

基于克隆选择算法的支持向量回归实现年用电量预测

孙成发, 高辉

(阿城继电器股份有限公司哈尔滨瑞雷电气科技发展有限责任公司, 黑龙江 哈尔滨 150090)

摘要: 建立在统计学习理论 (SLT) 和结构风险最小化 (SRM) 准则基础上的支持向量回归 (SVR) 是处理小样本数据回归问题的有利工具, SVR 的参数取值直接影响其学习性能和泛化能力。文中将 SVR 参数选取看作参数的组合优化问题, 采用克隆选择算法 (CSA) 求解该组合优化问题进而选取 SVR 参数, 并应用基于 CSA 的 SVR 求解年电力需求预测问题, 同时与 BP 网络预测方法进行了对比。预测结果表明提出的预测方法不仅易于实现, 而且精度较高, 且性能明显优于 BP 网络方法。

关键词: 年用电量; 支持向量回归; 克隆选择算法; 回归; 预测

Using support vector regression based on clonal selection algorithm in annual electric consumption forecasting

SUN Cheng-fa, GAO Hui

(Acheng Relay Co.,Ltd, Harbin Reli Electric Technology Co.,Ltd, Harbin 150090, China)

Abstract: Support vector regression (SVR) is based on statistical learning theory (SLT) and structural risk minimization (SRM) principle, is a powerful tool of solving a small-sample regression problem, and selecting appropriate parameters are very crucial to learning accuracy and generalization ability of SVR. In this paper, the selection problem of SVR parameters is considered as a combinatorial optimization problem, clonal selection algorithm (CSA) is employed to solve this optimization problem, further, to select appropriate parameters of SVR, and SVR based on CSA is used to annual electric consumption forecasting problem, at same time, comparing forecasting methods based on BP networks is studied. The forecasting example shows that the performance of the proposed method is superior to that of BP networks method in terms of easier realization, higher forecasting accuracy.

Key words: annual electric consumption; support vector regression; clonal selection algorithm; regression; forecasting

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2008)16-0011-05

0 引言

电力系统负荷预测是保证电力供应的重要工作, 对能源规划、电力系统运行与控制及经济发展战略研究有着重要意义。传统的预测方法包括: 回归分析、时间序列、专家系统、灰色理论等等^[1,2], 但由于电力系统受众多因素的影响具有高度的复杂性, 上述方法不仅工作量大, 而且精度也难以保证。在这种情况下, 具有较强的自学习能力、容错能力、解决非线性问题能力、处理噪声和不完全数据能力的 BP 网络作为一种新的工具被引入到电力系统负荷预测领域并取得了一定的成果^[3]。然而, 基于经验风险最小 (ERM) 准则的 BP 网络存在的诸如训练易陷入局部极小值, 难以平衡学习精度和泛化能力之间的矛盾等不足, 并且 BP 网络结构的确定也缺乏理论指导, 致使 BP 网络在电力系统负荷预测领域和其他领域的应用受到限制。

支持向量回归 (SVR) 是一种建立在统计学习理论 (SLT) 和结构风险最小化 (SRM) 准则基础上用于回归分析的新型学习工具, 能够很好地克服 BP 网络的不足, 并在诸多领域得到了应用^[4-6]。然而, SVR 的理论研究要远远超前其应用研究。在实际应用中, SVR 相关参数的选取对其性能有很大的影响, 是一个亟待解决的问题。以往常用正交试验法和留一法选择相关参数, 但是这两种方法均是在固定网格上的遍历性搜索, 存在搜索效率低, 搜索空间不连续问题^[7,8]。

本文将 SVR 相关参数的选取看作是一个组合优化问题, 建立了组合优化问题的目标函数, 采用克隆选择算法 (CSA) 求解该组合优化问题, 进而优选 SVR 相关参数, 形成基于 CSA 的 SVR (CSA-SVR)。并将 CSA-SVR 引入电力系统负荷预测领域, 通过实例分析表明应用 CSA-SVR 预测年用电量的有效性。

