

7-2-2020

Mixed H_2/H_∞ Optimal PID Control for Superheated Steam Temperature System

Weiping Liang

Department of Automation, North China Electric Power University, Baoding 071003, China;

Jiarong Wang

Department of Automation, North China Electric Power University, Baoding 071003, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Mixed H_2/H_∞ Optimal PID Control for Superheated Steam Temperature System

Abstract

Abstract: Aiming at the non-linear, large inertial, uncertain parameters and multi-disturbances of the main steam temperature object in power plants, a mixed H_2/H_∞ optimal PID control scheme was designed. The multiplicative perturbed boundary of the H_∞ and the effective range of the PID controller parameters were given under the system being closed-loop stability. An improved gravitational search algorithm was proposed in order to obtain optimum performance indicators. The effectiveness of the algorithm was supported through testing on typical test functions, then the algorithm was applied to optimize the parameters of the main steam temperature system Mixed H_2/H_∞ optimal PID controller. Simulation results show that the optimized main steam temperature control system has good control quality, and unknown disturbance can be overcome, and has strong robustness.

Keywords

mixed H_2/H_∞ control, gravitational search algorithm, main steam temperature system, PID control, robust stability

Recommended Citation

Liang Weiping, Wang Jiarong. Mixed H_2/H_∞ Optimal PID Control for Superheated Steam Temperature System[J]. Journal of System Simulation, 2016, 28(3): 661-667.

日气温多元时间序列局部支持向量回归预测

王定成, 曹智丽, 陈北京, 倪郁佳

(南京信息工程大学计算机与软件学院, 南京 210044)

摘要: 气温预报是天气预报的重要因素之一, 但大气系统是一个复杂的非线性系统, 要提高预报精度, 需要探索新的预报方法。研究一种多元时间序列局部支持向量回归的日气温预测方法, 以日最高、最低气温为例, 使用 C-C 方法和最小预测误差法构造日最高、最低气温的多元时间序列, 将分段提取最近邻点的方法应用于局部支持向量回归, 建立提前 1 天的每日最高、最低气温局部预测模型。以中国 753 站资料包中的数据进行仿真实验, 与欧氏距离提取最近邻点相比, 分段提取最近邻点的方法能有效提高日气温的预测精度。多元时间序列局部预测模型在日气温的短期预测(10 天以内)上比单元时间序列有着更好的应用价值。

关键词: 日气温预测; 多元时间序列; 分段; 最近邻点; 局部支持向量回归

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2016) 03-0654-07

Multivariate Time Series Local Support Vector Regression Forecast Methods for Daily Temperature

Wang Dingcheng, Cao Zhili, Chen Beijing, Ni Yujia

(College of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Daily temperature forecast is an important part in weather forecasting. New methods are explored to improve the prediction accuracy since the atmosphere system is a complex nonlinear system. A model based on multivariate time series and local support vector regression was proposed. After constructing multivariate time-series with C-C method and minimum prediction error method, a way to extract the nearest neighbor from each predictor's sequences was used to build the 1-day ahead local forecasting model for daily maximum and minimum temperature. To demonstrate the effectiveness, the model was applied and tested in data from 753 stations data package of China. Simulation results show that the model can improve prediction accuracy effectively, and has a better application value in short-term daily temperature forecast compared with univariate time series.

Keywords: daily temperature; multivariate time series; segmentation; nearest neighbor; local support vector regression

引言

气温的变化不仅直接关乎人们的衣食住行, 而

且对农业生产过程有着重大影响。然而大气系统是一个复杂的非线性系统, 这决定了气温预测的复杂性, 也促使各领域专家采用不同的方法来研究问题。其中, 基于数据的预测方法是重要的研究手段之一, 常用方法包括时间序列^[1]、神经网络^[2-3]和支持向量回归^[4]等。

文献 [1] 使用差分自回归移动平均模型



收稿日期: 2014-10-27 修回日期: 2015-01-11;
基金项目: 国家自然科学基金(61103141); 江苏省自然科学基金(BK2012858);
作者简介: 王定成(1967-), 男, 安徽霍山, 博士, 研究员, 研究方向为智能计算; 曹智丽(1989-), 女, 江苏常州, 硕士, 研究方向为智能计算。

<http://www.china-simulation.com>

• 654 •

(AutoRegressive Integrated Moving Average Model, ARIMA)预测全球年平均气温, 研究表明基于权重的 ARIMA 比传统的 ARIMA 预测效果更好, 但 ARIMA 只适用于单元时间序列。文献[3]使用基于遗传算法的神经网络建立孟加拉国达卡的提前一天日气温预测模型, 实验表明该方法在当地气温的预测上优于模糊神经网络、ARIMA 方法。但神经网络解决问题常依赖于专家的经验, 缺乏理论依据。支持向量回归(Support Vector Regression, SVR)具有严格的数学理论基础, 能有效解决在小样本情况下的非线性回归问题, 在保证泛化能力的同时获得全局最优模型, 在天气预测和灾难预报方面得到了广泛应用。文献[4]在 3 种隶属度函数的基础上, 设计了基于平方平均隶属度函数的模糊支持向量机对带有间断噪声的自动站日平均气温数据进行了插补实验, 实验证明其优于传统支持向量回归的性能。

