

DOI:10.11918/j.issn.0367-6234.201703048

差分进化最小二乘支持向量机法预测日用水量

陈磊, 陈李

(浙江工业大学 建工学院, 杭州 310014)

摘要:为解决最小二乘支持向量机的参数确定问题,提出采用自适应差分进化最小二乘支持向量机法预测日用水量.引入改进粗糙集算法分析日用水量主要影响因素,利用自相关系数法确定序列的相关性,并将自适应差分进化算法(SADE)用于优化最小二乘支持向量机(LSSVM)的参数,建立了基于SADELSSVM的预测模型.结果表明,与传统差分进化算法(DE)和自适应遗传算法(SAGA)相比,SADE具有更快的最优个体搜索速度和群体进化速度,与基于SAGALSSVM和基于DELSSVM的模型相比,本文提出模型的预测能力更强.

关键词: 自适应差分进化;最小二乘支持向量机;管网;日用水量

中图分类号: TU991.33 **文献标志码:** A **文章编号:** 0367-6234(2018)08-0083-05

Application of differential evolution and least squares support vector machine method in daily water demand prediction

CHEN Lei, CHEN Li

(College of Civil Engineering and Architecture, Zhejiang University of Technology, Hangzhou 310014, China)

Abstract: To find the optimal parameters of least squares vector machine (LSSVM), the daily water demand forecasting method based on self-adaptive differential evolution (SADE) and LSSVM was proposed. The main influencing factors of daily water consumption were determined using improved rough set algorithm, and the correlation analysis on daily water consumption series was conducted. SADE was applied to optimize the parameters of LSSVM to build SADELSSVM-based forecasting model. The case study shows that compared with self-adaptive GA(SAGA) and differential evolution(DE), SADE has stronger global search ability and faster evolution speed, and the proposed model has better prediction performance than SAGALSSVM-based model and DELSSVM-based model.

Keywords: self-adaptive differential evolution; least squares support vector machine; water distribution network; daily water consumption

实现管网优化调度能够节约大量供水能耗,全面提高供水的安全性和可靠性,但调度的重要前提是获得高精度的日用水量预测值.鉴于日用水量的非线性特征,学者们以主要影响因素和相关日用水量为输入,采用非线性映射能力较强的神经网络^[1-3]建模,但是神经网络存在参数较多,训练易陷入局部最优和过拟合等问题. Msiza 等^[4]根据主要影响因素和相关日用水量,利用参数较少(3个)和预测能力更强的支持向量机(SVM)建模.柳景青^[5]引入改进粗糙集算法深入分析了不同季节的日用水量主要影响因素,进一步提高了基于SVM模型的预测精度.然而,传统采用网格交叉验证法确定SVM模型参数耗时较长,并且优化的参数取决于网格的划分,有较强的主观性. Huang 等^[6]利用传统遗传算

法(GA)优化SVM的参数,但其未解决GA全局搜索能力较差的问题,难以找到较优参数.为此,本文在利用粗糙集和自相关系数法客观确定模型输入参数的基础上,引入参数更少(2个)和计算速度更快的最小二乘支持向量机(LSSVM)来建模,并利用寻优能力较强的差分进化算法对模型参数进行优化,全面提高模型的建模速度和预测精度.

1 函数估计的LSSVM算法^[7]

对于训练样本 $\{x_k, y_k\}_{k=1}^N$, 输入 $x_k \in \mathbf{R}^n$, 输出 $y_k \in \mathbf{R}$.

目标函数为

$$J_1(\mathbf{w}, \mathbf{e}) = \mu E_w + \zeta E_D = \frac{\mu}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \zeta \sum_{k=1}^N e_k^2,$$

$$\text{s. t. } y_k = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_k) + b + e_k, k = 1, \dots, N. \quad (1)$$

式中:权矢量 $\mathbf{w} \in \mathbf{R}^{n_f}$, 误差 $e_k \in \mathbf{R}$, μ 和 ζ 为参数,核函数 $\boldsymbol{\varphi}(\mathbf{x}_k): \mathbf{R}^n \rightarrow \mathbf{R}^{n_f}$, b 为偏置.