1 支持向量回归

回归问题: 设给定一个样本数据集为 $\{x_i, y_i\}$, $x_i \in X = R^n$ 为输入向量, $y_i \in Y = R$ 为输出变量, $i=1, \dots, l$, l 为样本数目, 且样本数据满足一个未知但确定的联合概率分布 $P(x, y)$, 回归问题就是寻找一个函数

$$f(x) = (w \cdot x) + b \quad (1)$$

以最小化期望风险

$$R[f] = \int L(x, y, f(x)) dP(x, y) \quad (2)$$

式中: $w \in R^n$, $b \in R$ 为广义参数, $(w \cdot x)$ 为 w 和 x 的内积运算, $L(x, y, f(x))$ 为给定损失函数, 常用的一种损失函数为 ε -不敏感损失函数, ε -不敏感损失函数描述为

$$L(x, y, f(x)) = |y - f(x)|_{\varepsilon} = \max\{0, |y - f(x)| - \varepsilon\} \quad (3)$$

式中: ε 为预先设置的一个正数。

支持向量回归的基本思想是通过一个非线性映射 $\phi(\cdot)$ 将样本的输入 x 由输入空间 X 映射到一个高维特征空间 H , 并在特征空间 H 实现线性函数回归。设非线性函数 $\phi(\cdot)$ 将输入空间 X 映射到高维特征空间 H , 依据统计学习理论和结构风险最小准则, 并采用 ε -不敏感损失函数, 同时引入上下松弛变量 ξ_i 和 ξ_i^* 以描述对 ε 带以外样本数据的拟合损失, 则确定回归线性函数

$$f(x) = (w \cdot \phi(x)) + b \quad (4)$$

就是要求解关于变量 w 、 b 、 ξ 和 ξ^* 的最优化问题

$$\begin{aligned} \min_{w, b, \xi_i, \xi_i^*} & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t.} & y_i - ((w \cdot \phi(x)) + b) \leq \varepsilon + \xi_i, i=1, \dots, l \\ & ((w \cdot \phi(x)) + b) - y_i \leq \varepsilon + \xi_i^*, i=1, \dots, l \\ & \xi_i, \xi_i^* \geq 0, i=1, \dots, l \end{aligned} \quad (5)$$

式中: C 为惩罚系数, 用于控制对 ε 带以外样本数据的惩罚程度, 并实现函数 $f(x)$ 的复杂度和拟合精度之间的平衡。

优化问题 (5) 为线性约束条件下的二次规划问题, 由优化理论可得它的对偶问题为

$$\begin{aligned} \max_{\alpha_i, \alpha_i^*} & -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i \cdot x_j) + \\ & \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) \\ \text{s.t.} & \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \\ & 0 \leq \alpha_i \leq C, 0 \leq \alpha_i^* \leq C, i=1, \dots, l \end{aligned} \quad (6)$$

式中: $\alpha_i \geq 0$ 、 $\alpha_i^* \geq 0$ 、 $\alpha_j \geq 0$ 和 $\alpha_j^* \geq 0$ 为 Lagrange

对偶变量, 且 $i, j=1, \dots, l$, $K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j))$ 为由映射函数 $\phi(\cdot)$ 在满足 Mercer 条件下构成的核函数, 常用的核函数是径向基核函数, 其表达式为

$$K(x_i, x) = \exp\left(-\|x - x_i\|^2 / (2\sigma^2)\right) \quad (7)$$

式中: σ^2 为径向基核函数的宽度系数。

若 $\bar{\alpha} = (\bar{\alpha}_1, \bar{\alpha}_1^*, \dots, \bar{\alpha}_l, \bar{\alpha}_l^*)^T$ 为对偶问题 (6) 的最优解, 根据 KKT 条件可计算 b 值, 即:

$$\begin{cases} b = y_i - \sum_{j=1}^l (\bar{\alpha}_j - \bar{\alpha}_j^*) K(x_j \cdot x_i) + \varepsilon, \text{if } \bar{\alpha}_i \in (0, C) \\ b = y_i - \sum_{j=1}^l (\bar{\alpha}_j - \bar{\alpha}_j^*) K(x_j \cdot x_i) - \varepsilon, \text{if } \bar{\alpha}_i^* \in (0, C) \end{cases} \quad (8)$$

