机产生各粒子 $\mathbf{x}_i$ 的初始速度 $(v_{i1},v_{i2},\dots,v_{in})$ 组成速度矩阵 $\mathbf{V}(t)$;每个粒子的个体最优解 $\mathbf{p}_i$ 初始值为 $\mathbf{x}_i$ 的初始值。

b. 评价各粒子适用度(fitness)。在具体矩阵方程求解中,可按 $(\mathbf{z}-\mathbf{BG})$ 的均方差来定义适应度函数:

$$f(\mathbf{x}_i)=\frac{1}{n}\|\mathbf{z}_i-\mathbf{B}_i\mathbf{x}_i\|^2$$

c. 对每个粒子,比较当前适应度 $f(\mathbf{x}_i)$ 和历史最好位置适应度 $f(\mathbf{p}_i)$,若 $f(\mathbf{x}_i)<f(\mathbf{p}_i)$,则 $\mathbf{p}_i=\mathbf{x}_i$,并根据式(4)调整 ω_{ps} ;比较群体所有粒子当前适应度 $f(\mathbf{x}_i)$ 和群体最好位置适应度 $f(\mathbf{g}_{\text{best}})$,若 $f(\mathbf{x}_i)<f(\mathbf{g}_{\text{best}})$,则全局最优解 $\mathbf{g}_{\text{best}}=\mathbf{x}_i$,并根据式(5)调整 ω_{ps} 。

d. 更新粒子的速度和位置,产生新种群 $\mathbf{X}(t+1)$,速度调整规则如下:

$$\mathbf{v}_i=\begin{cases} \mathbf{v}_{\text{max}} & \mathbf{v}_i>\mathbf{v}_{\text{max}} \\ -\mathbf{v}_{\text{max}} & \mathbf{v}_i<-\mathbf{v}_{\text{max}} \end{cases}$$

e. 检查结束条件。若满足,则结束寻优,返回当前最优个体为结果;否则 $t=t+1$,转至步骤 **b**。设定结束条件为寻优到最大迭代次数 t_{max} 或评价值小于给定精度。

f. 输出结果,得到矩阵方程的最小二乘解,即对应式(2)中最优参数 $\{\alpha_i\}_{i=1}^N$ 和 b 。

g. 将 $\{\alpha_i\}_{i=1}^N$ 和 b 代入下式得到识别函数式,再输入待识别样本进行识别。

$$y(\mathbf{x})=\sum_{k=1}^N\alpha_kK(\mathbf{x},\mathbf{x}_k)+b$$

本文选取径向基为核函数,如下式所示:

$$K(\mathbf{x},\mathbf{x}_k)=\exp[-\|\mathbf{x}-\mathbf{x}_k\|^2/(2\sigma^2)]$$

1.4 多类 LS-SVM

LS-SVM 起初用于 2 值分类问题,对于多值分类问题,目前主要的方法有 one-against-rest(1-a-r)、one-against-one(1-a-1)、Directed Acyclic Graph SVM (DAG-SVM)、Decision-tree-based multi-class SVM (DT-SVM)等^[14-15],在上述方法中,又以 1-a-r 以及 1-a-1 最为常见,1-a-1 采用投票组合的策略进行多分类,精度高,缺点是对于 K 分类问题必须训练 $K(K-1)/2$ 个 LS-SVM 分类器,且分类必须遍历所有分类器,训练复杂,分类效率低。1-a-r 采用“一对其余”的方法只需要训练 K 个 LS-SVM 分类器,采用“最大输出”法实现多分类。该方法较 1-a-1 大幅减少了所需训练的 LS-SVM 分类器,提高了训练速度。

根据罗杰斯比值法,牵引变压器绝缘故障共有 12 种状态,包括正常劣化、局部放电、轻度过热(低于 150 ℃)、轻度过热(150~200 ℃)、轻度过热(200~300 ℃)、一般导线过热、铁心环流、铁心和箱壳环以及接头过热、无工频续流的闪络、有工频续流的闪络、悬浮电位引起的连续火花、留有痕迹的局部放电。所以需要 12 个 LS-SVM 分类器,首先判断是否为 1 类故障(正常劣化),如果是,则判断下一个样本;否则判断是否为 2 类故障(局部放电),直至第 12 类故障(留有痕迹的局部放电)。其结构图如图 1 所示。




图 1 1-a-r LS-SVM 分类结构图

Fig.1 Multi-classification based on 1-a-r SVM strategy

2 实验

为检验本文提出的基于自适应 PSO 的 LS-SVM 牵引变压器故障诊断模型的应用效果,下面举例详细分析。样本取自 TM1-1 型牵引变压器,对应于 12 种不同的故障类别,分别采集了 600 组相应的特征气体。

2.1 样本信息选取和预处理

由于变压器故障时,油中溶解特征气体主要有 H_2 、 CH_4 、 C_2H_2 、 C_2H_4 、 C_2H_6 5 种,罗杰斯比值法是将气体体积分数的比值 $\varphi(CH_4)/\varphi(H_2)$ 、 $\varphi(C_2H_6)/\varphi(CH_4)$ 、 $\varphi(C_2H_4)/\varphi(C_2H_6)$ 和 $\varphi(C_2H_2)/\varphi(C_2H_4)$ 作为判断依据。将样本分为 2 部分,包括 300 组训练样本和 300 组测试样本,为了降低各种气体之间由于量值差异造成的影响,避免计算饱和现象的出现,要对样本数据进行归一化处理,使输入样本数据在 $[0,1]$ 之间,归一化公式如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

