第49卷第4期 大连理工大学学报 Vol. 49, No. 4
2009年7月 Journal of Dalian University of Technology July 2009

应用数学

文章编号：1000-8608(2009)04-0605-06

自适应参数的 AOSVR 算法及其在股票预测中应用

吴 微*，张 凌

（大连理工大学 应用数学系，辽宁 大连 116024）

摘要： 以股票预测为背景，在一种在线 SVR 算法 AOSVR 中，引入 Cherkassky 参数选择策略，形成自适应参数的 AOSVR 算法. 根据时间序列的变化，通过在线调整 SVR 参数达到更好的预测精度和泛化能力. 另外，针对股票市场特性，利用 AOSVR 的“忘记”阈值丢掉早期数据来集中刻画近期的股市特点. 将自适应参数的 AOSVR 算法应用到上证综合指数构成的时间序列上，取得了良好的预测效果.

关键词： 在线支持向量机回归算法；参数选择；非稳定时间序列；股票预测

中图分类号： O242 **文献标志码：** A

0 引 言

支持向量机回归(SVR)算法自提出以来，由于其不同于基于搜索的 BP 等传统神经网络而具有的全局最优、避免“维数灾难”等优点，已成为目前流行的模式分析方法之一，并且在股票预测中获得了较好效果[1~3]. 由于基于二次规划，经典的 SVR 算法如 Chunking[4]、Decomposition[5~7] 等都是批处理的. 在股票预测这样的时间序列问题中，由于样本点随时间递增给出，SVR 每次都要对新的训练集重新以批处理方式训练，十分耗时. 近来以原有训练集为基础在线更新的 SVR 成为研究热点[8~11]，其中 AOSVR[8] 以其自身优点在时间序列预测领域取得了较好的成果[12,13]. 但是它对敏感影响 SVR 性能的参数 C、ε 和核函数参数没有特殊考虑.

一般地，SVR 参数是在训练前由经验或校验方法确定的. Cherkassky 等[14] 根据 SVR 的统计特性提出由样本点直接确定参数的简单方法，并且在批处理 SVR 证明有很好的可行性. 股票预测问题里样本变化规律不稳定且噪声严重，固定 SVR 参数往往不能很好地刻画样本特性. 因此本文结合 AOSVR 的在线特点和 Cherkassky 等由数据确定参数的简单方法，构造在线自适应参数的 AOSVR 算法，可以随样本数据的加入在线调整参数从而更好地刻画股市样本的特征来达到更好的预测效果.

此外，尽管股票走势不稳定，但其近期行情是相对稳定的，而且股民也是由近期股情来做决策. 因此在大量的股票数据中利用近期样本可以更好地刻画股市特点. 本文为股票时间序列设定“忘记”阈值 T_{m}，当递增的 AOSVR 训练样本数大于 T_{m} 时，可以利用递减的 AOSVR 有技巧地而不是简单地丢掉早期数据.

本文利用自适应参数的 AOSVR 算法和“忘记”阈值方法，以 2002～2003 年上证综合指数为样本进行数值实验.

1 AOSVR 基本思想

1.1 支持向量机回归(SVR)算法和 KKT 条件

给定一个训练集 $T=\{(\boldsymbol{x}_i,y_i);i=1,\cdots,l\}$，其中 $\boldsymbol{x}_i\in\boldsymbol{R}^N$，$y_i\in\mathbf{R}$. 支持向量机的回归问题就是要在一个高维空间 $\boldsymbol{F}$ 中构造一个线性的回归函数 $f(\boldsymbol{x})=\boldsymbol{W}^{\mathrm{T}}\Phi(\boldsymbol{x})+b$，这里 $\boldsymbol{W}$ 是 $\boldsymbol{F}$ 中的向量，$\Phi(\boldsymbol{x})$ 是将原始问题空间的 $\boldsymbol{x}$ 映射到 $\boldsymbol{F}$. SVR 二次规划的目标函数具有如下形式[15]：