则回归函数为

$$f(x) = \sum_{i=1}^{nsv} (\bar{\alpha}_i - \bar{\alpha}_i^*) K(x_i \cdot x) + b \quad (9)$$

式中: x_i 为支持向量, nsv 为支持向量的个数。

2 克隆选择算法

借鉴克隆选择学说, 将抗原与待求解问题的目标函数和各种约束条件相对应、抗体与待求解问题的候选解相对应、抗体和抗原的亲合力与待求解问题的候选解满足待求解问题目标函数的程度相对应, 模仿克隆选择机理, 构成克隆选择算法, 克隆选择算法的基本步骤为^[9,10]:

(1) 抗体编码和初始化。设实数编码抗体表示为

$$(x_1, x_2, \dots, x_n) \quad (10)$$

对于实数抗体的每个实数 x_i 用长度为 m_i 的二进制数表示, 构成一个长度为 $m_1 + m_2 + \dots + m_n$ 的二进制编码的抗体, m_i 值的大小决定了候选解的精度和问题的求解难度。依据上述方法, 随机产生抗体集合 $Ab = \{Ab_i\}$, $i=1, \dots, N$, N 为初始抗体规模, 集合 Ab 的每一个抗体对应问题解空间中的一个解, 抗原 Ag 代表待优化的问题。

(2) 评估亲合力。为了评估抗体对抗原的亲合力, 必须对抗体进行解码。首先, 根据抗体编码时实数 x_i 对应的二进制数长度 m_i 对抗体进行划分, 形成二进制子段, 并把每一个二进制子段转化成实数, 形成形如式 (10) 的实数编码抗体, 然后, 计算全部抗体对抗原的亲合力, 组成亲合力集合 f 。

(3) 克隆选择。依据亲合力的大小对集合 f 元素排序, 同时调整抗体集合 Ab 中相应抗体的顺序, 选择亲合力高的 n 个抗体, 形成集合 $Ab_{\{n\}}$ 。

(4) 细胞克隆。对集合 $Ab_{\{n\}}$ 的抗体进行克隆, 第 i 个抗体的克隆数为

$$n_i = \text{round}\left(\frac{\beta \cdot N}{i}\right) \quad (11)$$

式中: β 为克隆系数, 用来控制克隆的规模, $\text{round}(\cdot)$ 为取整函数, 则克隆总数为

$$N_c = \sum_{i=1}^n n_i = \sum_{i=1}^n \text{round}\left(\frac{\beta \cdot N}{i}\right) \quad (12)$$

可见, 亲和力越高的抗体, 克隆的抗体越多, 这样, 高亲和力抗体的优良基因能够更好地保存和发展, 克隆后的抗体形成集合 C 。

(5) 高频变异。集合 C 的抗体提交给亲和力成熟过程, 即: C 中的每个抗体进行高频变异, 第 i 个抗体的变异概率为

$$P_i = \exp\left(-\alpha \frac{f_i}{f_{\max}}\right) \quad (13)$$

式中: α 为变异系数, f_i 为第 i 个抗体与抗原的亲和力, $i=1, \dots, N_c$, f_{\max} 为 C 中抗体与抗原亲和力的最大值。可见, 亲和力越大, 变异的概率越小, 变异后的抗体形成集合 C^* 。

