

短期负荷预测的集成改进极端学习机方法

程松¹, 闫建伟¹, 赵登福¹, 王圉², 王海明²

(1. 西安交通大学电气工程学院, 710049, 西安; 2. 河南省电力公司新乡供电公司, 453000, 河南新乡)

摘要: 首次将极端学习机(ELM)理论引入短期负荷预测领域,并以 BFGS 拟牛顿法对 ELM 网络左侧权值进行优化训练调整,形成基于迭代-解析的改进 ELM 预测模型.同时,采用集成技术 Boosting 算法,生成多个差异度大的改进 ELM 子网络,对其进行加权组合,构建了集成改进极端学习机预测模型.该模型不仅有效避免了极端学习机左侧权值随机给定的输出稳定性问题,而且克服了单一网络预测模型泛化能力较差等缺陷.

关键词: 极端学习机;短期负荷预测;训练;集成技术

中图分类号: TM715 **文献标志码:** A **文章编号:** 0253-987X(2009)02-0106-05

Short-Term Load Forecasting Method Based on Ensemble Improved Extreme Learning Machine

CHENG Song¹, YAN Jianwei¹, ZHAO Dengfu¹, WANG Quan², WANG Haiming²

(1. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. Xinxiang Power Supply Company, Electric Power of Henan, Xinxiang, Henan 433000, China)

Abstract: The extreme learning machine (ELM) theory is introduced into the domain of short-term load forecasting, and an ELM forecasting model is developed based on iteration-parse via optimizing, training and rectifying the left weights with BFGS quasi-Newton method. Adopting boosting algorithm of ensemble technology, several quite different ELM child-networks are generated and weighted, and a forecasting model of ensemble improved ELM are constructed. This model avoids effectively the output unstability from the left weights given arbitrarily, and breaks such limitations as weak generalization capability of single network model.

Keywords: extreme learning machine; short-term load forecasting; training; ensemble technology

短期负荷预测是电力系统日常运行中的一项基础工作,精确的负荷预测对于电力系统安排生产、经济调度和安全分析都具有十分重要的意义.对于短期负荷预测理论和方法,国内外学者做了大量研究^[1-3],其主要方法有:基于回归分析、时间序列的传统预测方法和以人工神经网络(ANN)^[4]为代表的人工智能预测方法.传统预测方法由于预测模型过于简单,难以描述影响因素与负荷变化规律之间复杂的非线性关系,虽然 ANN 短期负荷预测模型研究和应用较多,但存在训练速度慢、局部最优及过拟

合等问题.

极端学习机^[5]理论是南洋理工大学 Huang 博士于 2006 年提出的一种人工神经网络模型训练新算法,它将传统的 ANN 参数训练问题转化为不相容线性方程组求解问题,依据摩尔-彭罗斯广义逆(MP)^[6]矩阵理论,解析求得该方程组具有最小范数的最小二乘解作为网络右侧权值参数,可很好地克服一般 ANN 预测模型存在的训练时间长、易产生过拟合等问题.但是,极端学习机方法因左侧权值随机给定,使回归模型易产生泛化能力与稳定性不理

想等问题. 本文提出基于迭代-解析的改进极端学习机(ELM)网络模型,以 BFGS 拟牛顿法对网络左侧权值进行训练调整,右侧权值利用解析方法求得,在此基础上进一步通过集成技术 Boosting 算法生成多个 ELM 个体,构造集成改进极端学习机(EI-ELM)预测模型,该预测模型不仅兼顾了 ANN 和 ELM 的各自优点,同时提高了预测模型的稳定性与泛化能力.

1 极端学习机理论

极端学习机是一种 ANN 网络训练新算法,预测模型仍采用前向单隐层结构,如图 1 所示.




图 1 极端学习机网络结构图

设其中输入层、隐含层和输出层的节点数分别为 $n, \bar{N}, m$, 神经元函数为 $g(x)$, 阈值为 b_i , 样本数目为 N , 每个样本表示为 $(\mathbf{X}_i, \mathbf{Y}_i)$, $i=1, 2, \dots, N$, 其中, $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 为输入变量, $\mathbf{Y}_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in R^m$ 为输出变量.