局部 SVR 近年来在风功率预测中得到广泛应用^[5]。在对混沌时间序列的预测上, 局部 SVR 的预测精度要优于全局 SVR^[6]。局部 SVR 通过寻找预测点的邻近相点建立局部预测模型, 模型能随时间变化自动更新参数, 具有很好的动态性。因此, 局部 SVR 模型能更好地反映日气温的变化趋势。

目前, 国内外学者在进行气温时间序列预测研究时, 多使用单元时间序列建模, 但实际的气温变化是多种气象因素相互作用的结果, 体现多个变量描述事物状态思想的多元时间序列(Multivariate Time Series, MTS)更符合实际的气温变化规律。因此, 本文研究多元时间序列 SVR 日气温局部预测模型。

1 日气温多元时间序列相空间重构

1.1 相空间重构原理

基于 Takens 嵌入定理^[7-8]的相空间重构理论是研究时间序列的常用方法。时间序列相空间重构的目的是将时间序列变换到能有效反映其特征的高维状态空间, 并在此状态空间对时间序列特征进行

研究。已知日气温时间序列 X 和其他可选的气象因素时间序列 MF_t , $t=1,2,\dots,L$ 构成了 $L+1$ 维日气温多元时间序列, MF_t 表示第 t 个气象因素, 该时间序列相空间重构的相点如式(1), 而构造相点集 $\mathbf{X}=(x_1, x_2, x_3, \dots, x_n)$ 的过程就叫多元时间序列的相空间重构。

$$\begin{aligned} X_n = & (MF_{1,n}, MF_{1,n-\tau_1}, MF_{1,n-2\tau_1}, \dots, MF_{1,n-(m_1-1)\tau_1}, \\ & MF_{2,n}, MF_{2,n-\tau_2}, MF_{2,n-2\tau_2}, \dots, MF_{2,n-(m_2-1)\tau_2}, \dots, \\ & MF_{L,n}, MF_{L,n-\tau_L}, MF_{L,n-2\tau_L}, \dots, MF_{L,n-(m_L-1)\tau_L}) \end{aligned} \quad (1)$$

式(1)中: X_n 表示日气温在第 n 个时间点上的值, $n=1,2,\dots,N$; τ_t 和 m_t 分别是 MF_t 的延迟时间和嵌入维数。根据 Takens 嵌入定理, 当嵌入维数 m , $m=m_1+m_2+\dots+m_L > 2D$ 时(D 为吸引子维数), 存在映射 $F: \mathbf{R}^m \rightarrow \mathbf{R}^m$, 使得

$$x_{n+1} = F(X_n) \quad (2)$$

由式(2)可知, 要预测下一日的气温 x_{n+1} , 需要构造多元时间序列相点集 \mathbf{X} , 对映射模型 F 求解。

1.2 气象因素的选取

日气温多元时间序列由日气温时间序列 X 和其他可选的气象因素时间序列 MF_t , $t=1,2,\dots,L$ 共同构成, 气象因素指影响其他事物发展变化的气象原因或条件, 主要包括温、压、湿、风、太阳辐射等。鉴于不同气象因素对气温变化的作用不尽相同, 使用式(3)计算相关系数作为选择的依据。

$$R_t = \frac{\text{Cov}(X, MF_t)}{\sigma_X \cdot \sigma_{MF_t}} \quad t=1,2,\dots,S \quad (3)$$

式(3)中: σ_X , σ_{MF_t} 分别是序列 X , MF_t 的标准差; R_t 和 $\text{Cov}(X, MF_t)$ 为 X , MF_t 两者的相关系数和协方差, S 是备选气象因素总数。相关系数 R 是反映变量之间相关关系密切程度的统计指标, 实际应用时需同时进行显著性水平检验。

1.3 相空间重构参数计算

1.3.1 参数计算方法

延迟时间 τ 和嵌入维数 m 是多元时间序列相空间重构的 2 个重要参数。相空间重构关联积分 C-C 方法^[9-10]考虑延迟时间和嵌入维数选取的相互

依赖性,同时获得延迟时间和嵌入维数的估计值。考虑到现实气象数据不可避免的受到噪声数据的干扰,先采用 C-C 方法求取各时间序列的延迟时间和嵌入维数的取值范围,再以最小预测误差法得出两者的最优组合。

