

基于复 Gaussian 小波 SVM 的短期负荷预测

郑永康¹, 郝文斌¹, 刘俊丽², 李梓玮¹

(1. 成都市电业局, 四川 成都 610000; 2. 德阳市电业局, 四川 德阳 610000)

摘要:提出了复 Gaussian 小波 SVM 模型, 并将其应用于对电力系统短期负荷的预测。证明了复 Gaussian 小波核满足 SVM 平移不变核条件, 建立了相应的 SVM, 并且使用搜寻者优化算法对相关参数进行优化选择。在短期负荷预测的仿真实验中, 通过与常用的径向基核 SVM 模型的对比, 验证了该方法具有较好的精确度和有效性, 有一定的实用价值。

关键词:短期负荷预测; 复 Gaussian 小波; 支持向量机 (SVM); 搜寻者优化算法 (SOA)

Abstract: A new model of short-term load forecasting (STLF) based on complex Gaussian wavelet support vector machine (CGW-SVM) is presented. It is proved that the complex Gaussian wavelet is an admissible translation-invariant kernel function of support vector machine (SVM). CGW-SVM is constructed and its parameters are optimized using seeker optimization algorithm (SOA). The comparison results for STLF show that the proposed method has better performance than the conventional radial basis function SVM (RBF-SVM) in effectiveness and accuracy and is promising in STLF problem.

Key words: short-term load forecasting; complex Gaussian wavelet; support vector machine (SVM); seeker optimization algorithm (SOA)

中图分类号: TM715 **文献标识码:** A **文章编号:** 1003-6954(2009)02-0058-04

短期负荷预测 (short-term load forecasting, STLF) 是电力系统的一项基本工作, 直接影响着系统开停机的宏观调控。负荷预测的精度关系到整个电力系统运行的经济效益, 是一个值得深入研究的课题。由于负荷受到各种社会、自然因素影响, 模糊、非线性、强扰动是其最大特点, 难于精确建模。许多传统的方法, 包括: 时间序列法、回归法、卡尔曼滤波法、自回归法等都被用于 STLF^[1, 2], 并取得了一定的效果。但这些方法基本上是线性的, 难以获得短期负荷时间序列中的非线性特征。人工神经网络 (artificial neural networks, ANN) 也被大量用于 STLF^[3, 4]。ANN 具有较强的非线性映射能力, 但是由于它采用的是结构风险最小化原则 (empirical risk minimization, ERM), 算法结果并不理想。

近年来, 支持向量机 (support vector machine, SVM) 在电力系统负荷预测中得到广泛应用^[5~8]。SVM 算法基于统计学习理论^[9] (statistical learning theory, SLT), 遵循结构风险最小化 (structural risk minimization, SRM) 准则, 通过核函数的映射, 将原空间的非线性问题转化成特征空间中的线性问题^[10], 实现小样本下的机器学习。SVM 不仅可从理论上保证收敛到全局最优点, 并且能有效地避免维数灾难问题。文献 [5~8] 都选用了径向基核函数 SVM (radial

basis function SVM, RBF-SVM) 进行 STLF。对于 SVM 模型参数的选择, 文献 [5, 7, 8] 采用了经验取值的方法, 文献 [6] 对多个参数分别给出了相应的近似算法。这些优化方法都难以得到普遍适用的满意结果。

为了利用小波在提取非线性非平稳信号高频细微特征方面的优势, 故选用复 Gaussian 小波作为 SVM 的核函数, 构建了相应的复 Gaussian 小波 SVM (complex Gaussian wavelet SVM, CGW-SVM)。针对 SVM 的参数选择, 文中使用了搜寻者优化算法 (seeker optimization algorithm, SOA) 进行优化。最后对澳大利亚新南威尔士州每半小时的电力负荷 (<http://www.nemmco.com.au>) 进行预测, 结果验证了该小波核函数及其参数优化方法的有效性和优越性。

1 复 Gaussian 小波支持向量机

根据张量积理论^[11], 对于一维母小波函数 $\psi(x)$, 可分离的 d 维小波函数为 $\psi_d(x) = \prod_{i=1}^d \psi(x_i)$ 。以其构建的平移不变小波核函数可以表示为: $k(x, x') = \prod_{i=1}^d \psi\left(\frac{x_i - x'_i}{a}\right)$ 。

一个函数只要满足 Mercer 条件就是一个可容许的 SVM 核。但是对于平移不变函数, 将其分解为两个相同函数的点积形式比较困难, 文献 [12] 给出了平移不变核函数的充要条件:

定理: 平移不变核函数 $k(x, x')$ 是可容许的支持向量核, 当且仅当 $k(x)$ 的傅里叶变换

$$F[k(\omega)] = (2\pi)^{-d/2} \int_{R^d} \exp(-j\omega x) k(x) dx \quad (1)$$

为非负数。

1.1 复 Gaussian 小波核

复 Gaussian 小波由复 Gaussian 函数的 n 阶导数构成, 定义如下: $\psi(t) = C_n \frac{d^n}{dx^n} (e^{-x} e^{-x^2})$, 其中 C_n 为常数, 是用来保持小波函数的能量归一化特性。在文中, 令 $C_n = 1$ 不会影响小波核函数的性能。取复 Gaussian 函数 1 阶导数的虚部, 得到如下复 Gaussian 小波:

$$f(x) = (-\cos x + 2x \sin x) \exp(-x^2) \quad (2)$$

则平移不变复 Gaussian 小波核函数定义如下:

$$k(x, x') = \prod_{i=1}^d \left(-\cos \frac{x_i - x'_i}{a} + 2 \frac{x_i - x'_i}{a} \sin \frac{x_i - x'_i}{a} \right) \times \exp\left(-\frac{\|x_i - x'_i\|^2}{a^2}\right) \quad (3)$$

当 d 为大于零的偶数时, 该平移不变小波核函数是可容许的支持向量核函数, 证明如下。

证明: 将

$$\begin{aligned} k(x) &= \prod_{i=1}^d \psi\left(\frac{x_i}{a}\right) \\ &= \prod_{i=1}^d \left(-\cos \frac{x_i}{a} + 2 \frac{x_i}{a} \sin \frac{x_i}{a} \right) \exp\left(-\frac{\|x_i\|^2}{a^2}\right) \end{aligned}$$

代入 (1) 式积分项可得

$$\begin{aligned} &\int_{R^d} \exp(-j(\omega x)) k(x) dx = \\ &\int_{R^d} \exp(-j(\omega x)) \prod_{i=1}^d \left(-\cos \frac{x_i}{a} + 2 \frac{x_i}{a} \sin \frac{x_i}{a} \right) \exp\left(-\frac{\|x_i\|^2}{a^2}\right) dx \\ &= \prod_{i=1}^d \int_{-\infty}^{+\infty} \exp(-j(\omega x_i)) \left(-\cos \frac{x_i}{a} + 2 \frac{x_i}{a} \sin \frac{x_i}{a} \right) \exp\left(-\frac{\|x_i\|^2}{a^2}\right) dx \\ &= \prod_{i=1}^d \left[-a^2 \sqrt{\pi} \omega \sinh(\omega a/2) \exp(-1/4 - \omega^2 a^2/4) \right] \\ &= (-1)^d \prod_{i=1}^d a^2 \sqrt{\pi} \omega \sinh(\omega a/2) \\ &\times \exp(-1/4 - \omega^2 a^2/4) \end{aligned} \quad (4)$$

代入 (1) 得

$$F[k(\omega)] = (2\pi)^{-d/2} \times (-1)^d \times \prod_{i=1}^d a^2 \sqrt{\pi} \omega \sinh(\omega a/2) \exp(-1/4 - \omega^2 a^2/4)$$

显然, 当 d 为大于零的偶数时, $F[k(\omega)] \geq 0$, 得证。

1.2 支持向量机

在样本集 $\{(x_i, y_i), i=1, 2, \dots, n\}$ 中, $x_i \in R^d$ 为输入, y_i 为对应的输出, 定义 ϵ -不敏感损失函数:

$$|y - f(x)|_\epsilon = \begin{cases} 0 & , |y - f(x)| \leq \epsilon \\ |y - f(x)| - \epsilon & , |y - f(x)| > \epsilon \end{cases} \quad (5)$$

根据 SVM 构造如下回归估计函数:

$$f(x) = \langle w \cdot \Phi(x) \rangle + b \quad (6)$$

式中 $\Phi(x)$ 为从输入空间到高维特征空间的非线性映射, w 为权值系数, b 为偏差。

优化目标是:

$$\begin{aligned} \min_{w, b, \xi} & \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{s. t. } & |y_i - \langle w \cdot \Phi(x_i) \rangle - b| \leq \epsilon + \xi_i \\ & \xi_i \geq 0, \xi_i^* \geq 0, i=1, 2, \dots, n \end{aligned} \quad (7)$$