$$L_{\mathrm{D}}=\frac{1}{2}\sum_{i=1}^{l}\sum_{j=1}^{l}Q_{ij}(\alpha_i-\alpha_i^*)(\alpha_j-\alpha_j^*)+\varepsilon\sum_{i=1}^{l}(\alpha_i+\alpha_i^*)-\sum_{i=1}^{l}y_i(\alpha_i-\alpha_i^*)-\sum_{i=1}^{l}(\delta_i\alpha_i+\delta_i^*\alpha_i^*)+\sum_{i=1}^{l}[u_i(\alpha_i-$$

收稿日期： 2007-02-17； **修回日期：** 2009-05-04.
基金项目： 国家自然科学基金资助项目(10471017，10871220)；教育部青年骨干教师基金资助项目(3004-082502).
作者简介： 吴 微*(1953-)，男，教授，博士生导师，wuweiw@dlut.edu.cn.

$$C)+u_i^*(\alpha_i^*-C)]+\beta\sum_{i=1}^{l}(\alpha_i-\alpha_i^*) \quad (1)$$

其中 δ_i^*、u_i^*、α_i^* 和 β 都是 Lagrange 乘子；$Q_{ij}=K(\boldsymbol{x}_i,\boldsymbol{x}_j)=\Phi^{\mathrm{T}}(\boldsymbol{x}_i)\Phi(\boldsymbol{x}_j)$ 是核函数. 在本文后面的实验中，核函数取做 RBF 核函数：

$$K(\boldsymbol{x}_i,\boldsymbol{x}_j)=\exp\left(-\frac{\|\boldsymbol{x}_i-\boldsymbol{x}_j\|^2}{2\sigma^2}\right)$$

其中 σ 是核函数参数. 通过求式(1)得到回归函数形如

$$f(\boldsymbol{x})=\sum_{i=1}^{l}(\alpha_i-\alpha_i^*)K(\boldsymbol{x},\boldsymbol{x}_i)+b^*$$

式(1)的最优解存在当且仅当 Karush-Kuhn-Tucker(KKT)条件成立：

$$\begin{aligned}
&\frac{\partial L_{\mathrm{D}}}{\partial \alpha_i}=\sum_{j=1}^{l}Q_{ij}(\alpha_j-\alpha_j^*)+\varepsilon-y_i-\delta_i+\\
&\qquad u_i-\beta=0;\\
&\frac{\partial L_{\mathrm{D}}}{\partial \alpha_i^*}=-\sum_{j=1}^{l}Q_{ij}(\alpha_j-\alpha_j^*)+\varepsilon+y_i-\delta_i^*+\\
&\qquad u_i^*-\beta=0;\\
&\delta_i^*\geqslant 0,\delta_i^*\alpha_i^*=0;\\
&u_i^*\geqslant 0,u_i^*(\alpha_i^*-C)=0
\end{aligned} \quad (2)$$

令 $\theta_i\triangleq\alpha_i-\alpha_i^*$，$h(\boldsymbol{x}_i)\triangleq f(\boldsymbol{x}_i)-y_i$，易得 KKT 条件(2)的等价形式：

$$\begin{cases}
h(\boldsymbol{x}_i)\geqslant\varepsilon; & \theta_i=-C\\
h(\boldsymbol{x}_i)=\varepsilon; & -C<\theta_i<0\\
-\varepsilon\leqslant h(\boldsymbol{x}_i)\leqslant\varepsilon; & \theta_i=0\\
h(\boldsymbol{x}_i)=-\varepsilon; & 0<\theta_i<C\\
h(\boldsymbol{x}_i)\leqslant-\varepsilon; & \theta_i=C
\end{cases} \quad (3)$$

因此当问题达到最优解时，样本点可以分为 3 类，它们各自满足条件(3)：

(1) $E=\{i\,\|\,\theta_i\,|=C\}$，此时 $|h(\boldsymbol{x}_i)|>\varepsilon$ 样本点落在 ε-tube 之外，属于错误点；

(2) $S=\{i\,|\,0<|\theta_i|<C\}$，此时 $|h(\boldsymbol{x}_i)|=\varepsilon$ 样本点落在 ε-tube 之上，属于支持向量；

(3) $R=\{i\,\|\,\theta_i\,|=0\}$，此时 $|h(\boldsymbol{x}_i)|<\varepsilon$ 样本点落在 ε-tube 之内，没有影响.

