

自适应迭代最小二乘支持向量机回归算法

杨 滨¹,杨晓伟^{1,2},黄 岚¹,梁艳春¹,周春光¹,吴春国^{1,3}

(1. 吉林大学计算机科学与技术学院, 国家教育部符号计算与知识工程重点实验室, 吉林长春 130012;

2. 华南理工大学理学院数学系, 广东广州 510640; 3. 中国科学院自动化研究所模式识别国家重点实验室, 北京 100080)

摘 要: 基于最小二乘支持向量机回归算法, 本文在前期工作的基础上进行了扩展, 提出了更加详尽的自适应迭代最小二乘支持向量机回归算法. 与标准的 LSSVR 相比, 本文提出的算法在学习新样本的时候利用了已有的学习结果, 可以快速获得新的学习机. 模拟结果表明, 自适应迭代最小二乘支持向量机回归算法能够自适应地确定支持向量的数目, 保留了 QP 方法在训练 SVM 时支持向量的稀疏性, 在相近的回归精度下, 该算法极大地提高了标准 LSSVR 学习的速度.

关键词: 支持向量机; 自适应; 迭代; 回归; 最小二乘

中图分类号: TP18 **文献标识码:** A **文章编号:** 0372-2112 (2010) 07-1621-05

Adaptive and Iterative Training Algorithm of Least Square Support Vector Machine Regression

YANG Bin¹, YANG Xiao-wei^{1,2}, HUANG Lan¹, LIANG Yan-chun¹, ZHOU Chun-guang¹, WU Chun-guo^{1,3}

(1. College of Computer Science and Technology, Jilin University, Key Laboratory of Symbol Computation and Knowledge Engineering of the Ministry of Education, Changchun, Jilin 130012, China;

2. Department of Mathematics, School of Sciences, South China University of Technology, Guangzhou, Guangdong 510640, China;

3. National Laboratory of Pattern Recognition; Institute of Automation; Chinese Academy of Sciences; Beijing 100080, China)

Abstract: A novel adaptive and iterative training algorithm of least square support vector machine regression (AILSSVR) is presented based on the least square support vector machine regression (LSSVR) and the proof for inverse of an order-reduced matrix is given. Compared to the standard LSSVR, the proposed algorithm takes advantage of the previous training results when learning from a new sample; therefore, it can obtain a new learning machine efficiently. Numerical simulations demonstrate that AILSSVR can adaptively decide the number of support vectors and preserve the sparse property of support vectors in QP training methods. Under the similar regression accuracy, AILSSVR can speed up the learning process remarkably.

Key words: support vector machine; adaptive; iterative; regression; least square

1 引言

支持向量机(Support Vector Machine, SVM)自 1995 年由 Vapnik 提出以来就受到理论研究和工程应用两方面的重视. 近年来在语音识别领域的应用尤其广泛和深入^[1]. 标准 SVM 训练算法可以归结为求解一个具有线性不等式约束的二次规划(Quadratic Programming, QP)问题. 然而 QP 问题的求解是一件比较复杂的工作, 要求研究者掌握较深的优化技术, 而且对于样本数目较大的问题该方法的应用将受到时间和内存的制约^[2]. 针对传统 SVM 学习算法在大样本问题下遇到的困难, 许多研究者对其进行了改进^[3~5]. Osuna 等提出了一种分解算

法, 把标准 SVM 的 QP 问题分解成一系列小规模子 QP 问题, 使得每个子问题容易求解^[6]. 在文献[6]的基础上, Joachims 从选择工作集的角度提出了 SVM^{1eh}算法来更有效的实现文献[6]的分解算法^[7]. Platt 提出了序列最小优化(Sequential Optimal Minimization, SMO)的分解算法, 把标准 SVM 的 QP 问题分解成了可以解析求解的最小 QP 问题^[8]. Cauwenberghs 等提出了一种可逆的递归学习算法, 该算法在已学习样本的基础上, 每次可以解析地求解一个新增的样本, 其中的逆学习算法为留一确认法(Leave-One-Out Verification)的完整实现提供了保证, 改变了以往样本数目稍大时就要凭经验选取确认样本数的问题^[9]. 这些算法的提出使得基于 QP 求解 SVM