收稿日期: 2017-03-07

基金项目: 国家自然科学基金(51479177)

作者简介: 陈磊 (1977—), 男, 博士, 副教授

通信作者: 陈磊, zj_chen_lei@sina.com.cn

为求解最小值,构造函数

$$L = J_1(\mathbf{w}, \mathbf{e}) - \sum_{k=1}^N \alpha_k \{ \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_k) + b + e_k - y_k \}. \quad (2)$$

式中 α_k 为拉格朗日系数.

设 $\gamma = \zeta/\mu$, 对式(2)求偏导:

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{k=1}^N \alpha_k \boldsymbol{\varphi}(\mathbf{x}_k); \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{k=1}^N \alpha_k = 0; \\ \frac{\partial L}{\partial e_k} = 0 \rightarrow \alpha_k = \gamma e_k, k = 1, \dots, N; \\ \frac{\partial L}{\partial \alpha_k} = 0 \rightarrow \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_k) + b + e_k - y_k = 0, k = 1, \dots, N. \end{cases} \quad (3)$$

消去 \mathbf{w} 和 \mathbf{e} , 得

$$\begin{bmatrix} 0 & \mathbf{1}_v^T \\ \mathbf{1}_v & \Omega + \frac{1}{\gamma} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix}. \quad (4)$$

式中: $\mathbf{y} = [y_1, \dots, y_n]^T$, $\mathbf{1}_v = [1, \dots, 1]^T$, $\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_n]^T$, \mathbf{I} 为 $N \times N$ 的单位阵, $\Omega_{kl} = \boldsymbol{\varphi}(\mathbf{x}_k)^T \boldsymbol{\varphi}(\mathbf{x}_l) = K(\mathbf{x}_k, \mathbf{x}_l)$, $k, l = 1, \dots, N$.

求出 $\boldsymbol{\alpha}$ 和 b , 则采用径向基核函数的 LSSVM 的表达式为

$$y(\mathbf{x}) = \sum_{k=1}^N \alpha_k K(\mathbf{x}, \mathbf{x}_k) + b. \quad (5)$$

式中 $K(\mathbf{x}, \mathbf{x}_k) = \exp\{-\|\mathbf{x} - \mathbf{x}_k\|^2/\sigma^2\}$.

因此,建模仅需确定 σ 和 γ 两个参数.

2 差分进化算法(DE)优化模型参数

DE^[8]是一种利用种群个体间的合作和竞争实现优化搜索的算法.通过采用差分变异操作和竞争生存策略,该算法能够对优化空间实现全局搜索.由于DE算法的搜索性能主要取决于差分缩放因子 F 和交叉概率 CR 的取值,采用根据个体的目标值自适应调整参数的策略,以获得更好的优化结果.

DE算法的种群由 N_p 个个体组成,每个个体由优化参数 γ 和 σ 组成.DE算法由编码、变异、交叉和选择等操作组成.

1) 编码

γ 和 σ 采用实数编码,取值范围^[9]: $\gamma \in [0.01, 50]$, $\sigma \in [0.01, 50]$.

2) 变异

对于 G 代第 i 个个体,在 $[0, 1]$ 区间内产生一个随机实数 $F_{i,G}$, G 代第 i 个个体中的第 j 个优化参数 $p_{i,G}^j$ ($j = 1, 2$) 经过变异,得到相应的变异参数

$$v_{i,G+1}^j = p_{r_1,G}^j + F_{i,G}(p_{r_2,G}^j - p_{r_3,G}^j). \quad (6)$$

式中: r_1 、 r_2 、 r_3 为 $[1, N_p]$ 区间内随机产生的互不相同的整数,分别表示个体的编号,并且 $r_1 \neq r_2 \neq r_3 \neq i$; G 为代数; $F_{i,G}$ 为缩放因子,控制着差分向量 $(p_{r_2,G}^j - p_{r_3,G}^j)$ 的缩放.

3) 交叉

优化参数 $p_{i,G}^j$ 和变异参数 $v_{i,G+1}^j$ 根据式(7)进行混合,产生试验参数 $u_{i,G+1}^j$ ($j = 1, 2$):

$$u_{i,G+1}^j = \begin{cases} v_{i,G+1}^j, & \text{rand} \leq CR_{i,G} \text{ 或 } i = \text{randn}(2); \\ p_{i,G}^j, & \text{其他.} \end{cases} \quad (7)$$

式中: rand 为在 $[0, 1]$ 区间内随机产生的一个数; $CR_{i,G}$ 为 G 代第 i 个个体的交叉率; randn(2) 为 $[1, 2]$ 区间内产生的一个随机正整数,以保证至少一个优化参数会发生变异.