1.2 AOSVR 主要思想

AOSVR 通过更新 $f(\boldsymbol{x})=\sum_{i=1}^{l}\theta_iK(\boldsymbol{x},\boldsymbol{x}_i)+b^*$ 中每个样本点 $\boldsymbol{x}_i$ 对应的 θ_i 来使加入样本后新训练集满足 KKT 条件. 当一个新样本点 $\boldsymbol{x}_c$ 加入训练集后，AOSVR 在有限步内找到合适的该点对应的系数 θ_c 使得 $\boldsymbol{x}_c$ 点满足 KKT 条件. 在这个过程中要同时使已经存在的样本点继续满足它们相应的 KKT 条件. AOSVR 算法流程如下[8]：

(1) 取 $\theta_c=0$，判断 $\boldsymbol{x}_c$ 是否属于 R 集合，如果是转(5)，否则转(2)；

(2) 确定 θ_c 的变化量 $\Delta\theta_c$；

(3) 更新 T 中的样本系数 θ_i 和 θ_c，确定每个样本点所属的集合 S、E、R；

(4) 判断 $(\boldsymbol{x}_c,y_c)$ 是否属于 S 或 E 集合，若是转(5)，否则转(2)；

(5) 将 $(\boldsymbol{x}_c,y_c)$ 加入样本集 T，算法结束.

在更新系数的过程中关键是第(2)步，确定的标准是使样本在回归函数更新后仍然属于 E、S、R 中的最小 $\Delta\theta_c$.

2 AOSVR 下参数的自适应选择

SVR 的参数 C、ε 与 RBF 核函数的 σ 敏感地影响训练精确度和推广能力. 事实上，参数选择的方法比解决 SVR 更加复杂. 一般的 SVR 方法都是批处理方法，在加入样本训练之前都需要按照经验预先设定 3 个参数，或者由某种校验算法如 Cross Validation 或 Leave-One-Out 算法来求得. 但是对于股票预测这样的样本随时间递增给出并且具有不稳定噪声的回归问题，经验设定无法很好掌握数据的特性而校验算法也异常繁琐耗时. 如果能够随样本加入根据样本数据随时调整参数将可以更好地刻画样本变化特点. 以 AOSVR 的在线 SVR 为基础引入 Cherkassky 方法[14]恰好满足了这样的要求.

基于 SVR 各个参数对于样本数据统计特性的分析，Cherkassky 等[14]提出了一种简单的由样本直接确定参数的方法，其中 $\bar{y}$ 和 σ_y 分别是 $y_i(i=1,\cdots,l)$ 的平均值和标准差，d 是 $\boldsymbol{x}$ 的维数，$rang(\boldsymbol{x})$ 是 $\boldsymbol{x}$ 各分量的值域：

$$\begin{aligned}
&C=\max(|\bar{y}+3\sigma_y|,|\bar{y}-3\sigma_y|)\\
&\varepsilon=3\sigma_y\sqrt{\frac{\ln l}{l}}\\
&\sigma^d=(0.2\sim 0.5)\times rang(\boldsymbol{x})
\end{aligned} \quad (4)$$

在 AOSVR 下，加入新样本后，根据式(4)更新 C、ε 和 σ 而不是保持同样的参数值，这样将样本变化的特征反映到回归函数中. 原本应用于批处理 SVR 的 Cherkassky 方法引入到在线的 SVR 中，恰好满足在非稳定时间序列预测里随样本变化调整回归参数的要求. 当然仅仅加入 1 个样本时更新对 3 个参数变化影响不大，但是对于噪声异常或者数据变化剧烈的情况，这种方法是合理的，并且这种简单的方法并不加大时间损耗.