(6) 再选择。评估抗体集合 C^* 中每个抗体对抗原的亲和力, 组成亲和力集合 f^* 。对集合 f^* 元素依据亲和力的大小进行排序, 同时调整抗体集合 C^* 中相应抗体的顺序, 选择亲和力高的 n 个抗体形成集合 $Ab_{\{n\}}$ 。

(7) 增补新抗体。随机产生抗体集合 $Ab_{\{d\}}$, $Ab_{\{d\}}$ 中抗体个数为

$$N_d = \text{round}(\gamma \cdot N) \quad (14)$$

式中: γ 为增补系数, 集合 $Ab_{\{d\}}$ 和集合 $Ab_{\{n\}}$ 一起构成下一代抗体集合 Ab 。通过补充新抗体 $Ab_{\{d\}}$, 增加了抗体的多样性, 扩大了算法搜索的范围, 有利于避免陷入局部极值。

(8) 终止条件。选择进化代数做为终止条件, 当算法运行到设定的代数时, 算法终止运行, 否则, 继续, 返回 (2)。

3 克隆选择算法优化支持向量回归参数

在选用 ε -不敏感损失函数和径向基核函数的条件下, 影响 SVR 性能的相关参数主要包括: 不敏感系数 ε , 径向基核函数的宽度系数 σ^2 和控制回归函数复杂度和拟合精度平衡的惩罚系数 C 。SVR 的学习能力和泛化能力很大程度上受上述三个参数的影响, 且各参数存在最佳匹配问题, 这些参数的正确选择对 SVR 性能非常重要。鉴于以往正交试验法和留一法选择相关参数的不足, 提出应用具有搜索能力强、收敛速度快和稳定性好的 CSA 优化 SVR 参数, 形成 CSA-SVR。

SVR 参数选择问题可视为参数 ε 、 C 和 σ^2 的组合优化问题, 即最优匹配问题, 如果以 SVR 的拟合数值与真实数值的均方误差 MSE 作为性能评价指标, 则 SVR 参数选择问题可转化为在 ε 、 C 和 σ^2 组成的 R^3 空间上的连续函数优化问题。

$$\begin{aligned} \min f(\varepsilon, C, \sigma^2) &= \min MSE \\ \text{s.t. } \varepsilon_{\min} &\leq \varepsilon \leq \varepsilon_{\max} \\ C_{\min} &\leq C \leq C_{\max} \\ \sigma_{\min}^2 &\leq \sigma^2 \leq \sigma_{\max}^2 \end{aligned} \quad (15)$$

对于一组固定的参数 ε 、 C 和 σ^2 可通过序贯最小优化算法 (SMO) 训练 SVR, 进而计算 MSE 。参数 ε 、 C 和 σ^2 的取值范围与训练样本数据和实际问题有关, ε 值与样本数据含噪声水平相关, 通常与噪声水平成正比关系; C 值与可容忍的误差相关, 较大的 C 值容许较小的误差, 较小的 C 值容许较大的误差; σ^2 值与样本数据输入空间相关, 若输入空间范围较大, 应取较大的 σ^2 值, 若输入空间范围较小, 应取较小的 σ^2 值。

4 基于 CSA-SVR 实现年用电量预测

4.1 年用电量预测问题的数学描述

年用电量预测问题就是一个由年用电量观测数据构成的一维时间序列分析问题, 可采用相空间重构方法来分析问题。具体方法: 由年用电量在一些固定时间延迟点的观测数据确定相空间的一个相点, 依此类推, 可重构嵌入相空间。嵌入相空间的维数是时间序列延迟点的个数。如果设嵌入相空间的维数为 m , 未知系统的相空间维数为 d , Takens 嵌入定理证明, 若满足条件 $m \geq 2d + 1$, 则嵌入相空间和未知系统相空间微分同胚, 拓扑等价。