4) 选择

计算优化参数 $p_{i,G}^j$ 和试验参数 $u_{i,G+1}^j$ ($j = 1, 2$) 对应的目标函数,采用贪婪的选择模式

$$p_{i,G+1}^j = \begin{cases} u_{i,G+1}^j, & f(u_{i,G+1}^1, u_{i,G+1}^2) < f(p_{i,G}^1, p_{i,G}^2); \\ p_{i,G}^j, & f(u_{i,G+1}^1, u_{i,G+1}^2) \geq f(p_{i,G}^1, p_{i,G}^2). \end{cases} \quad (8)$$

为了获得更好的个体,需在贪婪选择前对 F 和 CR 进行自适应调整.

对于 G 代第 i 个个体,若根据 $F_{i,G}$ 和 $CR_{i,G}$ 的组合得到试验参数的目标值小于优化参数对应的目标值,则 $G+1$ 代第 i 个个体的 $F_{i,G+1}$ 和 $CR_{i,G+1}$ 保持不变;否则,在取值范围内重新随机产生 $F_{i,G+1}$ 和 $CR_{i,G+1}$.具体如下:

$$F_{i,G+1} = \begin{cases} F_{i,G}, & f(u_{i,G+1}^1, u_{i,G+1}^2) \leq f(p_{i,G}^1, p_{i,G}^2); \\ F_{\min} + \text{rand} \times (F_{\max} - F_{\min}), & \text{其他.} \end{cases} \quad (9)$$

式中 F_{\min} 、 F_{\max} 分别为 F 取值的下限和上限.

$$CR_{i,G+1} = \begin{cases} CR_{i,G}, & f(u_{i,G+1}^1, u_{i,G+1}^2) \leq f(p_{i,G}^1, p_{i,G}^2); \\ CR_{\min} + \text{rand} \times (CR_{\max} - CR_{\min}), & \text{其他.} \end{cases} \quad (10)$$

式中 CR_{\min} 、 CR_{\max} 分别为 CR 取值的下限和上限.

3 基于 SADELSSVM 的日用水量建模和预测

3.1 模型的输入参数分析

3.1.1 主要影响因素分析

一般来说,日用水量的影响因素主要是最高温度、平均温度、最低温度、星期量、阴晴量和降雨量等因素.为了进一步确定主要影响因素,采用善于处理

不精确、不相容数据的基于权值累计评价的可变精度粗糙集算法. 通过引入变精度, 使算法具有较好的整体信息评价能力和容错性; 通过采用权值累计评价, 使算法客观评价主影响因素, 较好地解决分析不同长度序列可能得到不同主要影响因素的不足.

利用浙江某城市 2003 年—2006 年的日用水量及相关天气数据, 采用改进粗糙集算法分析了不同季节的主要影响因素, 过程详见文献[5]. 分析结果为: 春、冬季日用水量的主要影响因素为相对湿度、阴晴量、星期量和平均温度, 而夏、秋季日用水量的主要影响因素为相对湿度、阴晴量、星期量和最高温度. 各季日用水量都删除了部分影响因素, 这些因素虽然也重要, 但它们与主要影响因素相关, 因此可被替代. 比如: 最低温度、最高温度与平均温度有一定相关性, 阴晴量则可部分表示降雨量. 因此, 计算结果是合理的.

3.1.2 序列相关性分析

采用自相关系数法确定序列数据间的相关性, 具体过程如下.

日用水量序列 $d_i(t = 1, 2, \dots, T)$ 的自相关系数为

$$c_h = \frac{\sum_{i=1}^{T-h} (d_i - \bar{d})(d_{i+h} - \bar{d})}{\sum_{i=1}^T (d_i - \bar{d})^2}. \quad (11)$$

式中: $\bar{d} = \frac{1}{T} \sum_{i=1}^T d_i$, $h = 1, 2, \dots, T-1$. 当 $|c_h| \in (0.8, 1)$ 时属于高度相关; 当 $|c_h| \in (0.5, 0.8)$ 时属于中度相关.