松弛变量 ξ_i, ξ_i^* 和惩罚因子 c 用于调节超出 ϵ 管道的样本点。引入 Lagrange 乘子, 把这个不等式约束下的优化问题转化成无约束二次规划问题进行求解, 形式如下:

$$\max_{\alpha, \alpha^*, \beta, \beta^*} \left[\min_{w, b, \xi} [L(w, b, \xi, \xi^*)] \right] \quad (8)$$

其中: $L(w, b, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n$

$$\begin{aligned} &\alpha_i (\epsilon + \xi_i) \\ &- (y_i - \langle w \cdot \Phi(x_i) \rangle - b) - \sum_{i=1}^n \alpha_i^* (\epsilon + \xi_i^*) \\ &+ (y_i - \langle w \cdot \Phi(x_i) \rangle - b) - \sum_{i=1}^n (\beta_i \xi_i + \beta_i^* \xi_i^*) \end{aligned}$$

式中 $\alpha_i, \alpha_i^*, \beta_i, \beta_i^*, i=1, 2, \dots, n$ 是 Lagrange 乘子。

根据鞍点定理, 对 $L(w, b, \xi, \xi^*)$ 分别求 w, b, ξ, ξ^* 的偏导数并令其为零, 将所得结果代入到 (8) 式可以把原问题转化它的对偶问题:

$$\begin{aligned} \max_{\alpha, \alpha^*, \beta, \beta^*} & \left\{ -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n [(\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j)] \right. \\ & \left. - \epsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \right\} \\ \text{s. t. } & \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0, \quad 0 \leq \alpha_i \leq C, \quad 0 \leq \alpha_i^* \leq C \end{aligned} \quad (9)$$

根据 KKT (Karush-Kuhn-Tucker) 条件 [9] 下面关系成立:

$$\begin{cases} \alpha_i [\epsilon + \xi_i - (y_i - \langle w \cdot \Phi(x_i) \rangle - b)] = 0 \\ \alpha_i^* [\epsilon + \xi_i^* - (y_i - \langle w \cdot \Phi(x_i) \rangle - b)] = 0 \end{cases} \quad (10)$$

α_i, α_i^* 必有一个为零, 或者均为零。 $\alpha \neq 0$ 对应

的样本点 x_i 称作支持向量, 求解实际只针对支持向量。这样, 就得到 SVM 的回归估计函数:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle \Phi(x_i) \cdot \Phi(x) \rangle + b$$

$$= \sum_{x \in SV} (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (11)$$

其中 K 为核函数, 采用不同的核函数可以构建不同的 SVM, 常用的核函数为 Gaussian 核。这里选用复 Gaussian 小波核 $K(x, x_i) = \exp(-((x - x_i) / a)^2)$ 函数, 构成 CGW-SVM。

2 搜寻者优化算法

SVM 参数的选择实质上是最小化泛化误差, 一般使用遗传算法和粒子群 (particle swarm optimization PSO) 算法进行参数的寻优。文献 [13, 14] 提出了一种新的优化算法: SOA。SOA 模拟人的智能搜索行为, 将其应用于优化问题的求解。

2.1 SOA 算法原理

在搜索连续空间, 较优解的邻域内可能存在更优的解。因此, 当搜寻者即个体所处位置较优时, 应该在较小邻域内进行搜索; 而当搜寻者所处位置较差时, 应该在较大邻域内搜索。因此, SOA 利用描述自然语言和不确定性推理的模糊逻辑来对上述搜索规则进行建模。同时, SOA 通过社会学习和认知学习来获取社会经验和认知经验, 在结合智能群体的利他行为、利己行为和预动行为的基础上, 确定个体的搜索行为。SOA 算法流程如下:

- 1) $t=0$;
- 2) 在搜索空间内均匀随机地产生初始位置 p ;
- 3) 评价每个搜索者的位置;
- 4) 对每一个个体 i 每一维 j 上分别计算搜索方向 $d_{ij}(t+1)$ 和步长 $\alpha_{ij}(t+1)$;
- 5) 根据式 (12) 和 (13), 更新每一个个体的位置为 $\bar{x}(t+1)$;
- 6) $t=t+1$;
- 7) 若不满足进化结束条件 $t=T_{max}$ 则转 3), 否则输出结果。

$$x_{ij}(t+1) = x_{ij}(t) + \Delta x_{ij}(t+1) \quad (12)$$

$$\Delta x_{ij}(t+1) = \alpha_{ij}(t+1) d_{ij}(t+1) \quad (13)$$

在算法开始前每一个个体都定义了一个邻域, 以此来实现信息的社会共享。根据种群索引将种群分为三个子群, 同一子群中的所有个体构成一个邻域。

每次迭代中, 各子群中最差的两个个体替换成其它两个子群中最好的个体。

2.2 搜索步长的确定

SOA 搜索步长的模糊变量采用高斯隶属函数, 如式 (14) 所示。显然, 输出变量超出 $[u - 3\delta, u + 3\delta]$ 时, 其隶属度小于 0.0111, 设定最小隶属度 $\mu_{min} = 0.0111$ 。

$$\mu_i = e^{-((x_i - u) / \delta)^2 / 2\delta^2} \quad (14)$$

根据目标函数值的优劣递减排序, 对应序列号为 1 到 s (s 是种群大小)。目标函数的模糊变量采用线性隶属函数, 使隶属度直接与函数值的排列顺序成正比。设在最佳位置有最大隶属度值 $\mu_{max} = 1.0$, 最差位置有最小值 μ_{min} 如式 (15) 所示。

$$\mu_i = \mu_{max} \frac{s - I_i}{s - 1} (\mu_{max} - \mu_{min}) \quad (15)$$

其中, I_i 是种群函数值按降序排列后 $\bar{x}(t)$ 的序列编号。根据式 (16) 的不确定推理的行为部分可得出步长。

$$a_{ij}(t) = \delta_{ij} (-2 \times 1_n(\mu_i))^{1/2} \quad (16)$$

高斯隶属函数参数 δ_{ij} 由式 (17) ~ (19) 确定。

$$\delta_i = \omega \times \text{abs}(\bar{x}_{max} - \bar{x}_{min}) \quad (17)$$

$$\omega = (T_{max} - t) / T_{max} \quad (18)$$

$$\delta_{ij} = \text{RAND}(0, \delta_i) \quad (19)$$

其中, \bar{x}_{min} 和 \bar{x}_{max} 分别是同一子群中的最小和最大函数值的位置; ω 是惯性权值; t 和 T_{max} 分别为当前迭代次数和最大迭代次数; $Y = \text{abs}(X)$ 返回一个数组 Y , 使 Y 的每一个元素是 X 与其对应的元素的绝对值。式 (19) 是为了模拟人的搜索行为的随机性。

2.3 搜索方向的确定

搜索方向由利己行为、利他行为和预动行为共同决定, 如式 (23) 所示。 $d_{p, \text{ogg}}$ 、 $d_{p, \text{ego}}$ 和 $d_{p, \text{pm}}$ 分别为第 i 个搜寻者根据利他行为、利己行为和预动行为确定的利他方向、利己方向和预动方向。

$$\bar{d}_{p, \text{alt}} = \bar{g}_{\text{best}} - \bar{x}_i(t) \quad (20)$$

$$\bar{d}_{p, \text{ego}} = \bar{g}_{\text{best}} - \bar{x}_i(t) \quad (21)$$

$$d_{p, \text{pm}} \begin{cases} \bar{x}_i(t) - \bar{x}_i(t-1) \text{ if } \text{fun}(\bar{x}_i(t)) \leq \text{fun}(\bar{x}_i(t-1)) \\ \bar{x}_i(t-1) - \bar{x}_i(t) \text{ if } \text{fun}(\bar{x}_i(t)) > \text{fun}(\bar{x}_i(t-1)) \end{cases} \quad (22)$$

$$\bar{d}_i(t) = \text{sign}(\omega \bar{d}_{p, \text{pm}} + \omega_1 \bar{d}_{p, \text{ego}} + \omega_2 \bar{d}_{p, \text{alt}}) \quad (23)$$

其中, \bar{g}_{best} 为第 i 个搜寻者所在邻域的集体历史最佳位置, \bar{g}_{best} 为第 i 个搜寻者到目前为止经历过的

最佳位置, $\text{fun}(\cdot)$ 为最小问题目标函数, $\text{sign}(\cdot)$ 表示输入矢量每一维的符号函数, φ_1 和 φ_2 是在已知区间 $[0, 1]$ 内被均匀、随机选择的实数, 是如 (18) 式所示的惯性权值。