3　股票预测中应用 AOSVR 的“忘记”阈值

股票市场变化不稳定，但是近期的股票走势比较稳定，而且投资者也是根据近期的股票行情来决定投资行为. 因此在预测中，应该更好地把握股票近期特点，同时考虑到时间和空间效率也要求训练的网络忘记早期的信息来增强近期信息的“记忆”. AOSVR 可以做到在时间序列中有技巧地“忘记”早期样本，而不是直接丢掉. 具体方法是：当训练样本个数增加到一个指定阈值 T_m 时，AOSVR 就从样本序列中去掉早期样本点. 而去掉样本点必然会改变其他样本的 KKT 条件. 因此，和前述递增训练方法相似，AOSVR 采用递减的方式有步骤地去掉样本点，同时保证其他样本点的 KKT 条件. 结合“忘记”阈值的自适应参数的 AOSVR 如图 1 所示.

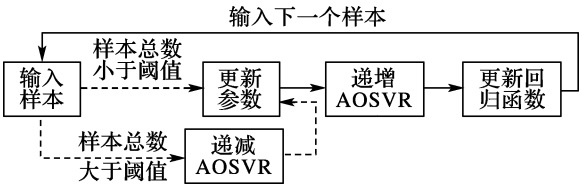

图 1　自适应参数的 AOSVR 流程图

Fig. 1　Flowchart of AOSVR with adaptive parameters

4　自适应参数的 AOSVR 在股票预测中应用

股票预测是典型的非稳定时间序列预测问题. 目前，研究者用 BP 等神经网络给出了不错的预测结果[16,17]. 但是这些方法始终面临一个如何确定网络结构的问题，而 SVR 通过解二次规划直接确定网络，避免了该问题并总有全局最优解. 然而目前应用到股票预测的 SVR 方法都是传统的固定 SVR 参数并以批处理方式解二次规划来确定回归函数. 在股票市场这种样本变化不稳定且噪声严重的问题里，相对于传统方法，自适应参数的 AOSVR 算法通过递增地给出训练样本并且随着样本集的变化动态地改变 SVR 参数值可以更好地刻画样本的特征从而达到更好的预测效果. 同时，利用 AOSVR“忘记”阈值，可以更好地刻画股票近期特征以达到更好的精确度和推广效果.

4.1　时间序列的构成

股市数据时刻变化，但却有明显的时序性. 样本数据的变化直接受到时间参数的影响，所以本文直接使用原始数据，从而很好地描述数据的瞬时变化特性. 本文选用 2002～2003 年上证综合指数为训练集和测试集构成时间序列，表 1 给出了每个样本的 12 个分量，它们分别是股市数据指标，用来刻画股票走势[16,18].

表 1　样本元素的构成

Tab. 1　Components of samples

元素	含义	元素	含义
ξ_1	今日收盘指数	ξ_7	K 指标
ξ_2	今日涨跌值	ξ_8	D 指标
ξ_3	昨日涨跌值	ξ_9	RSI
ξ_4	前日涨跌值	ξ_{10}	DIF
ξ_5	前 10 日(含今日)平均涨跌值	ξ_{11}	DEA
ξ_6	前 30 日(含今日)平均涨跌值	ξ_{12}	BAIS

4.2　样本归一化

为了提高训练的效率和结果的推广能力，需要压缩输入数据的实际变化范围. 因此对样本数据进行归一化处理. 设 ξ_{ij} 是第 i 个训练样本的第 j 个分量，首先计算样本集合上各维分量的均值 $P_j = \frac{1}{l}\sum_{i=1}^{l}\xi_{ij}$，然后进行样本集合的归一化处理：$\bar{\xi}_{ij} = \xi_{ij}/P_j$. 这样使得样本集合在各维上都尽量向“1”靠近，从一定程度上减少了样本向量在各维上的差别.