根据 2003 年—2006 年的序列, 计算得到 $|c_7| = 0.831$, 其他的 $|c_h| < 0.5$.

3.2 日用水量建模和预测

鉴于四季的主要影响因素不尽相同, 为了便于建模和预测, 输入取各季主要影响因素的合集, 即相对湿度、阴晴量、星期量、平均温度和最高温度, 其中星期量 $\in [1, 8]$, 节假日的星期量取 8, 阴晴量 $\in [1, 8]$. 考虑到序列的相关性, 输入增加取预测日前第 7 天日用水量.

将 2007 年—2008 年的日用水量数据分为 367 组数据, 其中 2007 年 1 月 1 日—12 月 26 日 360 组是训练验证集, 2007 年 12 月 27 日—2008 年 1 月 2 日 7 组(包括工作日和周末日)为预测集. 为了客观评价模型参数, 将 360 组数据 6 等分, 进行 6 折交叉验证计算(即每次选 5 份数据训练 LSSVM, 用 1 份验证 LSSVM, 进行每次选取不同验证集的 6 次验证), 各个体的目标值计算方法如下:

$$f(\gamma, \sigma) = \left(\sum_{m=1}^6 \sum_{q=1}^{60} \frac{1}{60} (F_{mq} - Y_{mq})^2 \right)^2. \quad (12)$$

式中: γ 、 σ 为个体中对应的 LSSVM 参数; F_{mq} 表示第 m 次验证中以验证集第 q 组数据为 LSSVM 输入计算得到的预测值; Y_{mq} 表示第 m 次验证中验证集第 q 组输入数据对应的实际日用水量.

日用水量建模的过程如下:

1) 设置 SADE 算法最大进化代数 MAX 为 100, 赋值代数 G 为 1, 取种群的个体数 $N_p = 50$, 随机产生第 i 个实数编码的个体 (γ_i, σ_i) 以及与其对应的 $F_{i,G}$ 和 $CR_{i,G}$ ($i = 1, 2, \dots, N_p$).

2) 利用交叉验证法计算种群个体的目标值(对训练验证集中的训练数据和验证的输入数据归一化预处理, 并反预处理预测结果).

3) 对各个体中的优化参数进行变异和交叉, 得到相应试验参数, 并判断各试验参数是否已超出取值范围: 若试验参数小于 0.01, 试验参数取 0.01; 若大于 50, 则取 50.

4) 根据试验参数, 同样利用交叉验证法计算其目标函数值, 与对应优化参数的目标值对比后, 通过选择得到新种群及其个体目标值. 根据选择结果, 对种群第 i 个 ($i = 1, \dots, N_p$) 个体的 $F_{i,G}$ 和 $CR_{i,G}$ 进行自适应调整.

5) 判断 G 是否等于最大进化代数: 若是, 输出最小目标值对应的最优参数, 计算结束; 若否, $G = G + 1$, 转到步骤 3).

为验证 SADE 算法的寻优能力, 将其与自适应遗传算法(SAGA)和传统 DE 算法进行对比, 3 种算法都采用相同的寻优范围和目标函数. 传统 DE 算法的 F 和 CR 分别取 0.7 和 0.9(根据文献[10]的结论并进行试算), 其他参数和 SADE 算法一样. 自适应遗传算法(SAGA)的个体取 50 个, 个体中 γ 和 σ 都采用实数编码, 最大进化代数取 100, 采用轮盘赌法和两位交叉方式, 采用自适应交叉和变异操作^[11](高目标值的个体具有更大的交叉和变异概率), 每代保留种群最优个体.

由于 SAGA、SADE 和 DE 算法的个体是随机产生的, 每个算法都在配置为 CPU Intel Core i5 1.8G、4G DDR 内存的计算机上运行 5 次, 以更好地验证算法的寻优能力. 5 次优化计算得到的最小目标值平均值 \bar{f}_{\min} 和平均目标值平均值 \bar{f}_{avg} 详见图 1、2. 可以看出, SADE 不仅具有最强的全局寻优能力(5 次中最多在 15 代找到最优的个体, 最优个体目标值也最小), 而且具有最快的群体平均进化速度, 从第 7 代起已获得比 DE 和 SAGA 更小的 \bar{f}_{avg} ; DE 算法也

具有较强的全局寻优能力(5 次中最多在 25 代找到最优的个体,最优个体目标值仅次于 SADE),并且具有较快的群体平均进化速度,从第 7 代起已获得比 SAGA 更小的 \bar{f}_{avg} ;SAGA 则具有最差的全局寻优能力(5 次中最多在 50 代才找到最优个体,最优个体的目标值也最大),并且群体平均进化速度最慢,7 代后的 \bar{f}_{avg} 都为最大.