其中, $x \in [x_{\min}, x_{\max}]$, $x_{\min}$ 和 $x_{\max}$ 分别为最小值和最大值。

2.2 迭代寻优

设粒子群规模为 25,解空间为 300 维,最大迭代次数为 1000,加速度常数 $\varphi_1 = \varphi_2 = 2.05$,初始 $w_{\text{ps}} = 0.9$ 。建立 12 个 LS-SVM 分类器, γ 选取 1000,径向基核函数的宽度参数 σ^2 选取 0.125。利用标准 PSO 和自适应 PSO 求解 LS-SVM 中的式(3)所得到的平均误差曲线如图 2 所示(1 为标准 PSO,2 为自适应 PSO; ξ 为均方误差, N 为迭代次数)。标准 PSO 算法在第 80 次迭代后误差精度达到 0.3,而自适应 PSO 算法在迭代相同的次数时,精度达到 0.09,在 200 次迭代后误差精度便达到 0.02,可见自适应 PSO 在收敛速度和精度上均优于标准 PSO。

2.3 识别结果比较

将自适应 PSO 迭代后得到的预测模型对 300 个故障样本进行识别,分别建立经典 SVM 模型和标




图 2 标准 PSO 算法和自适应 PSO 算法误差曲线

Fig.2 Error curves of standard PSO algorithm and adaptive PSO algorithm

准 PSO 的 LS-SVM 模型,并将识别的结果与本文提出的诊断模型相比较。经典 SVM 模型采用径向基核函数;标准 PSO 的 LS-SVM 模型中的惯性权重 w_{ps} 恒定。测试参数分别是:训练时耗、测试时耗、训练集准确率(RMS)和误差(Dev)、测试集的准确率(RMS)和误差(Dev)。性能测试如表 1 所示(I 为经典 SVM,II 为标准 PSO 的 LS-SVM,III 为自适应 PSO 的 LS-SVM)。

表 1 算法性能比较

Tab.1 Comparison of algorithm performance

算法	时耗/s		训练集指标/%		测试集指标/%	
	训练	测试	RMS	Dev	RMS	Dev
I	0.2309	0.3416	86.783	1.4108	85.753	2.115
II	0.1253	0.2133	87.398	1.3920	86.967	1.909
III	0.0662	0.1117	89.327	1.3350	88.634	1.894

从性能测试的统计结果可看出,自适应 PSO 的 LS-SVM 训练时耗和测试时耗明显比经典 SVM 和标准 PSO 的 LS-SVM 都小,说明在处理相对复杂的问题和实时性能要求较高的问题时,自适应 PSO 的 LS-SVM 具有较强的优势;自适应 PSO 的 LS-SVM 训练集和测试集的准确概率都略高于经典 SVM 和标准 PSO 的 LS-SVM,误差相对较小,显示了自适应 PSO 的 LS-SVM 具有较好的分类效果。

其次,测试 3 种分类器在不同训练数据样本数量情况下的性能。训练时间测试的训练数据样本数量范围取 50~300,训练时间变化对比结果如图 3 所示(1 为经典 SVM,2 为标准 PSO 的 LS-SVM,3 为自适应 PSO 的 LS-SVM,后同; t_x 为训练时间, m_x 为训练样本数);测试时间测试的测试样本数量范围取 50~300,训练样本数量取 300,测试时间变化对比结果如图 4 所示(t_c 为测试时间, m_c 为测试样本数);准确率测试的训练样本数量范围取 50~300,测试样本数量取 300,准确率变化对比结果如图 5 所示(η 为准确率, m_x 为训练样本数)。

从上述性能变化曲线的测试结果可以看出:随




图 3 训练时间对比曲线

Fig.3 Comparison among training time curves




图 4 测试时间对比曲线

Fig.4 Comparison among test time curves




图 5 准确率对比曲线

Fig.5 Comparison among accuracy curves

随着训练样本数量的增加,3 种分类算法的训练时间都有明显增加,但自适应 PSO 的 LS-SVM 的训练时间明显低于经典 SVM 算法和标准 PSO 的 LS-SVM,说明自适应 PSO 的 LS-SVM 对不同样本数量测试条件和环境都具有良好的适应能力,学习过程快;在测试时间上,3 种算法的处理时间随着测试样本数量的增加而线性增加,但自适应 PSO 的 LS-SVM 的处理时间明显短于经典 SVM 和标准 PSO 的 LS-SVM,自适应 PSO 的 LS-SVM 表现出较好的实时处理能力;在相同条件下,3 种算法分类准确率也都具有随着训练样本数量增加而增加的趋势,但是自适应 PSO 的 LS-SVM 略高于经典 SVM 和标准 PSO 的 LS-SVM,可见自适应 PSO 算法在矩阵迭代过程中获得了更高的精度。