4.3　股票预测和结果分析

尽管 BP 在股票预测方面有成功的应用，但本质上说 BP 在回归方面不如 SVR. 因此本文仅在 SVR 领域讨论股票预测问题. SVM-light[6] 和 SMO[5,7] 是 SVR 的两种有效批处理实现方式，本文将 SVM-light 和 SMO 与 AOSVR 在预测精确度、泛化能力、时间效率方面进行比较分析. 预测结果评价方法采用正规化均方误差(E_{nms})：

$$E_{nms} = \frac{1}{l\delta^2}\sum_{i=1}^{l}(f(x_i) - y_i)^2;$$

$$\delta^2 = \frac{1}{l-1}\sum_{i=1}^{l}(y_i - \bar{y})^2 \tag{5}$$

实验 1　自适应参数的 AOSVR 和 SVM-light、SMO 在预测效果上的比较

取 200 d 股票数据作为训练样本，其后 20 d 作为测试样本. 在 200 d 的训练样本中，分别采用 AOSVR 递增给出样本在线更新参数方法和 SVM-light、SMO 的批处理方法训练，在后 20 d 测试训练结果. 从表 2 可以看到：自适应参数的 AOSVR 与 SVM-light 和 SMO 在训练精度上相差不大，可以验证自适应参数的 AOSVR 和批处理的结果是一致的，而由于前者使用自适应参数

在结果上略微好些. 从预测结果上看,SVM-light 和 SMO 比自适应参数的 AOSVR 有较大差距. 因为前者是固定参数,当股票值变化剧烈时不能刻画所有的情形,而后者自适应参数使预测的 20 d 股票特征刻画得更好. 当然这种差距部分原因在于 SVM-light 和 SMO 参数没有取到最好,这也正是本文自适应参数的 AOSVR 较批处理方法在股票预测中的优势之一. 通过该实验说明在线自适应参数的 AOSVR 比传统的批处理方法在股票预测中具有一定的优越性.

表 2 自适应参数的 AOSVR 和固定参数的 SVM-light 及 SMO 的比较

Tab. 2 Comparison of adaptive AOSVR, and SVM-light and SMO with fixed parameters

SVR 算法	E_{nms}	
	训练结果	预测结果
自适应 AOSVR	0.153 2	0.325 6
SVM-light	0.160 4	0.423 0
SMO	0.157 9	0.391 2

实验 2 自适应参数的 AOSVR 和固定参数的 AOSVR 在预测效果上的比较

实验分 50、100、200、350 d 4 个时间段,将样本看做时间序列,每加入 1 个样本做 1 次更新并预测第 2 d 的股票收盘指数,当第 2 d 股票收盘指数得到后加入训练集更新并预测第 3 d 股票收盘指数,以此类推. 事实上,股票预测往往仅需要预测第 2 d 的股票值即可,当第 2 d 股票值得到后再用来预测第 3 d 的股值. 由表 3 可见:自适应参数这一列所得结果相对其他 3 列固定参数结果更好. 这说明自适应的参数调整可以更好地刻画时间序列特性. 同时可见随着时间的增长误差值逐渐降低,这是因为时间长股票变化幅度就相对剧烈,而自适应参数能比较好地适应这种变化. 同时需要说明的是,SVR 性能的优劣极其敏感地依赖于参数的选择. 最合适的参数会使股票预测效果最好,但这种参数很难通过经验设定来达到. 因此本文自适应参数比固定参数有更好的实用意义,见图 2.