设由年用电量观测数据构成的一维时间序列为 $\{p(t), t=1, \dots, n\}$, 由时间序列嵌入 m 维相空间, 得到一系列 m 维相空间的相点

$$p(t+\tau) = (p(t), p(t-\tau), \dots, p(t-(m-1)\tau)) \quad (16)$$

式中: τ 为延迟时间, m 为嵌入维数。则年用电量预测的过程就是通过年用电量观测数据构成的一维时间序列, 重构产生年用电量的未知系统的相空间, 实现由嵌入 m 维相空间向量 $(p(t), p(t-\tau), \dots, p(t-(m-1)\tau))$ 到一维空间向量 $p(t+\tau)$ 的映射函数 $f: R^m \rightarrow R$ 的过程。

4.2 算例分析

通过以上分析, 年用电量预测问题就是建立从嵌入 m 维相空间到一维空间的回归问题。下面通过实例, 说明基于 SVR 解决年用电量预测问题的具体方法和步骤, 同时, 出于比较的目的, 采用 BP 网络处理相同的问题。文中采用文献[6]提供的四川省

1978~1998 年年实际用电量的历史数据构造训练样本和测试样本,并应用 CSA-SVR 和 BP 网络解决年用电量预测问题。

(1) 数据的准备和预处理。

确定延迟时间 τ 和嵌入维数 m 是形成用于 CSA-SVR 和 BP 网络训练样本数据的必要条件。选用自相关法和伪邻近点法分别确定延迟时间 $\tau=1$, 嵌入维数 $m=3$, 则 1978~1998 年实际数据可构成 14 个训练样本 (1981~1994 年) 和 4 个测试样本 (1995~1998 年)。

为了避免较大范围变化的数据淹没较小范围变化的数据,而丢失样本数据携带的信息,对样本数据的输入和输出在区间 $[0.1, 0.9]$ 进行归一化处理

$$\bar{x}_i = 0.1 + \frac{(0.9 - 0.1)(x_i - x_{\min})}{x_{\max} - x_{\min}} \quad (17)$$

式中: x_i 为样本的输入或输出, \bar{x}_i 为与 x_i 对应的归一化数据, x_{\max} , x_{\min} 分别为样本的输入或输出的最大值和最小值。归一化数据可通过表达式

$$x_i = x_{\min} + \frac{(\bar{x}_i - 0.1)(x_i - x_{\min})}{(0.9 - 0.1)} \quad (18)$$

转化到实际范围。

(2) 参数的选择。

BP 网络: 选用三层 BP 网络, 输入层节点数依据样本输入向量的维数确定为 3, 输出层节点数依据样本输出向量的维数确定为 1, 对于隐含层节点数通过试凑法选取, 通过多次试验比较, 最终取为 5。CSA-SVR: 采用 CSA 优化 SVR 参数, 确定各参数取值范围: $\varepsilon \in [0.01, 0.3]$ 、 $C \in [1, 20]$ 、 $\sigma^2 \in [0.01, 0.3]$ 。CSA 的群体规模 $N=10$, 每个参数均采用 16 位二进制数表示, 则抗体二进制编码长度为 $16 \times 3 = 48$, 克隆系数 $\beta=0.9$, 变异系数 $\alpha=2$, 增补系数 $\gamma=0.3$, 终止代数 50。算法独立运行 20 次, 取最好的一次试验结果作为 CSA-SVR 参数, 参数优化过程如图 1, 最终优化结果为 $C=8.25$, $\varepsilon=0.02$, $\sigma^2=0.07$, 均方误差为 0.1626。

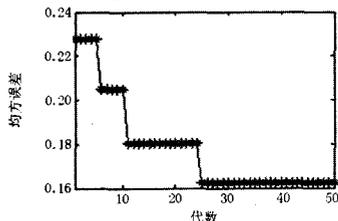


图 1 CSA 优化 SVR 参数的进化过程

Fig.1 Evolution process of CSA for optimizing SVR

(3) 试验结果与分析

BP 网络采用附加动量的 BP 学习算法训练样本数据, 学习误差小于 0.002 时, 算法停止。CSA-SVR

采用 SMO 算法训练样本数据, 全部样本数据满足 KKT 条件时, 算法停止。BP 网络和 CSA-SVR 均在选定参数下独立运算 10 次, 取最好的一次作为试验结果。