3 应用实例

采用前面提出的 CGW-SVM 方法和常用的 RBF-SVM 方法, 对澳大利亚新南威尔士州 2006 年 7 月 23 日每半小时的负荷进行预测, 实验所用的原始数据是该地区 7 月份每半小时的负荷。对负荷进行归一化处理, 按文献 [15] 的方法进行相空间重构。取预测日前 10 天的数据进行训练, 用 SOA 进行 SVM 参数优化, 用平均绝对百分比误差 E_{mape} 作为参数评价的依据。

3.1 数据预处理

首先对负荷进行归一化处理, 搜寻该负荷时间序列 $x(k)$ 中的最大值 x_{max} 和最小值 x_{min} , 则归一化后的 $x(k)$ 为:

$$x(k) = \frac{x(k) - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (24)$$

根据文献 [15] 提出的方法, 将该负荷时间序列重构为 6 维向量点作为支持向量机的输入, 并得到其对应的输出参量。

3.2 参数选取

使用 SOA 对参数进行优化选择, 绝对百分比误差 E_{mape} 作为判断参数优劣的条件。 E_{mape} 定义为:

$$E_{\text{mape}} = \frac{1}{N} \sum_{i=1}^N \frac{|f_i - y_i|}{y_i} \times 100\% \quad (25)$$

其中, f_i 和 y_i 分别表示预测值和实际值, N 是预测值的个数。

针对 CGW-SVM 和 RBF-SVM 的宽度参数 a 惩罚因子 C 管道半径 ϵ 等参数, 分别设置寻优区间为: $a \in [1, 100]$; $C \in [10^2, 10^{10}]$; $\epsilon \in [0.0001, 0.1]$ 。

用 SOA 和 PSO 优化算法 [16] 对比实验, 种群个数均取为 20 个。多次独立试验表明, SOA 算法平均在进化到 17 代时能获得最优值, 而 PSO 算法需要进化到 31 代左右才能取得最优值。

通过优化学习, 对于 CGW-SVM, 得到如下参数: $a=19.6733$, $C=2.8 \times 10^7$, $\epsilon=0.014$; 对于 RBF-SVM, 优化后的参数为: $a=2.4$, $C=3.7 \times 10^4$, $\epsilon=0.009$ 。

3.3 预测结果

图 1 给出了 CGW-SVM 和 RBF-SVM 的预测结果, 图 2 给出了相应的预测误差。表 1 给出了平均绝对百分比误差 E_{mape} 、最大相对误差 E_{max} 和支持向量个数 N_{sv} 。可以看出: 经过 SOA 优化参数的 SVM 模型都能取得比较好的预测效果, 但 CGW-SVM 模型效果更好, 其 E_{mape} 和 E_{max} 值都相对较小; 另外, CGW-SVM 的支持向量数比 RBF-SVM 多 21 个。




图 1 实际负荷值及 CGW-SVM 和 RBF-SVM 预测负荷曲线图

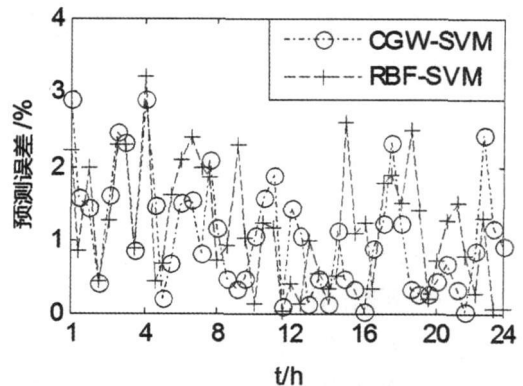


图 2 对应图 1 的预测误差

表 1 负荷预测结果

结果	$E_{\text{mape}}(\%)$	$E_{\text{max}}(\%)$	N_{sv}
CGW-SVM	1.09	2.91	274
RBF-SVM	1.17	3.22	253

4 结论

前面尝试将复 Gaussian 小波理论与核函数方法相结合, 构造 CGW-SVM 进行 STLF。通过对“1 阶复 Gaussian 小波在输入向量维数为偶数时, 满足 SVM 平移不变核函数条件”这一命题的证明, 表明它可以作为 SVM 的核函数使用; 将该小波 SVM 应用于 STLF, 前面使用 SOA 进行 SVM 参数的优化。从仿真结果可以看出: 提出的 CGW-SVM 的预测效果优于

(下转第 94 页)