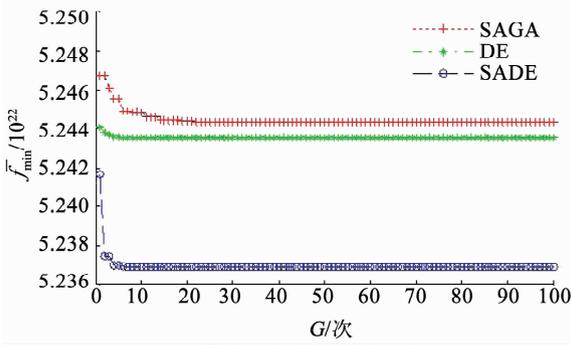


图 1 最小目标值平均值对比

Fig. 1 Comparison of the mean of minimum objective values among three algorithms

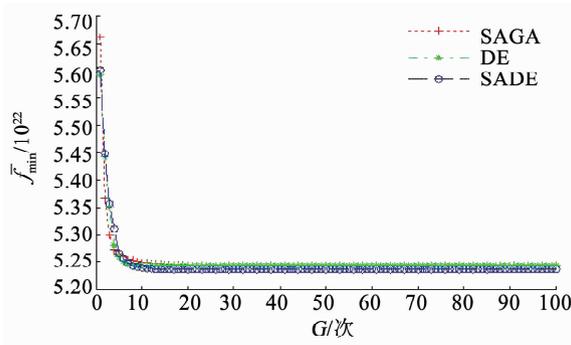


图 2 平均目标值平均值对比

Fig. 2 Comparison of the mean of average objective values among three algorithms

取 5 次计算中最小目标值的对应参数为每个算法优化得到的最优参数,SADE、DE 和 SAGA 算法得到的最优参数分别为(0.435 6,1.284 7)、(0.318 5,1.695 1)和(0.671 4,2.192 3). 分别用各最优参数对 LSSVM 的参数赋值,利用预处理后的 360 组训练测试集训练 LSSVM 模型,然后模型根据预处理后的预测集输入数据对 7 日用水量进行预测,在对预测结果反预处理后,得到图 3 所示的结果.

采用绝对相对误差 e_{APE} 和平均绝对相对误差 e_{MAPE} 来评价各模型的预测结果:

$$e_{APE} = \left| \frac{Y_s - F_s}{Y_s} \right|, \quad (13)$$

$$e_{MAPE} = \frac{1}{S} \sum_{s=1}^S \left| \frac{Y_s - F_s}{Y_s} \right|. \quad (14)$$

式中: F_s 为模型对第 s 天用水量的预测值, Y_s 为第 s 天的实际日用水量, S 为预测总天数.