3 结论

牵引变压器故障诊断问题非常复杂,影响诊断结果的因素很多,本文提出的基于自适应 PSO 优化的 LS-SVM 算法既利用了 LS-SVM 算法解决小样本、非线性、高维数和局部极小点等问题,又利用了自适应 PSO 算法解决 LS-SVM 模型对于大规模样本所出现的计算复杂度高、计算速度慢等问题,使其总求得最优解,其训练速度和精度均得到提高。实例证明它是有效和可靠的,有很好的推广应用价值。

参考文献:

- [1] 周利军,吴广宁. 牵引负荷对变压器绝缘老化和寿命损失的影响[J]. 电力系统自动化,2005,29(18):90-94.
ZHOU Lijun, WU Guangning. Effect of traction loads on insulation aging and loss-of-line of transformers[J]. Automation of Electric Power Systems, 2005, 29(18): 90-94.
- [2] JARDINI J A, SCHMIDT H P, TAHAN C M V et al. Distribution transformer loss of life evaluation: a novel approach based on daily load profiles[J]. IEEE Trans on Power Delivery, 2000,

15(1):361-366.

- [3] MCNUTT W J. Insulation thermal life considerations for transformer loading guides[J]. IEEE Trans on Power Delivery, 1992, 7(1):390-401.
- [4] DUVAL M. A review of fault detectable by gas-in-oil analysis in transformers[J]. IEEE Electrical Insulation Magazine, 2002, 18(3):8-17.
- [5] DURASAMY V, DEVARAJAN N, SOMASUNDARESWARI D, et al. Neuro fuzzy schemes for fault detection in power transformer[J]. Applied Soft Computing, 2007, 7(2):534-539.
- [6] HUNG Chinpao, WANG Manghui. Diagnosis of incipient faults in power transformers using CMAC neural network approach [J]. Electric Power Systems Research, 2004, 17(10):235-244.
- [7] 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):1878-1886.
XIAO Yancai, CHEN Xiuhai, ZHU Hengjun. The application of genetic support vector machine in power transformer fault diagnosis[J]. Journal of Shanghai Jiao Tong University, 2007, 41(11): 1878-1886.
- [8] FEI Shengwei, LIU Chengiang, MIAO Yubin. Support vector machine with genetic algorithm for forecasting of key-gas ratios in oil-immersed transformer[J]. Expert Systems with Applications, 2009, 36(4):6326-6331.
- [9] SUYKENS J A K, VANDEWALLE J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [10] SUYKENS J A K, BRANBANTER J D, LUKAS L, et al. Weighted least squares support vector machines: robustness and sparse approximation[J]. Neurocomputing, 2002, 48(1):85-105.
- [11] KENNEDY J, EBERHART R C. Particle swarm optimization[C] //Proc IEEE Int Conf Neural Networks. Piscataway, USA: IEEE, 1995:1942-1948.
- [12] SHI Y, EBERHART R. A modified particle swarm optimizer [C] //IEEE World Congress on Computational Intelligence. Anchorage, USA: IEEE, 1998:69-73.
- [13] CLERC M. The swarm and the queen: towards a deterministic and adaptive particle swarm optimization [C] //Proc of the Congress of Evolutionary Computation. Washington, USA: [s.n.], 1999:1951-1957.
- [14] SHIH F Y, ZHANG K. Support vector machine networks for multi-class classification[J]. Pattern Recognition and Artificial Intelligence, 2005, 19(6):775-786.
- [15] LIU Yiguang, YOU Zhisheng, CAO Liping. A novel and quick SVM-based multi-class classifier[J]. Pattern Recognition, 2006, 39(10):2258-2264.

(编辑: 柏英武)

作者简介:

方 科(1982-), 男, 安徽安庆人, 助理实验师, 硕士, 主要研究方向为智能信息处理、多传感器数据融合、嵌入式系统等(E-mail: tfangke@gmail.com);

黄元亮(1963-), 男, 湖南永顺人, 副教授, 博士, 主要研究方向为定性仿真、牵引供电等;

刘新东(1981-), 男, 河南商丘人, 讲师, 博士, 主要研究方向为电力系统安全与稳定。

Insulation fault diagnosis model based on adaptive PSO and LS-SVM for traction transformer

FANG Ke, HUANG Yuanliang, LIU Xindong

(Electric Automation Institute of Jinan University, Zhuhai 519070, China)

Abstract: Combined with the Rogers ratio method, an insulation fault diagnosis model based on adaptive PSO and LS-SVM is presented for traction transformer. It adjusts the inertia weights to accelerate the training speed according to the swarm convergence and individual fitness. The matrix of LS-SVM is solved through the adaptive PSO to avoid the inverse solution for memory saving. In order to quickly and accurately distinguish 12 insulation faults, 12 LS-SVM classifiers based on adaptive PSO are built. Tests on 600 groups of fault data indicate that, the proposed model has faster convergence velocity and higher accuracy than classical SVM model and LS-SVM model based on standard PSO.

Key words: fault diagnosis; traction transformer; least squares support vector machine; particle swarm optimization; Rogers ratio method; multi-classification