收稿日期: 2009-06-09; 修回日期: 2009-07-16

基金项目: 国家自然科学基金(No. 60803052, No. 10872077); 国家 863 高技术研究发展计划(No. 2007AA04Z114, No. 2009AA02Z307); 欧盟项目(No. 155776-EM-1-2009-1-IT-ERAMUNDUS-ECW-L12); 吉林省科技发展计划(No. 20080172, No. 20080708, No. 20070703); 吉林大学“985”与“211”项目; 吉林大学科学前沿与交叉学科创新项目(No. 20093172, No. 200810026)

的思想得到了更实用化的发展.但是 QP 问题的求解仍然给研究者和工程师们设置了一道较高的门槛,制约了 SVM 的应用范围.

Suykens 等人把标准 SVM 的线性不等式约束转化成了线性等式约束,从而使得 SVM 的求解问题等价于一组线性方程组的求解^[10].这种回归方法被称为最小二乘支持向量机回归(Least Squares Support Vector Machine, LSSVR).SVM 的求解从 QP 问题向线性方程组的成功转化极大地提高了 SVM 的求解效率,降低了 SVM 的学习难度,也使得 SVM 得到了更加广泛的应用^[11,12].2000 年 Suykens 等针对 LSSVR 损失了支持向量稀疏性的不足进行了改进,提出了稀疏近似的策略^[13].该方法在给定阈值的约束下,按照支持向量谱从小到大的顺序进行去除.但是对于支持向量谱比较均匀的问题该方法仍然不易于对其支持向量进行适当的取舍.2005 年,王玲等人在 Zhang, Zhou 和 Jiao 工作^[14]的基础之上,给出了隐空间支持向量机的最小二乘算法^[15];2007 年,针对分类问题,Wang 和 Chen 提出了一种基于矩阵模式的最小二乘支持向量机^[16],但该方法只适合于线性分类问题;2009 年,Zhao 和 Sun 提出了一种递归缩减最小二乘支持向量回归机,该方法可以得到稀疏解^[17].一般来说,学习集的样本越丰富,学习机的精度越高.但在实际的机器学习问题中,当样本数目达到机器内存无法容纳的时候,丰富的样本反而成了机器学习的障碍.为了完成大样本支持向量回归问题,本文扩展了文献[18]的工作,提出了更加详尽的自适应迭代最小二乘支持向量机回归算法(Adaptive and Iterative Training Algorithm of Least Square Support Vector Machine Regression, AILSSVR).该算法极大地提高了支持向量机的学习速度,并且较好地保持了 QP 训练算法中支持向量的稀疏性.

2 LSSVR 与增量 LSSVR

假设学习集为 $S = \{s_i | s_i = (x_i, y_i)\}$, 其中, $x_i \in R^n, y_i \in R$. 回归函数的形式为

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

其中 $\varphi(\cdot)$ 是特征函数, w 和 b 是待求的回归参数. 标准 SVM 是求解下面的最小值问题:

$$\begin{cases} \min Q(w, b, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + \gamma \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t. } y_i - w \cdot \varphi(x_i) - b \leq \varepsilon + \xi_i \\ w \cdot \varphi(x_i) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, l \end{cases} \quad (2)$$

其中 $\xi = (\xi_1, \xi_2, \dots, \xi_l)^T, \xi_i^* = (\xi_1^*, \xi_2^*, \dots, \xi_l^*)^T, \gamma$ 是预先设定的常数. Suykens 等人提出的 LSSVR 方法把最