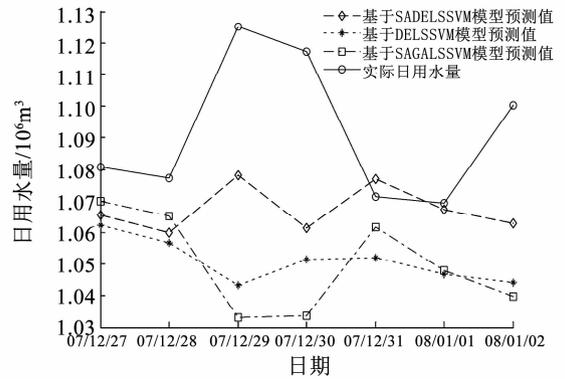


图 3 日用水量预测对比

Fig. 3 Comparison of daily water demand forecasting among three models

对于 2007 年 12 月 27 日—2008 年 1 月 2 日的 7 日用水量,基于 SADELSSVM 模型预测的绝对相对误差分别为 1.4%、1.6%、4.2%、5.0%、0.5%、0.2%、3.4%,绝对相对误差的最大值为 5.0%,平均绝对相对误差为 2.33%. 基于 DELSSVM 模型预测 7 日用水量的绝对相对误差分别为 1.7%、1.9%、7.3%、5.9%、1.8%、2.1%、5.1%,绝对相对误差的最大值为 7.3%,平均绝对相对误差为 3.69%. 基于 SAGALSSVM 模型预测 7 日用水量的绝对相对误差分别为 1.0%、1.1%、8.2%、7.5%、0.9%、2.0%、5.5%,绝对相对误差的最大值为 8.2%,平均绝对相对误差为 3.74%. 由于 12 月 30 日用水量与以前相差较大,基于 SADELSSVM 模型、基于 DELSSVM 模型和基于 SAGALSSVM 模型对该日预测误差都较大,分别为 5.0%、5.9% 和 7.5%. 对于 3 个算法,SADE 算法具有最强的全局寻优能力,DE 算法具有较强的全局寻优能力,因此,基于 SADELSSVM 模型预测误差最小,基于 DELSSVM 模型预测误差较小. 12 月 29 日和 1 月 2 日与以前用水量相差不大,SADE 算法仍能够找到较优的模型参数,因此,基于 SADELSSVM 模型预测误差仅为 4.2%、3.4%. 但限于 DE 和 SAGA 算法的寻优能力,基于 DELSSVM 模型和基于 SAGALSSVM 模型的参数与基于 SADELSSVM 模型的参数有一定偏差,因此,两模型对 12 月 29 日和 1 月 2 日预测的绝对相对误差也较大,预测结果分别为 7.3%、5.1% 和 8.2%、5.5%.

在季节变化时,日用水量一般会有较大变化,预测难度较大,因此,分别利用以上 3 个模型预测该城市 2008 年四季改变后一周的日用水量(3 月 1 日—7 日、6 月 1 日—7 日、9 月 1 日—7 日、12 月 1 日—7 日),以进一步验证本文提出模型的有效性,得到的预测结果见表 1. 可以看出,对于 28 日中每一天的预测结果,基于 SADELSSVM 模型预测精度最高,基

于 DELSSVM 模型预测精度第二, 基于 SAGALSSVM 模型预测精度则最差. 基于 SADELSSVM 模型预测的平均绝对相对误差为 3.56%, 绝对相对误差的最大值为 6.7% (9 月 1 日). 基于 DELSSVM 模型预测的平均绝对相对误差为 4.07%, 绝对相对误差的最大值为 7.1% (6 月 1 日). 基于 SAGALSSVM 模型预测的平均绝对相对误差为 4.49%, 绝对相对误差的最大值为 8.3% (6 月 1 日). 由于 3 月 1 日、3 月 2 日、6 月 1 日、6 月 2 日、9 月 1 日、9 月 2 日、12 月 1 日和 12 月 2 日与以前的日用水量相差较大, 3 个模型对 8 日的预测误差都较大, 但是具有较强全局寻优能力的 SADE 算法仍能根据历史数据搜索到较优参数, 因此, 基于 SADELSSVM 模型对该 8 日的预测误差较小. 由于 DE 算法寻优能力较差, SAGA 算法寻优能力最差, 基于 DELSSVM 模型对该 8 日的预测误差较大, 基于 SAGALSSVM 模型对该 8 日的预测误差最大.

表 1 绝对相对预测误差对比 %

Tab.1 Comparison of absolute relative error among three models

日用水量 预测时间	绝对相对误差		
	基于 SADELSSVM 模型	基于 DELSSVM 模型	基于 SAGALSSVM 模型
3 月 1 日	4.5	4.9	6.4
3 月 2 日	4.7	5.6	5.9
3 月 3 日	2.4	2.7	2.9
3 月 4 日	2.6	3.1	3.2
3 月 5 日	2.8	3.2	3.5
3 月 6 日	2.6	3.2	3.3
3 月 7 日	3.4	3.9	4.2
6 月 1 日	6.5	7.1	8.3
6 月 2 日	5.4	6.3	7.5
6 月 3 日	2.5	3.1	3.3
6 月 4 日	2.9	3.1	3.4
6 月 5 日	3.1	3.3	3.5
6 月 6 日	2.4	2.9	3.2
6 月 7 日	2.2	2.4	2.6
9 月 1 日	6.7	6.9	7.3
9 月 2 日	5.8	6.2	6.8
9 月 3 日	2.9	3.5	3.8
9 月 4 日	3.0	3.6	3.8
9 月 5 日	3.4	3.7	3.9
9 月 6 日	2.2	2.5	2.8
9 月 7 日	3.1	3.4	3.6
12 月 1 日	4.3	5.8	6.5
12 月 2 日	4.2	4.9	6.2
12 月 3 日	2.8	3.3	3.5
12 月 4 日	3.3	3.9	4.2
12 月 5 日	3.1	3.6	3.8
12 月 6 日	4.1	4.5	4.7
12 月 7 日	2.8	3.4	3.6