如果设该 ELM 网络输出值为 $\mathbf{O}_j = [o_{j1}, o_{j2}, \dots, o_{jm}]^T \in R^m$, 则网络数学模型可表示为

$$\sum_{i=1}^N \beta_i g(\mathbf{w}_i \mathbf{X}_j + b_i) = \mathbf{O}_j \quad j = 1, 2, \dots, N \quad (1)$$

$$\mathbf{w}_i = [\omega_{1i}, \omega_{2i}, \dots, \omega_{ni}]^T$$

$$\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T \quad i = 1, 2, \dots, \bar{N}$$

图 1 的理想目标是寻求输入输出权值,使得

$$\left. \begin{aligned} y_{j1} &= \sum_{i=1}^{\bar{N}} \beta_{i1} g\left(\sum_{k=1}^n \omega_{ki} x_{jk} + b_1\right) \\ y_{j2} &= \sum_{i=1}^{\bar{N}} \beta_{i2} g\left(\sum_{k=1}^n \omega_{ki} x_{jk} + b_2\right) \\ &\vdots \\ y_{jm} &= \sum_{i=1}^{\bar{N}} \beta_{im} g\left(\sum_{k=1}^n \omega_{ki} x_{jk} + b_N\right) \end{aligned} \right\} \quad (2)$$

表示成矩阵形式为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Y} \quad (3)$$

$$\mathbf{H}(\omega_1, \dots, \omega_N, b_1, \dots, b_N, X_1, \dots, X_N) =$$

$$\begin{bmatrix} g(\omega_1 X_1 + b_1) & \cdots & g(\omega_N X_1 + b_N) \\ \vdots & & \vdots \\ g(\omega_1 X_N + b_1) & \cdots & g(\omega_N X_N + b_N) \end{bmatrix}_{N \times N}$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}_{N \times m}; \quad \mathbf{Y} = \begin{bmatrix} \mathbf{Y}_1^T \\ \vdots \\ \mathbf{Y}_N^T \end{bmatrix}_{N \times m}$$

极端学习机的训练目标是寻求最优的网络权值 $\mathbf{W}, \boldsymbol{\beta}$, 使得网络输出值与对应实际值误差最小, 即

$$\min E(\mathbf{W}, \boldsymbol{\beta}) = \sum_{j=1}^N \|\mathbf{O}_j - \mathbf{Y}_j\| \quad (4)$$

式中: $\mathbf{W} = (\mathbf{w}_i, i=1, 2, \dots, \bar{N}; \mathbf{b}_j, j=1, 2, \dots, \bar{N})$, 包含了网络左权值参数及隐层神经元域值.

可见, ELM 网络的训练过程可归结为一个非线性优化问题, 目标函数为式(4)所示. 极端学习机理论的主要思想是在训练开始前, 将输入权值和阈值 $\mathbf{W}$ 随机给定, 此时矩阵 $\mathbf{H}$ 为一常数矩阵, 式(3)被简化成一组线性方程, 通过 MP 广义逆理论, 即可解析求得式(3)最小范数的最小二乘解, 即网络右侧权值 $\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y}$, 完成 ELM 网络训练过程. 当以上 ELM 网络输入变量由负荷、气象、日期等因素构成, 输出变量取为负荷值时, 则可构建基于 ELM 短期负荷预测模型.

2 集成改进极端学习机预测模型

2.1 基于迭代-解析的改进 ELM 模型

针对极端学习机参数 $\mathbf{W}$ 随机给定, 预测模型因受随机因素干扰导致模型预测精度稳定性问题, 本文提出了基于迭代-解析的改进 ELM 预测模型, 即 ELM 网络左侧权值及隐单元域值 $\mathbf{W}$ 通过 BFGS 拟牛顿法^[7-8]训练调整得到, 右侧权值 $\boldsymbol{\beta}$ 则通过解析 MP 广义逆求得, 这种改进兼顾到了 ELM 与 ANN 各自的优点.