表 1 BP 网络和 CSA-SVR 拟合预测结果

Tab.1 Fitting and forecasting results of the 2 methods

年份	实际值 / 亿 kWh	BP 网络		CSA-SVR	
		预测值 / 亿 kWh	相对误差 / (%)	预测值 / 亿 kWh	相对误差 / (%)
81	94.25	92.33	2.03	99.93	2.84
82	100.29	98.21	2.06	105.33	5.03
83	108.15	101.46	5.92	108.96	0.75
84	116.37	107.96	7.88	113.18	2.73
85	124.92	116.31	6.47	123.30	1.28
86	129.83	128.91	0.72	135.59	4.44
87	151.12	141.92	6.17	145.89	3.45
88	159.92	151.88	5.02	161.48	0.98
89	172.67	170.21	1.42	171.14	0.88
90	177.11	178.75	0.93	182.94	3.29
91	188.15	187.10	0.55	191.42	1.74
92	194.37	197.16	1.43	202.39	4.12
93	218.91	213.06	2.66	212.04	3.13
94	247.55	226.38	8.55	240.65	2.78
95	273.50	291.33	6.52	269.23	1.55
96	292.10	320.47	9.71	292.06	0.01
97	299.17	330.98	10.63	302.66	1.16
98	304.08	329.76	2.03	305.40	0.43

表 1 列出了 BP 网络和 CSA-SVR 对年用电量的预测结果和相对误差。不难看出, 对于前 14 个训练样本, CSA-SVR 拟合的相对误差最大值为 5.03%, 而 BP 网络拟合的相对误差最大值为 7.88%; 对于后 4 个测试样本, CSA-SVR 预测的相对误差最大值为 1.55%, 而 BP 网络预测的相对误差最大值为 10.63%, 数据表明基于 CSA-SVR 的年用电量预测性能明显要优于 BP 网络。

图 2 对 BP 网络和 CSA-SVR 拟合预测结果及实际年用电量作了对比。图 3 对 BP 网络和 CSA-SVR 拟合预测结果相对误差进行了比较。图 2 和图 3 更清晰地表明应用 CSA-SVR 求解年用电量预测问题比 BP 网络具有更好的性能, 可应用于实际的预测工作。

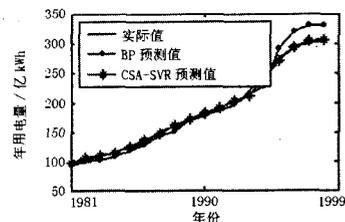


图 2 BP 网络和 CSA-SVR 拟合预测结果

Fig.2 Fitting and forecasting results of the 2 methods

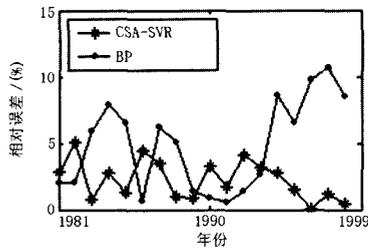


图3 BP网络和CSA-SVR拟合预测相对误差对比

Fig.3 Fitting and forecasting relative error of the 2 methods

5 结论

鉴于 SVR 性能很大程度上取决于相关参数的选择,文中将上述问题看作一个由 SVR 相关参数构成的组合优化问题,建立了该组合优化问题的数学模型,采用 CSA 求解该问题,进而优选 SVR 相关参数,形成 CSA-SVR,并将 CSA-SVR 用于解决年电力需求预测问题。试验表明,应用 CSA-SVR 解决年电力需求预测问题具有较高的精度,为该问题的解决提供了一个新的思路和途径,具有一定理论意义和实用价值。