小值问题(2)的约束转化成了一组等式约束^[10,13], 相当于求解下面的最小值问题:

$$\begin{cases} \min Q(w, e) = \frac{1}{2} \|w\|^2 + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 \\ \text{s.t. } y_i = w \cdot \varphi(x_i) + b + e_i, \quad i = 1, 2, \dots, l \end{cases} \quad (3)$$

其中 $e = (e_1, e_2, \dots, e_l)^T$. 问题(2)的约束中含有不等式, 而问题(3)的约束为线性等式约束. LSSVR 的求解最终可以归结为线性方程组的求解^[10]:

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & A \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (4)$$

其中, $A = \Omega + \gamma^{-1} I, \Omega_{ij} = k(x_i, x_j), k(\cdot, \cdot)$ 是核函数, 通常取为径向基核. 我们称 A 为核相关矩阵. 求解线性方程组(4)的关键在于计算核相关矩阵的逆, A^{-1} . 当有新的样本 $s_{l+1} = (x_{l+1}, y_{l+1})$ 加入学习集时, 核相关矩阵变成

$$A_{l+1} = \begin{bmatrix} A_l & b_1 \\ b_2 & c \end{bmatrix} \quad (5)$$

其中 A_l, A_{l+1} 分别是学习集 S 和 $S \cup \{s_{l+1}\}$ 的核相关矩阵, $b_2 = (\Omega_{l+1,1}, \dots, \Omega_{l+1,l}), b_1 = b_2^T, c = \Omega_{l+1,l+1}$. 若可以利用 A_l^{-1} 间接计算得到 A_{l+1}^{-1} , 则完成了增量式 SVM 学习的任务. 事实上, 这正是 Liu 等在 LSSVR 的基础上提出的增量式 LSSVR 学习算法^[19]. 文献[19]给出了确保增量式 LSSVR 算法可行的两个引理.

3 逆学习算法

对于给定的样本集 S , Cauwenberghs 等提出了逆学习算法, 即在已经学习过的样本集中按照一定的选择策略去除某个样本, 并使得新的学习问题可以在原有问题的基础上进行, 而不必重新求解全部回归参数^[9]. 对于 LSSVR 而言, 就是可以在已知 $A_l = (a_{ij}), A_l^{-1} = (\bar{a}_{ij})$ 和 $A_{l-1} = (a_{ij})_{i,j \neq k}$ 的前提下计算 A_{l-1}^{-1} . 这里 A_{l-1} 是 A_l 去掉第 k 行, 第 k 列后的降阶矩阵. 我们称之为核相关矩阵的降阶求逆, 简称降阶求逆. 文献[9]给出了降阶求逆的公式.

不妨令 $A_{l-1}^{-1} = (\hat{a}_{ij})_{i,j \neq k}$, 则降阶求逆的公式为:

$$\hat{a}_{ij} = \bar{a}_{ij} - \frac{1}{a_{kk}} \bar{a}_{ik} \bar{a}_{kj}, \quad i, j \neq k \quad (6)$$

4 算法的提出

受文献[9]逆学习算法和文献[19]增量学习算法的启发, 在文献[18]的基础上, 本文提出了更加详尽的自适应迭代最小二乘支持向量机回归算法(AILSSVR).

假设 S 为第 2 节给定的学习集, 回归函数式(1)展开为:

$$f(x, a, b) = \sum_{i \in W} a_i k(x, x_i) + b \equiv f(x) |_W \quad (7)$$

其中 a_i 和 b 是回归参数, W 是参与回归函数构造的学

习样本集,称为工作集, \tilde{W} 是学习算法以工作集 W 确定的回归参数集. 本文提出的 AILSSVR 算法由初始化和迭代更新两部分组成.