采用求解非线性规划中的 BFGS 算法对极端学习机网络参数 $\mathbf{W}$ 进行优化, 即式(4)在固定右侧权值 $\boldsymbol{\beta}$ 基础上, 寻找最佳参数 $\mathbf{W}^*$, 使 $E(\mathbf{W}, \boldsymbol{\beta})$ 达到最小, 此时式(4)可简化为

$$\min E(\mathbf{W}) = \sum_{j=1}^N \|\mathbf{O}_j - \mathbf{Y}_j\| \quad (5)$$

对二阶可微的误差函数 $E(\mathbf{W})$, 其参数 $\mathbf{W} = (\mathbf{w}_i, i=1, 2, \dots, \bar{N}; \mathbf{b}_j, j=1, 2, \dots, \bar{N})$, 简记为 M 维变量 $\mathbf{W} = (\mathbf{w}_i, i=1, 2, \dots, M)$, 则它的一阶导数(梯度向量)为

$$\mathbf{g}(\mathbf{W}) = \left(\frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \dots, \frac{\partial E}{\partial w_M} \right)^T \quad (6)$$

二阶导数矩阵(Hessian 矩阵)为

$$\mathbf{G}(\mathbf{W}) = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1^2} & \frac{\partial^2 E}{\partial w_1 \partial w_2} & \cdots & \frac{\partial^2 E}{\partial w_1 \partial w_M} \\ \frac{\partial^2 E}{\partial w_2 \partial w_1} & \frac{\partial^2 E}{\partial w_2^2} & \cdots & \frac{\partial^2 E}{\partial w_2 \partial w_M} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 E}{\partial w_M \partial w_1} & \frac{\partial^2 E}{\partial w_M \partial w_2} & \cdots & \frac{\partial^2 E}{\partial w_M^2} \end{bmatrix} \quad (7)$$

BFGS 算法求解 $\mathbf{E}(\mathbf{W})$ 极小点 $\mathbf{W}^*$ 的迭代步骤(第 k 次)如下。

(1) 确定搜索方向 $\mathbf{s}^{(k)}$, 满足

$$\mathbf{B}^{(k)} \mathbf{s}^{(k)} = -\mathbf{g}^{(k)} \quad (8)$$

其中, 由给定的初始正定矩阵 $\mathbf{B}^{(1)}$ (取单位矩阵) 经迭代计算逐步进行修正。注意, $\mathbf{B}^{(k)}$ 是 Hessian 矩阵 $\mathbf{G}^{(k)}$ 的一个近似, 为对称正定矩阵, 从而使 $\mathbf{s}^{(k)\top} \mathbf{g}^{(k)} < 0$, 保证了 $\mathbf{s}^{(k)}$ 为下降方向。

(2) 沿 $\mathbf{s}^{(k)}$ 进行线性搜索, 得最优步长 $\alpha^{(k)}$, 从而得出变量的新值

$$\mathbf{W}^{(k+1)} = \mathbf{W}^{(k)} + \alpha^{(k)} \mathbf{s}^{(k)} \quad (9)$$

采用不精确搜索法, 使步长 $\alpha^{(k)}$ 满足

$$\left. \begin{aligned} \mathbf{E}(\mathbf{W}^{(k)} + \alpha^{(k)} \mathbf{s}^{(k)}) &\leq \mathbf{E}(\mathbf{W}^{(k)}) + \rho \alpha^{(k)} \mathbf{g}^{(k)\top} \mathbf{s}^{(k)} \\ |\mathbf{g}(\mathbf{W}^{(k)} + \alpha^{(k)} \mathbf{s}^{(k)})^\top \mathbf{s}^{(k)}| &\leq -\sigma \mathbf{g}^{(k)\top} \mathbf{s}^{(k)} \end{aligned} \right\} \quad (10)$$

式中: $\rho \in (0, 0.5)$; $\sigma \in (\rho, 1)$ 。

(3) 修正矩阵 $\mathbf{B}$

$$\mathbf{B}^{(k+1)} = \mathbf{B}^{(k)} + \frac{\boldsymbol{\gamma}^{(k)} \boldsymbol{\gamma}^{(k)\top}}{\boldsymbol{\delta}^{(k)\top} \boldsymbol{\delta}^{(k)}} - \frac{\mathbf{B}^{(k)} \boldsymbol{\delta}^{(k)} \boldsymbol{\delta}^{(k)\top} \mathbf{B}^{(k)}}{\boldsymbol{\delta}^{(k)\top} \mathbf{B}^{(k)} \boldsymbol{\delta}^{(k)}} \quad (11)$$

$$\left. \begin{aligned} \boldsymbol{\delta}^{(k)} &= \mathbf{W}^{(k+1)} - \mathbf{W}^{(k)} \\ \boldsymbol{\gamma}^{(k)} &= \mathbf{g}^{(k+1)} - \mathbf{g}^{(k)} \end{aligned} \right\} \quad (12)$$