参考文献

- [1] 王成山,杨军,张崇见. 灰色系统理论在城市年用电量预测中的应用-不同预测方法的比较[J]. 电网技术,1999,23(2):15-18.
Wang C S, Yang J, Zhang C J. The Application of Grey System Theory in City Electricity Demand Forecasting[J]. Power System Technology, 1999,23(2):15-18.
- [2] Metaxiotis K, Kagiannas A, Askounis A, et al. Artificial Intelligence in Short Term Electric Load Forecasting: a State-of-the-art Survey for the Researcher[J]. Energy Conversion and Management, 2003,44:1525-1534.
- [3] 何飞,张国忠,刘亚.基于 BP 网络的改进负荷预测方法[J]. 华东电力,2004,32(3):31-33.
He F, Zhang G Z, Liu Y. Improved Load Forecasting Method Based on BP Network[J]. East China Electric

- Power, 2004,32(3):31-33.
- [4] Vapnik V N. An Overview of Statistical Learning Theory[J]. IEEE Trans on Neural Networks, 1999,10(5): 988-999.
- [5] 王晓红,吴德会. 一种基于最小二乘支持向量机的年电力需求预测方法[J]. 继电器,2006,34(16):74-78.
Wang X H, Wu D H. Annual Electric Consumption Forecasting Model Based on Least Square Support Vector Machines[J]. Relay, 2006,34(16):74-78.
- [6] 熊建秋,邹长武,李祚泳. 基于免疫进化支持向量机的年用电量预测[J]. 四川大学学报, 2006,38(2):6-10.
Xiong J Q, Zou C W, Li Z Y. The Long Term Prediction of Annual Electricity Consumption Based on IEA-SVM Model[J]. Journal of Sichuan University, 2006,38(2):6-10.
- [7] Wang X, Yang C H, Qin B, Gui W H. Parameter Selection of Support Vector Regression Based on Hybrid Optimization Algorithm and Its Application[J]. Journal of Control Theory and Applications, 2005, 4: 371-376.
- [8] Wang X, Yang C H, Qin B, Gui W H. Parameter Selection of Support Vector Regression Based on Hybrid Optimization Algorithm and Its Application[J]. Journal of Control Theory and Applications. 2005,4:371-376.
- [9] De Castro L N, Von Zuben F J. Learning and Optimization Using the Clonal Selection Principle[J]. IEEE Trans on Evolutionary Computation, 2002, 6(3): 239-251.
- [10] De Castro L N, Von Zuben F J. The Clonal Selection Algorithm with Engineering Applications[A]. In: Proc of GECCO'00, Workshop on Artificial Immune Systems and Their Applications[C]. 2000: 36-37.

收稿日期: 2008-01-18

作者简介:

孙成发(1965-),男,高级工程师,研究方向为电力系统自动化及继电保护; E-mail: suncf2000@163.com

高辉(1969-),男,博士,研究方向为智能控制及电力系统自动化。

《继电器》杂志更名为《电力系统保护与控制》

根据新闻出版总署文件(新出报刊[2008]647号)——关于同意《继电器》更名的批复,同意《继电器》更名为《电力系统保护与控制》,新编国内统一连续出版物号:CN41-1401/TM, 办刊宗旨及业务范围调整为:关注科学发展,理论联系实际,面向应用,为科研生产一线服务,主要刊发涉及电力系统保护与控制专业领域的新技术、新成果及运行经验、技术改进、科学管理、技术规程、国外先进技术等方面的论文。

欢迎从事电力科研、设计及设备研制企事业单位的专业技术人员,全国所有高校相关专业的师生,发电厂、变电站所、输配电系统及供电企业的专业技术人员,从事电力生产、建设及经营管理部门的相关人员积极投稿,继续关注和支持本刊的建设和发展,共同将《电力系统保护与控制》杂志办得越来越好!