预定学习精度和检验精度均设为 θ , 算法停止参数为 ϵ . AILSSVR 学习算法的伪代码为:

第一部分: 初始化

1. 令 $W = \{s_1, s_2\}$, 根据方程组(4)解析地计算 A^{-1} , 得到回归参数集 \tilde{W}
2. for $k = 3, \dots, l$ do
3. 以样本 s_k 检测回归函数 $f(x) |_{\tilde{W}}$
4. if $|f(x_k) |_{\tilde{W}} - y_k| > \theta$ then
5. $W = W \cup \{s_k\}$
6. 以增量算法重新计算 \tilde{W}
7. 确定最小支持向量谱 $|a_i^*| = \min_{i_i \in W} |a_i|$
8. 构造临时学习集 $\hat{W} = \tilde{W} \setminus \{s_i^*\}$
9. 采用逆学习算法由 \tilde{W} 计算 (\hat{W})
10. // (\hat{W}) 为临时回归参数集
11. 以样本 s_{k+1} 检测 $f(x) |_{(\hat{W})}$
12. if $|f(x_{k+1}) |_{(\hat{W})} - y_{k+1}| \leq \theta$ then
13. $W = \hat{W}, \tilde{W} = (\hat{W})$
14. end if
15. end for
16. 计算工作集的目标函数值 $Q(w, \epsilon) |_W$

第 1 步中核相关矩阵 A 是一个 2 阶矩阵, 因此它的逆 A^{-1} 可以采用解析的方法计算. 后面随着工作集样本数目的增加将采用增量算法计算核相关矩阵 A 的逆矩阵, 从而可以快速得到新的回归函数. 目标函数的计算公式为

$$Q(w, \epsilon) |_W = \frac{1}{2} \|w\|_w^T |_{\tilde{W}} + \frac{\gamma}{2} \sum_{i_i \in W} \epsilon_i^2 \quad (8)$$

第二部分: 迭代更新

17. if $(|W| = l)$ then
18. 输出回归函数 $f(x) |_{\tilde{W}}$
19. else
20. while 不满足停机规则 do
21. for $k = 1, \dots, l$ do
22. if $s_k \notin W$ 且 $f(x_k) |_{\tilde{W}}$ 误差大于 θ then
23. $W = W \cup \{s_k\}$
24. 以增量算法重新计算 \tilde{W}
25. $|a_i^*| = \min_{i_i \in W} |a_i|$
26. $\hat{W} = W \setminus \{s_i^*\}$
27. 采用逆学习算法计算 (\hat{W})
28. if 相邻样本误差小于 θ then
29. $W = \hat{W}, \tilde{W} = (\hat{W})$
30. end if
31. 计算工作集目标函数值
32. end if
33. end for
34. end while
35. end if

停机规则为, 若

$$\frac{|Q_{\text{current}} - Q_{\text{last}}|}{Q_{\text{current}}} \leq \epsilon \quad (9)$$

则停机, 式(9)中 Q_{last} 和 Q_{current} 分别为上一次和本次工作集更新后的目标函数值.

5 数值实验

为了验证 AILSSVR 学习算法的有效性, 我们以 VISUAL C++ 6.0 实现了上述算法. 由于标准 LSSVR 算法需要较大的内存开销, 我们在具有 4GB 内存的 Dell PowerEdge 服务器上测试了下面的两类问题. 第一类是简单的初等函数, 包括: $f(x) = \sin(x)$, $f(x) = x^2$ 和 $f(x) = x^3$. 这类问题的特点是函数形式已知, 可以检验算法对确定性系统的回归能力. 第二类是 Mackey-Glass (MG) 系统和采样函数 $\text{sinc}(x)$. MG 系统最初是由 Mackey 和 Glass 于 1977 年建立的血细胞规整 (blood cell regulation) 模型^[20]. 它是一个高度混沌的系统, 这一特性使得它成为具有挑战性的回归问题, 因此也是被广泛研究的问题. MG 系统可描述为^[20]:

$$\frac{dx}{dt} = \frac{a \cdot x(t-\tau)}{1 + x^{10}(t-\tau)} - b \cdot x(t) \quad (10)$$