表 3 自适应参数的 AOSVR 和固定参数的 AOSVR 比较

Tab. 3 Comparison of AOSVRs with adaptive and fixed parameters

时间段/d	自适应参数	固定参数		
		$C=1$, $\varepsilon=10$, $\sigma=2$	$C=1$, $\varepsilon=1$, $\sigma=0.5$	$C=0.3$, $\varepsilon=1$, $\sigma=0.5$
50	0.287 8	1.158 0	1.467 2	1.666 9
100	0.273 1	1.358 9	1.616 7	1.839 3
200	0.135 5	0.993 1	0.864 7	1.064 6
350	0.157 0	0.862 4	0.758 7	0.917 4

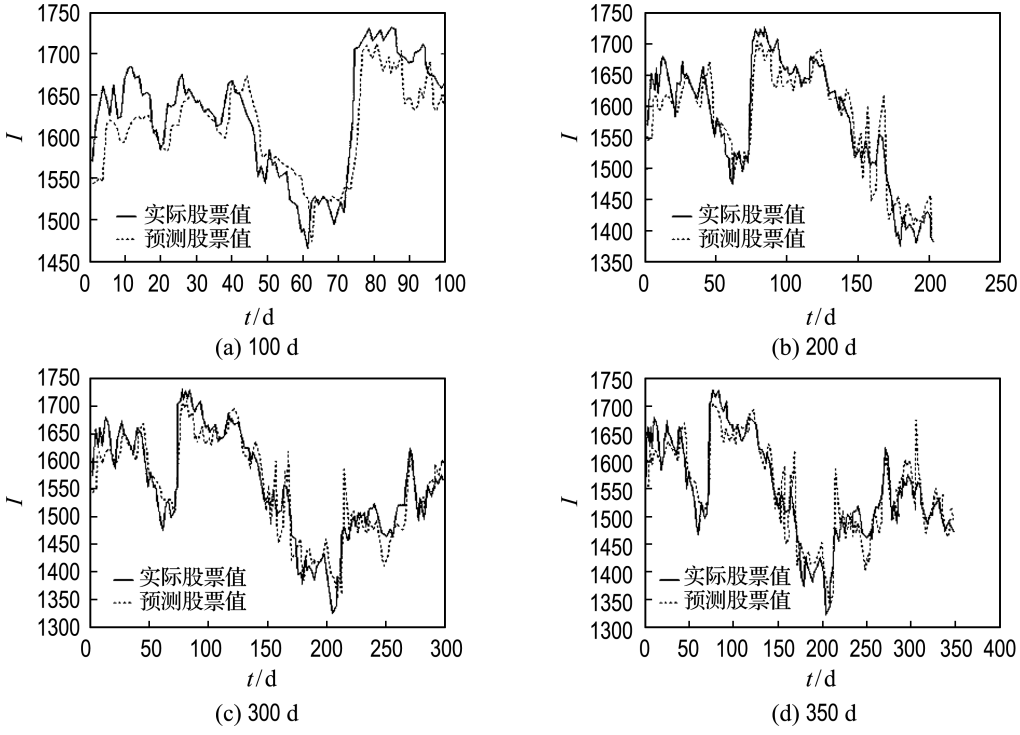

图 2 自适应参数的 AOSVR 在不同时间段内的股票预测

Fig. 2 Stock market forecast by adaptive AOSVR in different time intervals

实验 3　自适应参数的 AOSVR 和在线迭代的 SVM-light、SMO 在时间效率上的比较

SVM-light 和 SMO 在加入 1 个样本后更新回归函数要在新的训练集上批处理训练，这样每加 1 个样本都要重新更新必然会比 AOSVR 耗时. 该实验在时间效率上和预测精度上将二者进行比较. 由表 4 可见随着样本增多 SVM-light 和 SMO 比 AOSVR 的时间增长快. 从预测精度上看，虽然 SVM-light 和 SMO 也是每次增加 1 个样本后更新回归函数但是由于它们用一个固定的参数，而自适应的 AOSVR 在每次增加样本后更新参数可以更好地刻画样本特性，从而达到更好的预测效果.