迭代-解析算法的具体步骤如下:

(1) 随机给定网络的左侧权值参数及隐单元域值参数, 记为 $\mathbf{W}^{(1)} = (\mathbf{w}^{(1)}, \mathbf{b}^{(1)})$;

(2) 计算隐层输出矩阵 $\mathbf{H}$ 并解析 MP 广义逆得到输出层权值 $\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y}$;

(3) 在网络右侧权值 $\boldsymbol{\beta}$ 不变情况下调用 BFGS 优化学习算法, 求解 $\mathbf{E}(\mathbf{W})$ 极小点 $\mathbf{W}^*$;

(4) 在 $\mathbf{W}^*$ 基础上重新计算输出矩阵 $\mathbf{H}'$ 并解析得到输出层权值 $\boldsymbol{\beta}' = \mathbf{H}'^+ \mathbf{Y}$;

(5) 如果满足 $\sum_{i=1}^N \|\boldsymbol{\beta}_i - \boldsymbol{\beta}'_i\| \leq \varepsilon$, ε 为一较小正数, 则网络训练完毕, 否则令 $\boldsymbol{\beta} = \boldsymbol{\beta}'$, 返回第 3 步。

2.2 集成改进 ELM 模型

为进一步提高改进 ELM 预测模型的稳定性和

泛化能力, 本文将集成技术应用于 ELM 负荷预测模型。

使用集成技术的关键在于如何构造差异度大的 ELM 子网络, 本文采用 Boosting 算法^[9-10]生成多个差异较大且相互配合的改进 ELM 网络, 再利用各网络权因子 $\ln(1/\beta_i)$ 将它们的预测输出集成。

Boosting 算法构造 ELM 网络的步骤如下。

(1) 给定训练集 $(\mathbf{X}_i, \mathbf{Y}_i)$, $i=1, 2, \dots, N$, 最大迭代次数给定 T 。

(2) 初始化权值 $\alpha_i^1 = 1/N$, $i=1, \dots, N$ 。

(3) 迭代 $t=1, 2, \dots, T$, 计算样本的采样概率

$$p_i^t = \alpha_i^t / \sum_{j=1}^N \alpha_j^t \quad i=1, \dots, N \quad (13)$$

按照 p_i^t 概率采样产生本次迭代所需样本集合 $(\mathbf{X}^t, \mathbf{Y}^t)$, 训练生成个体网络 $h_t: \mathbf{X}^t \rightarrow \mathbf{Y}^t$, 计算 h_t 在每个训练样本上的误差

$$\epsilon_i^t = \frac{|h_t(\mathbf{X}_i) - \mathbf{Y}_i|}{\sup |h_t(\mathbf{X}_i) - \mathbf{Y}_i|} \quad i=1, 2, \dots, N \quad (14)$$

计算加权误差和

$$\epsilon_t = \sum_{i=1}^N p_i^t \epsilon_i^t \quad (15)$$

若 $\epsilon_t > 0.5$, 则终止迭代, 并转步骤 4。计算

$$\beta_t = \epsilon_t / (1 - \epsilon_t) \quad (16)$$

计算样本新权值

$$\alpha_i^{t+1} = \alpha_i^t \beta_i^{1-\epsilon_i^t} \quad (17)$$

(4) 预测日输入向量为 $\mathbf{X}_d$, 依据各网络 h_t 针对原始样本的集权因子 $\ln(1/\beta_i)$, 计算最终输出

$$h_t(\mathbf{X}_d) = \frac{\ln(1/\beta_t)}{\sum_t \ln(1/\beta_t)} h_t(\mathbf{X}_d) \quad (18)$$

2.3 基于集成改进极端学习机的负荷预测

本文以 ELM 理论建立了短期负荷预测模型, 为提高模型稳定性和泛化能力, 对其左权值提出基于 BFGS 迭代-解析算法, 并以集成技术构建组合预测模型, 基于集成改进极端学习机短期负荷预测流程如图 2 所示。