其中 $\tau = 17$, $a = 0.2$, $b = 0.1$, $\Delta t = 1$, $t \in (0, 400)$. 回归时的嵌入维数分别取为 $n = 4, 6, 8$. 采样函数是信号处理中经常使用的, 其函数形式为:

$$f(x) = \begin{cases} 1, & x = 0 \\ \frac{\sin(x)}{x}, & x \neq 0 \end{cases}, \quad -15 \leq x \leq 15 \quad (11)$$

各类测试问题所取的算法运行参数如表 1 所示. 这两类问题的核函数均取为径向基核

$$k(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / (2\sigma^2)) \quad (12)$$

表 1 算法运行参数

	γ	σ	θ	ϵ
第一类问题	5000	1.0	0.01	0.01
第二类问题	50000	2.0	0.01	0.01

表 2 给出了上述各算例的运行结果, 其中第三列是算法确定的支持向量数目, 第四列是算法的学习时间, 第五、八列分别是学习和检验的均方差, 第六、九列分别是学习和检验的回归正确率. 这里回归正确率是回归的相对误差

$$\epsilon_{\text{rel}} = \left| \frac{f(x) - y}{y} \right| \quad (13)$$

小于 θ 的样本个数与学习集 (检验集) 样本个数的百分比. 第七列是算法相对于标准 LSSVR 的加速比, 其计算公式为 $r = t_{\text{lssvr}} / t_{\text{ailsvr}}, t_{\text{lssvr}}, t_{\text{ailsvr}}$ 分别是标准 LSSVR 与 AILSSVR 的学习时间. 从表 2 可以看出, 与标准的 LSSVR 相比, 在相似的回归正确率的前提下, 本文提出

的 AILSSVR 学习算法大幅度地提高了学习速度,其中改进最大的是 4 维的 MG system 算例,速度提高了 3 万余倍,改进最小的是 cubic 算例,速度也提高了 200 余倍.图 1 绘出了表 2 中前 4 个算例的支持向量在二维平面的位置,其中原点代表支持向量.由支持向量的位置

图可以看出,在曲率变化大的位置支持向量的密度较大,反之,在相对平直的位置支持向量密度较小.图 1 所显示的支持向量密度的变化也在一定程度上说明了本文提出的 AILSSVR 算法可以较好地抽取学习集的支持向量.

表 2 AILSSVR 算法与标准 LSSVR 的比较

数据集 $l \times n$	算法	支持向量数目	训练时间(Sec.)	均方误差(训练)	准确率(训练)	时间比	均方误差(检验)	准确率(检验)
sin 3000×1	LSSVR	ALL	1465.05	$3.58e-009$	99.93	1479	$4.19e-009$	99.87
	AILSSVR	50	0.99	$1.52e-006$	99.77			
square 3000×1	LSSVR	ALL	1463.44	$2.62e-005$	99.97	323	$2.49e-005$	99.97
	AILSSVR	131	4.52	$3.04e-003$	99.33			
cubic 3000×1	LSSVR	ALL	1564.88	$8.05e-003$	96.03	228	$9.38e-003$	95.90
	AILSSVR	209	6.86	$6.09e-001$	98.20			
sinc 3000×1	LSSVR	ALL	1448.28	$8.23e-011$	99.93	1105	$1.14e-010$	99.80
	AILSSVR	54	1.31	$1.59e-008$	99.87			
MG system 6000×4	LSSVR	ALL	11048.69	$1.44e-008$	100	36828	$1.49e-008$	100
	AILSSVR	5	0.30	$5.34e-006$	100			
MG system 6000×6	LSSVR	ALL	12954.34	$8.06e-009$	100	34090	$8.48e-009$	100
	AILSSVR	5	0.38	$9.23e-007$	100			
MG system 6000×8	LSSVR	ALL	13104.99	$3.30e-009$	100	29122	$3.28e-009$	100
	AILSSVR	5	0.45	$3.05e-006$	100			