综上, 基于 SADELSSVM 模型具有最强的预测能力, 基于 DELSSVM 模型具有较强的预测能力, 基于 SAGALSSVM 模型则具有最差的预测能力.

4 结 语

SADE 算法根据个体进化结果自适应调整每个个体的差分向量缩放因子和交叉概率, 较好地解决了传统 DE 算法两参数的确定问题, 而且全面提高了算法的全局搜索能力和收敛速度. 分析结果验证了 SADE 算法具有更强全局寻优能力和更快收敛速度, 也验证了基于 SADELSSVM 模型具有更强的预测能力.

参考文献

- [1] BABEL M S, SHINDE V R. Identifying prominent explanatory variables for water demand prediction using artificial neural networks: A case study of Bangkok [J]. *Water Resources Management*, 2011, 25(6): 1653-1676. DOI: 10.1007/s11269-010-9766-x.
- [2] 袁一星, 兰宏娟, 赵洪宾, 等. 城市用水量 BP 网络预测模型 [J]. *哈尔滨建筑大学学报*, 2002, 35(3): 56-58.
YUAN Yixing, LAN Hongjuan, ZHAO Hongbin, et al. BP model for forecasting urban water consumption [J]. *Journal of Harbin University of C. E. & Architecture*, 2002, 35(3): 56-58.
- [3] 王亮, 汪震, 岳琳. 基于粒子群优化算法的城市日用水量预测模型 [J]. *中国给水排水*, 2007, 23(7): 89-93. DOI: 10.3321/j.issn:1000-4602.2007.07.023.
WANG Liang, WANG Zhen, YUE Lin. Urban daily water consumption forecasting model based on particle swarm optimization [J]. *China Water & Wastewater*, 2007, 23(7): 89-93. DOI: 10.3321/j.issn:1000-4602.2007.07.023.
- [4] MSIZA S, NELWAMONDO F, MARWALA T. Water demand prediction using artificial neural networks and support vector regression [J]. *Journal of Computers*, 2008, 3(11): 1-8. DOI: 10.4304/jcp.3.11.1-8.
- [5] 柳景青. 调度时用水量预测的系统理论方法及应用研究 [D]. 浙江: 浙江大学, 2005.
LIU Jingqing. Study on forecasting model of hourly water consumption for optimal operation [D]. Zhejiang: Zhejiang University, 2005.
- [6] HUANG C L, WANG C J. A GA-based feature selection and parameters optimization for support vector machines [J]. *Expert Systems with Applications*, 2006, 31(2): 231-240. DOI: 10.1016/j.eswa.2005.09.024.
- [7] SUYKENS J A K, GESTEL V T, BRABANTER D J, et al. Least squares support vector machines [M]. Singapore: World Scientific, 2002.
- [8] STORN R, PRICE K V. Differential evolution - a simple and efficient heuristic for global optimization over continuous space [J]. *Journal of Global Optimization*, 1997, 11(4): 341-359. DOI: 10.1023/A:1008202821328.
- [9] GESTEL V T, SUYKENS J A K, BAESENS B, et al. Benchmarking least squares support vector machine classifiers [J]. *Machine Learning*, 2004, 54(1): 5-32. DOI: 10.1023/B:MACH.0000008082.80494.e0.
- [10] STORN R, PRICE K V, LAMPINEN J. Differential evolution: A practical approach to global optimization [M]. Berlin: Springer, 2005.
- [11] SRINIVAS M, PATNAIK L M. Adaptive probabilities of crossover and mutation in genetic algorithms [J]. *IEEE Transactions on System Man and Cybernetics*, 1994, 24(4): 656-667. DOI: 10.1109/21.286385.