3 算例分析

本文使用 24 组集成改进极端学习机模型分别预测待预测日 24 h 的 96 点负荷值, 模型样本使用待预测日前半年负荷及气象数据, 输入变量包括预测点 2 d 前及 7 d 前相同时刻 4 个点的负荷值和该时刻前后两个时刻的平均负荷值, 预测日前 2 d 的日最高、最低和平均温度及星期类型, 输出变量为预




图 2 集成改进极端学习机方法短期负荷预测流程

测日某时刻 4 个点的负荷值,并通过对隐节点数与样本数相同的等维极端学习机网络进行训练,再对该等维网络右权值向量的模值进行有序聚类,得出相应的多个权值分割点,并将其作为集成改进极端学习机各改进 ELM 子网络的隐单元数。

本文应用日平均相对误差 δ 与负荷预测准确率 η 作为各种方法预测效果判断的依据

$$\delta = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{y_i} \right| = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{19}$$

$$\eta = \left(1 - \left(\frac{1}{n} \sum_{i=1}^n (e_i/y_i)^2 \right)^{1/2} \right) \times 100\% \tag{20}$$

式中: e_i 为第 i 个预测值和实际值的绝对误差; y_i 、 $\hat{y}_i$ 分别为第 i 个实际负荷值、预测负荷值; n 为日负荷预测总点数。

算例 1: 迭代-解析改进效果分析. 采用基于迭

代-解析的改进极端学习机(IELM)预测模型与一般 ELM 预测模型,对杭州、西安电网 2007 年的历史负荷随机选取一周进行预测对比计算,结果见表 1~表 3。

表 1 杭州电网日误差 δ 及准确率 η 的比较

星期	ELM		IELM	
	$\delta/\%$	$\eta/\%$	$\delta/\%$	$\eta/\%$
一	1.837	97.749	1.683	98.022
二	3.062	95.037	2.041	97.536
三	1.495	97.184	1.592	98.159
四	2.021	96.372	1.937	97.461
五	4.379	95.541	1.748	97.754
六	2.143	96.136	2.196	96.891
日	3.906	96.720	2.035	97.073
平均	2.691	96.391	1.890	97.558

表 2 西安电网日误差 δ 及准确率 η 的比较

星期	ELM		IELM	
	$\delta/\%$	$\eta/\%$	$\delta/\%$	$\eta/\%$
一	1.962	97.651	1.582	98.361
二	2.105	97.027	1.638	97.740
三	4.371	95.734	1.801	97.673
四	2.018	97.350	2.034	97.532
五	1.947	97.859	2.135	96.849
六	3.749	96.135	2.067	97.137
日	2.836	96.438	2.139	97.081
平均	2.712	96.885	1.914	97.481

表 3 杭州、西安电网预测时间比较

地区	预测时间/min	
	ELM	IELM
杭州	1.962	12.582
西安	1.712	11.914

由表 1 可见,IELM 模型的周平均预测误差显著降低,其中采用 IELM 法 δ 为 1.890%,比 ELM 法低 0.801%,准确率则提高了 1.167%。表 2 中 IELM 法与 ELM 法相比, δ 由 2.712%降低为 1.914%,准确率提高 0.596%。同时可以发现,采用 ELM 法预测时,会出现预测误差突然增大的现象,如表 1 星期五日平均误差为 4.379%,表 2 星期三日平均误差为 4.371%,都明显高于周平均值。虽然本文方法预测速度比 ELM 方法慢,但本文模型有效提高了一般极端学习机受随机因素影响的泛化能力。

算例 2: 集成改进效果分析. 以集成极端学习机(EELM)与 ELM 两种方法,对甘肃电网一周每日 96 点负荷进行了预测计算,结果如表 4 所示。

表4 甘肃电网一周日误差及准确率的比较

星期	ELM		EELM	
	$\delta/\%$	$\eta/\%$	$\delta/\%$	$\eta/\%$
一	2.193	96.320	1.752	97.841
二	2.547	95.741	2.147	97.365
三	3.095	95.204	2.083	97.529
四	1.730	96.826	1.865	98.032
五	5.148	94.375	2.831	96.822
六	4.211	95.652	2.410	97.036
日	4.536	95.219	2.517	96.934
平均	3.351	95.619	2.230	97.365