表 4　自适应参数的 AOSVR 与在线迭代的 SVM-light 和 SMO 在不同时间段比较

Tab. 4　Comparison of adaptive AOSVR and online SVM-light and SMO in different time intervals

时间段/d	AOSVR		SVM-light		SMO	
	E_{nms}	t/s	E_{nms}	t/s	E_{nms}	t/s
50	0.287 8	4	0.273 2	5	0.278 0	6
100	0.273 1	4	0.275 9	9	0.318 5	9
200	0.135 5	14	0.314 2	71	0.329 5	89
350	0.157 0	217	0.295 1	459	0.305 2	490

实验 4　引入“忘记”阈值在股票预测中的作用

在实际应用中，股票样本数量往往很大，在 SVR 训练过程中会使在有限的时间空间效率下无法完成. 利用 AOSVR“忘记”阈值 T_m 将“时间久远”样本有规则“忘掉”，可以控制问题规模使时间空间效率不致过低. 在实验中，尝试给出不同的阈值 T_m 检验与不使用阈值的 AOSVR 在预测精度和时间空间效率上的比较. 当样本数量大于 T_m 时，将首先利用递减的 AOSVR 去掉早期的数据，这样额外加入了计算量. 因此选择合适的 T_m 是一个在舍去样本计算和新加样本计算之间寻求平衡的问题. 如表 5 所示，当 T_m 较小时，递减 AOSVR还没有发挥优势反而增大了计算量；当 T_m 达到一定值，由于递减 AOSVR 使训练集不致无限制增大降低了内存要求并使运算速度相对加快. 从预测效果上看，引入适当的 T_m 使忘记早期数据能够充分利用近期数据特点，但 T_m 过小或过大都不能达到最好的效果. 在本文采用的股票模型中，实验证明 T_m 在 200 左右为宜.

表 5　带与不带“忘记”阈值 T_m 的AOSVR 不同时间段比较

Tab. 5　AOSVRs with and without "forgetting" bias T_m in different time intervals

T_m/d	时间段/d	带“忘记”阈值的 AOSVR		不带“忘记”阈值的 AOSVR	
		E_{nms}	t/s	E_{nms}	t/s
100	150	0.301 1	5	0.294 3	4
100	200	0.253 1	18	0.135 5	15
100	250	0.273 2	35	0.138 0	30
100	300	0.152 6	44	0.150 4	53
100	350	0.168 5	160	0.157 0	217
200	250	0.141 0	33	0.138 0	30
200	300	0.146 2	49	0.150 4	53
200	350	0.153 7	148	0.157 0	217
350	400	0.150 9	425	0.141 9	459
350	450	0.159 5	490	0.154 8	560

5　结　论

股票市场是个非稳定的时间序列，利用常规的预测方法往往效果不好. AOSVR 在处理时间序列问题方面比批处理的支持向量机在时间空间效率方面有更好的特性. 本文将 Cherkassky 方法结合在 AOSVR 中达到在线自适应更新 SVR 参数，可以更好地刻画股票市场变化不稳定的特性，在实验中取得了良好的效果. 本文同时讨论了利用“忘记”阈值舍掉早期样本点来提高空间时间效率的方法. 但是这种方法仍然是尝试性的，一个切实可行的选择“忘记”阈值方法将是以后研究的努力方向.