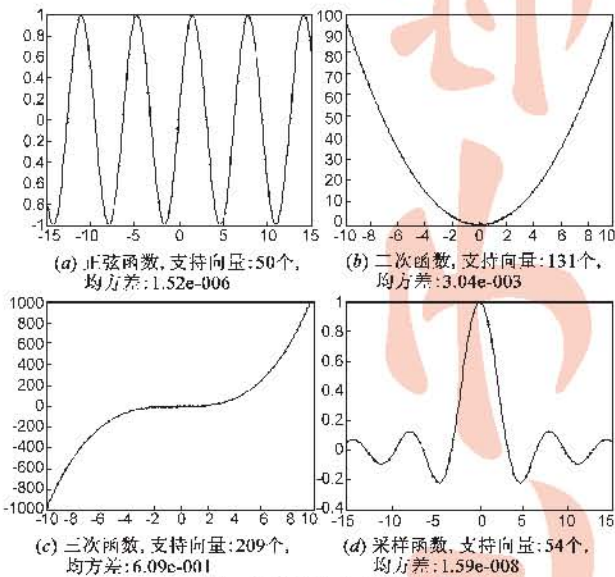


图 1 支持向量分布图

6 结论与讨论

本文在标准 LSSVR 训练算法的基础之上提出了一种自适应迭代最小二乘支持向量机回归训练算法(AILSSVR).该训练算法能够自适应地确定支持向量个数,极大地提高了算法的训练速度,并且保持了标准训练算法易于理解、便于求解的优点,较好地克服了标准 LSSVR 算法中支持向量稀疏性缺失的问题.算法训练速度的提高将促进 SVM 在实时系统控制中的应用.

参考文献:

[1] 齐峰岩,鲍长春.一种基于支持向量机的含噪语音的清/浊/静音分类的新方法[J].电子学报,2006,34(4):605 -

611.
Qi Feng-yan, Bao Chang-chun. A method for voiced/unvoiced/silence classification of speech with noise using SVM[J]. Acta Electronica Sinica, 2006, 34(4): 605 - 611. (in Chinese)

[2] Vapnik V N. Statistical Learning Theory[M]. New York: Springer-Verlag, 1998.

[3] Quan Yong, Yang Jie, Yao Lixiu, et al. Successive overrelaxation for support vector regression[J]. Journal of Software, 2004, 15(2): 200 - 206.

[4] Tian Shengfeng, Huang Houkuan. A simplification algorithm to support vector machines for regression[J]. Journal of Software, 2002, 13(6): 1169 - 1172.

[5] Zhang Haoran, Han Zhengzhi. An improved sequential minimal optimization learning algorithm for regression support vector machine[J]. Journal of Software, 2003, 14(12): 2006 - 2013.

[6] Osuna E, Freund R, Girosi F. An improved training algorithm for support vector machines[A]. IEEE Workshop on Neural Networks and Signal Processing[C]. Amelia Island, 1997. 276 - 285.

[7] Joachims T. Making large-scale support vector machine practical[A]. In Advances in Kernel Methods-Support Vector Learning[C]. Cambridge, Massachusetts: The MIT Press, 1999. 169 - 184.

[8] Platt JC. Fast training of support vector machines using sequential minimal optimization[A]. In Advances in Kernel Methods-Support Vector Learning[C]. Cambridge, Massachusetts: The MIT Press, 1999. 185 - 208.

[9] Cauwenberghs G, Poggio T. Incremental and decremental support vector machine learning[A]. In Advances in Neural Information Processing Systems[C]. Cambridge, MA: MIT Press,

2001, 13:426 - 433.