由表4可见,在引入集成技术后,平均误差由3.351%降低到2.230%,准确率上升1.746%,并且ELM法误差最大为5.148%,EELM法则仅为2.831%。可见,集成技术的引入可有效避免单一网络模型出现大预测偏差的问题,从而具有更高的预测精度和泛化能力。

算例3:与其他方法比较。以集成改进极端学习机(EIELM)预测模型对杭州电网2007年8月1~14日的负荷进行预测,并与ANN方法进行对比,预测误差及运算时间的比较结果如表5所示。

由表5可以看出,本文EIELM方法的 δ 为1.882%,比ANN方法降低1.157%,日误差最大

表5 杭州2007年8月1日~14日的预测结果

星期	EIELM		ANN	
	$\delta/\%$	t/min	$\delta/\%$	t/min
07-7-1	1.683	1.459	2.876	2.118
07-7-2	2.146	1.323	3.259	1.846
07-7-3	1.958	1.557	2.327	1.836
07-7-4	1.632	1.320	3.195	2.432
07-7-5	2.371	1.401	2.963	2.311
07-7-6	1.094	1.683	2.458	2.198
07-7-7	1.739	1.574	3.674	1.920
07-7-8	1.874	1.410	3.546	2.217
07-7-9	2.143	1.594	3.203	2.230
07-7-10	1.570	1.748	3.457	2.017
07-7-11	2.016	1.640	2.790	1.974
07-7-12	2.148	1.732	3.286	2.053
07-7-13	2.231	1.088	2.317	2.013
07-7-14	1.741	1.660	3.196	2.361
平均	1.882	1.514	3.039	2.109

值EIELM方法为2.371%,比ANN方法低1.303%,而运算时间EIELM方法比ANN方法则

缩短了0.595 min。可见,本文方法不仅预测精度及稳定性上要高于ANN方法,运算速度也比ANN方法快。这是因为IELM方法兼顾了ANN方法与ELM方法各自优点,预测网络更加稳定,且集成技术的引入避免了大的预测偏差,提高了网络泛化能力。另外,该改进算法只需对参数 $\mathbf{W}$ 进行训练调整,从而使网络参数的寻优相比ANN方法降到一个低维空间,迭代运算量减少。

4 结 论

本文首次将极端学习机理论引入短期负荷预测领域,并以BFGS拟牛顿方法对ELM网络左侧权值进行优化训练调整,形成基于迭代-解析的改进极端学习机预测模型,并在该模型基础上,引入集成技术Boosting算法生成多个ELM网络个体,建立了集成改进极端学习机模型。实际算例表明,本文方法不仅有效抑制了一般ELM方法预测精度不稳定的缺陷,而且相比ANN方法训练速度快、泛化能力强,具有很好的应用价值。

参考文献:

[1] 牛东晓,曹树华,赵磊,等. 电力系统负荷预测技术及其应用[M]. 北京:中国电力出版社,1998.

[2] 康重庆,夏清,刘梅. 电力系统负荷预测[M]. 北京:中国电力出版社,2007.

[3] GROSS G, GALIANA F D. Short-term load forecasting[J]. Proc IEEE, 1987, 75(12): 1537-1558.

[4] HIPPERT H S, PEDREIRA C E, SOUZA R C. Neural networks for short-term load forecasting: a review and evaluation [J]. IEEE Trans on Power Systems, 2001,16(1): 44-55.

[5] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. ScienceDirect: Neurocomputing, 2006, 70: 489-501.

[6] 程云鹏. 矩阵论[M]. 西安:西北工业大学出版社,2003.

[7] 杨冰. 实用最优化方法及计算机程序[M]. 哈尔滨:哈尔滨船舶工程学院出版社,1994.

[8] 张可村,李换琴. 工程优化方法及其应用[M]. 西安:西安交通大学出版社,2007.

[9] SCHAPIRE R E. The strength of weak learnability [J]. Machine Learning, 1990,5(2): 197-227.

[10] DRUCKER H. Improving regressors using Boosting techniques[C]//The Fourteenth International Conference on Machine Learning. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1997:107-115.

(编辑 杜秀杰)