再热蒸汽温度和炉膛燃烧室温度无法控制,漏出的冷却水进入外置床后,还将导致外置床内灰渣结成块,堵塞外置床及其进灰管道,引起故障停炉,也给检修带来麻烦。遇到这种情况,立即将泄漏灰控阀冷却水回水直接排到地沟,尽可能降低冷却水出水背压,并调整灰控阀冷却水进水量,防止大量冷却水漏入外置床,待停炉后进行检修。切不可关闭冷却水水源继续运行,否则阀杆在高温下弯曲或断裂,将给运行和检修带来较大困难。

4 结 论

灰控阀是大型循环流化床的一个重要控制设备,正确运行和维护好灰控阀,有利于大型循环流化床锅炉安全稳定运行。

作者简介

王永龙(1972—),男,四川内江人,大学本科学历,助理工程师、技师,四川白马循环流化床示范电站有限责任公司,从事 300MW 循环流化床机组机务方面的检修维护技术管理工作。

(收稿日期:2008—09—25)

(上接第 61 页)

常用的 RBF-SVM,并且 SOA 与 PSO 优化算法相比,能更快地得到优化的 SVM 参数。因此,其研究成果初步展示出基于 CGW-SVM 的 STLF 和 SOA 参数优化方法的有效性和优越性,具有一定的理论意义和实用价值。

参考文献

- [1] I Moghram, S Rahman. Analysis and evaluation of five short-term load forecasting techniques [J]. IEEE Trans Power Syst 1989; 1484—1491.
- [2] 刘晨晖. 电力系统负荷预报理论与方法 [M]. 哈尔滨: 哈尔滨工业大学出版社, 1987.
- [3] 邵能灵, 侯志俭. 小波模糊神经网络在电力系统短期负荷预测中的应用 [J]. 中国电机工程学报, 2004, 24(1): 24—29.
- [4] Topalli AK, Erkmen I. A hybrid learning for neural networks applied to short term load forecasting [J]. Neurocomputing 2003, 51: 495—500.
- [5] 李元诚, 方廷健, 于尔铿. 短期负荷预测的支持向量机方法研究 [J]. 中国电机工程学报, 2003, 23(6): 55—59.
- [6] 谢 宏, 魏江平, 刘鹤立. 短期负荷预测中支持向量机模型的参数选取和优化方法 [J]. 中国电机工程学报, 2006, 26(22): 17—22.
- [7] Zhang Ming-guang. Short-term load forecasting based on support vector machines regression [J]. Proceedings of the Fourth International Conference on Machine Learning and Cybernetics Guangzhou 2005, 8: 4310—4314.
- [8] 姜惠兰, 刘晓津, 关颖等. 基于硬 C 均值聚类算法和支持向量机的电力系统短期负荷预测 [J]. 电网技术, 2006, 30(8): 81—85.
- [9] Vapnik V. N. Statistical learning theory [M]. New York:

Springer-Verlag 2000.

- [10] Nello C. John S T. An introduction to support vector machines and other kernel-based learning methods [M]. UK: Cambridge University Press 2000.
- [11] Burges C. J. C. Geometry and invariance in kernel based methods [A]. Advance in Kernel Methods—support Vector Learning[C]. Cambridge MIT Press 1999; 89—116.
- [12] Zhang Li, Zhou Wei-da, Jiao Li-cheng. Wavelet support vector machine [J]. IEEE Transactions on systems man and cybernetics—Part B: cybernetics 2004, 34(1): 34—39.
- [13] Dai Chao-hua, Zhu Yun-fang, Chen Wei-rong. Seeker optimization algorithm [J]. Proc 2006 Inter Conf Computational Intelligence and Security, Guangzhou, China, IEEE, 2006, 1: 225—229.
- [14] Dai Chaohua, Zhu Yunfang, Chen Weirong. Seeker optimization algorithm for training feed-forward neural networks. IEEE Transactions on Neural Networks (revised and resubmitted).
- [15] Jiang Chuan-wen, Li Tao. Forecasting method study on chaotic load series with high embedded dimension [J]. Energy Conversion and Management 2005, 46: 667—676.
- [16] Y Shi and R Eberhart. Empirical study of particle swarm optimization [J]. in Proc of the 1999 Congress on Evolutionary Computation. pp 1945—1950.

作者简介:

郑永康(1977—),男,博士,研究方向为电力系统负荷预测、计算智能等;

郝文斌(1976—),男,博士,工程师,主要研究方向为电力系统继电保护、变电所综合自动化及调度管理系统等。

(收稿日期:2008—12—03)