- [10] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. *Neural Processing Letters* 1999, 9:293 - 300.
- [11] 刘涵, 郭勇, 郑岗, 刘丁. 基于最小二乘支持向量机的图像边缘检测研究[J]. *电子学报*, 2006, 34(7):1275 - 1279.
Liu Han, Guo Yong, Zheng Gang, Liu Ding. Edge detection based on least squares support vector machines[J]. *Acta Electronica Sinica*, 2006, 34(7):1275 - 1279. (in Chinese)
- [12] 张忠伟. 基于最小二乘支持向量机的比特分配算法[J]. *电子学报*, 2007, 35(4):756 - 760.
Zhang Zhong-wei. A LS-SVM-based bit allocation algorithm [J]. *Acta Electronica Sinica*, 2007, 35(4):756 - 760. (in Chinese)
- [13] Suykens J A K, Lukas L, Vandewalle J. Sparse sparse approximation using least squares support vector machines[A]. In *Proc. of the IEEE International Symposium on Circuits and Systems (ISCAS 2000)* [C]. Geneva, Switzerland, 2000. 757 - 760.
- [14] Zhang Li, Zhou Weida, Jiao Licheng. Hidden space support vector machines[J]. *IEEE Transactions on Neural Networks*, 2004, 15(6):1424 - 1434.
- [15] 王玲, 薄列峰, 刘芳, 焦李成. 最小二乘隐空间支持向量机[J]. *计算机学报*, 2005, 28(8):1302 - 1307.
Wang Ling, Bo Lie-Feng, Liu Fang, Jiao Li-Cheng. Least squares hidden space support vector machines [J]. *Chinese Journal of Computers*, 2005, 28(8):1302 - 1307. (in Chinese)
- [16] Zhe Wang, Songcan Chen. New least squares support vector machines based on matrix patterns[J]. *Neural Processing Letters*, 2007, 26:41 - 56.
- [17] Yongping Zhao, Jianguo Sun. Recursive reduced least squares support vector regression[J]. *Pattern Recognition*, 2009, 42: 837 - 842.
- [18] 杨晓伟, 骆世广, 余舒, 吴春国, 梁艳春. 基于支持向量机的大样本回归算法比较研究[J]. *计算机工程与应用*, 2006, 42(6):36 - 39.
Yang Xiao-wei, Luo Shi-guang, Yu Shu, Wu Chun-guo, Liang Yan-chun. Comparison of algorithms for large regression problems based on support vector machine[J]. *Computer Engineering and Applications*, 2006, 42(6):36 - 39. (in Chinese)
- [19] Liu Jianghua, Chen Jiapin, Jiang Shan, et al. Online SL-SVM for function and classification[J]. *Journal of University of Science and Technology, Beijing*, 2003, 10(5):73 - 77.
- [20] Flake G W, Lawrence S. Efficient SVM regression training with SMO[J]. *Machine Learning*, 2002, 46:271 - 290.

作者简介:



杨 滨 男, 1978 年 2 月生于吉林省前郭县, 硕士, 吉林大学计算机科学与技术学院讲师, 博士研究生, 主要研究方向为数据挖掘、机器学习。

E-mail: yangbin@jlu.edu.cn



杨晓伟 男, 1969 年 1 月生于河南省平顶山市, 博士, 华南理工大学理学院数学系教授, 主要研究方向为机器学习、模式识别、优化计算与数据挖掘。

E-mail: xwyang@scut.edu.cn



黄 岚 女, 1974 年 4 月生于江苏省抚州市, 博士, 吉林大学计算机科学与技术学院副教授, 研究方向: 智能算法及其应用。国家 863 项目负责人。

E-mail: huanglan@jlu.edu.cn



梁艳春 男, 1953 年 10 月生于吉林省吉林市, 博士, 吉林大学计算机科学与技术学院教授, 博士生导师, 主要研究领域为人工神经网络、进化计算和生物信息学等。

E-mail: yeliang@jlu.edu.cn



吴春国(通讯作者) 男, 1976 年 1 月生于黑龙江鹤岗市, 博士, 吉林大学计算机科学与技术学院副教授, 主要研究领域为机器学习、进化算法和生物信息学等。

E-mail: wucg@jlu.edu.cn