参考文献：

[1] TAY F E H, CAO L J. Modified support vector machines in financial time series forecasting [J]. **Neuralcomputing**, 2002, **48**: 847-861

[2] KIM K. Financial time series forecasting using support vector machines [J]. **Neuralcomputing**, 2003, **55**: 307-319

[3] YANG H, CHAN L, KING I. Support vector machine regression for volatile stock market prediction [M] // HUTCHISON D, KANADE T, KITTLER J, *et al*. **Lecture Notes in Computer Sciences (Vol 2412)**. London: Springer-Verlag, 2002

[4] OSUNA E, FREUND R, GIROSI F. An improved training algorithm for support vector machines [C] // **Neural Networks for Signal Processing VII - Proceedings of the 1997 IEEE Workshop**. Amelia

Island:[s n], 1997

[5] PLATT J C. Sequential minimal optimization:a fast algorithm for training support vector machines [M] // SCHÖLKOPF B, BURGES C J C, SMOLA A J. **Advances in Kernel Methods-Support Vector Learning**. Cambridge:MIT Press, 1998

[6] JOACHIMS T. Making large-scale support vector machine learning practical [M] // SCHÖLKOPF B, BURGES C J C, SMOLA A J. **Advances in Kernel Methods-Support Vector Learning**. Cambridge:MIT Press, 1998

[7] FLAKE G W, LAWRENCE S. Efficient SVM regression training with SMO [J]. **Machine Learning**, 2002, **46**(1-3):271-290

[8] MA J, THEILER J, PERKINS S. Accurate online support vector regression [J]. **Neural Computation**, 2003, **15**(11):2683-2703

[9] RALAIVOLA L, D'ALCHÉ-BUC F. Incremental support vector machine learning:a local approach [C] // **Proceedings of International Conference on Artificial Neural Networks**. London:Springer-Verlag, 2001

[10] LAU K W, WU Q H. Online training of support vector classifier [J]. **Pattern Recognition**, 2003, **36**(8):1913-1920

[11] SHILTON A, PALANISWAMI M, RALPH D, *et al*. Incremental training of support vector machines [J]. **IEEE Transaction on Neural Networks**, 2005, **16**(1):114-131

[12] 汪 辉,皮道映,孙优贤. 支持向量机在线算法及其应用[J]. 浙江大学学报(工学版), 2004, **38**(12):1642-1649

[13] ZHOU Dian-ming, GAO Feng, GUAN Xiao-hong. Application of accurate online support vector regression in energy price forecast [C] // **Fifth World Congress on Intelligent Control and Automation**. Piscataway:IEEE, 2004

[14] CHERKASSKY V, MA Y. Practical selection of SVM parameters and noise estimation for SVM regression [J]. **Neural Networks**, 2004, **17**(1):113-126

[15] VAPNIK V N. **The Nature of Statistical Learning Theory** [M]. Berlin:Springer, 1999

[16] 吴 微,陈维强,刘 波. 用 BP 神经网络预测股票市场涨跌[J]. 大连理工大学学报, 2001, **41**(1):9-15

(WU Wei, CHEN Wei-qiang, LIU Bo. Predication of ups and downs of stock market by BP neural networks [J]. **Journal of Dalian University of Technology**, 2001, **41**(1):9-15)

[17] 张燕平,张 铃,吴 涛. 基于覆盖的构造性学习算法 SLA 及其在股票预测中的应用[J]. 计算机研究与应用, 2004, **41**(6):980-984

[18] 张玉林,吴 微. 用 BP 神经网络捕捉股市黑马初探[J]. 运筹与管理, 2004, **13**(2):123-126

AOSVR algorithm with adaptive parameters and its application to stock market forecast

WU Wei*, ZHANG Ling

(Department of Applied Mathematics, Dalian University of Technology, Dalian 116024, China)

Abstract: With the application to stock market forecast as background, Cherkassky's parameter-selection method is embedded into an online support vector regression algorithm AOSVR, resulting in an adaptive AOSVR algorithm. Forecast accuracy and generalization ability are much improved through online adapting the SVR parameters according to the movement of the time series. Meanwhile, based on the characteristics of stock market, a "forgetting" bias is used to ignore to some extent the earlier data and to concentrate on the recent data. The adaptive AOSVR algorithm is successfully applied to the forecast of the time series of Shanghai stock market index.

Key words: online support vector regression algorithm; parameter selection; non-stationary time series; stock market forecast