1.3.2 最小预测误差法

最小预测误差法^[11]是根据下一步预测的最小误差为时间序列 MF 确定最优的延迟时间 τ 和嵌入维数 m 组合,算法见算法一。

算法一: 最小预测误差算法

1. Input : MF , size $N \times 1$
2. Initialize τ, m
3. Apply C-C method, Get $\tau \in [a, b], m \in [c, d]$
4. for $\tau = a$ to b do
5. for $m = c$ to d do
6. Phase space Reconstruction
7. Get new sample set $\{y, x\}$,
size $L \times (1+m), L = N - (m-1)\tau - 1$
8. Divide $\{y, x\}$ into:
Train: $\{yT, xT\}$, size $l \times (1+m), l < m$
Test: $\{yE, xE\}$, size $(L-l) \times (1+m)$
9. for $j=1$ to $L-l$ do
10. Compute K nearest points for (yE_j, xE_j)
11. Get nearest neighbor set $\{yK, xK\}$
12. predicted value $tE_j = \text{avg} \sum yK$
13. end for
14. Compute $E_{\tau, m} = \text{avg} \sum (yE - tE)$
15. end for
16. end for
17. $(\tau_{\text{best}}, m_{\text{best}}) = \arg \min \{E_{\tau, m} : (\tau, m)\}$
18. Output $\tau_{\text{best}}, m_{\text{best}}$

对所有 L 个气象因素执行最小预测误差法,确定每一个气象因素延迟时间和嵌入维数的最优组合,完成日气温多元时间序列的相空间重构。

2 日气温建模

2.1 支持向量回归原理

支持向量回归是统计学习理论^[12]的重要内容,通过引入核函数的概念,将输入向量映射到一个高维的特征向量空间,并在高维特征空间构造最优回归函数,解决非线性回归问题。对于给定样本集

$$(x_i, y_i), i=1, 2, 3, \dots, l, x_i \in \mathbf{R}^n, y_i \in \mathbf{R} \quad (4)$$

根据结构风险最小化原则,用线性回归函数 $f(x) = w \cdot x + b$ 拟合样本数据,在样本集中求解最优回归函数。

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (5)$$

$$\text{s.t.} \begin{cases} y_i - w \cdot x_i - b \leq \varepsilon + \xi_i \\ w \cdot x_i + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (6)$$

式(5)~(6)中, ε 为损失精度,考虑到允许拟合误差的情况,引入了松弛变量 ξ_i 和 ξ_i^* , C 为惩罚变量。利用 Lagrange 优化方法把上述问题转化为其对偶问题,并引入核函数 $k(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ 将数据映射至高维空间。通过二次规划方法求得 α_i, α_i^* , 得出最优回归函数(7):

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i \cdot x) + b \quad (7)$$

根据泛函的有关理论,核函数 $k(x_i, x_j)$ 满足 Mercer 条件^[12],它就对应某一变换空间中的内积。核函数种类很多,主要有:多项式函数 $k(x_i, x) = [(x_i + x) + 1]^q$, 高斯径向基函数 $k(x_i, x) = \exp(-\|x_i - x\|^2 / (2g)^2)$, Sigmoid 函数 $k(x_i, x) = \tanh(v(x_i \cdot x) + c)$ 等。

2.2 多元时间序列局部支持向量回归

局部支持向量回归^[13](Local Support Vector Regression, LSVR)是在 SVR 方法的基础上引入局部预测思想,对样本建立局部预测模型。多元时间序列局部支持向量回归,即在相空间重构后,通过

计算预测点 X_n 和其他点之间的距离, 得出最邻近点集合建立 SVR 模型进行预测。LSVR 模型能够自动更新, 动态地捕获时间序列的变化信息, 在样本集数据量较大的情况下有效缩短训练时间, 建模步骤如下:

步骤 1: 在多元时间序列重构的相空间中, 计算预测点 X_n 与其他历史点的距离, 选择距离最小的 K 个最近邻点组成近邻点集合 U_n 。

步骤 2: 将 U_n 作为 SVR 的训练集, 使用优化算法对 SVR 参数寻优, 得到 LSVR 模型, 将预测点 X_n 输入模型获得预测值 x_{n+1} 。

2.3 最近邻点的选取

局部支持向量回归算法的预测精度依赖于近邻点的选取, 一般采用欧氏距离公式计算得出最近邻点。文献[6]指出当时间序列嵌入维数较小时, 欧氏距离公式所确定的最邻近相点基本上能反映它与原相点的相关程度, 但当维数逐渐增大时, 这种效果会逐渐降低。由多个变量构成的多元时间序列的维数总和相当大, 但每个变量单独的嵌入维数却不是很高。而不同气象因素与当日最高、最低气温的相关程度各不相同, 因此在选取最近邻点建立局部模型时, 为了最小化气象因素互相之间的影响, 同时保留每个因素对气温变化的作用, 采用了分段提取最近邻点的方法。

对于预测点 X_n , 分别计算组成 X_n 的每一个气象因素与其他点的相同气象因素之间的欧式距离

$D_{n,j,t}$ 。

$$D_{n,j,t} = \|X_n \{MF_t\} - X_j \{MF_t\}\|, \quad (8)$$

$$j = 1, 2, \dots, n-1; t = 1, 2, \dots, L$$

式(8)中, $X \{MF_t\}$ 表示在样本点 X 中由第 t 个气象因素构成的一段序列。对所有 $D_{n,j,t}$ 依次排序, 选取每次排序后前 K 个距离最小的样本点, 共同组成近邻点集合 U_n , 其中近邻点的个数属于集合 $[K, L \cdot K]$ 。

2.4 预测流程

文献[9-10]提出在实际应用于现实数据预测时, 相空间重构的参数其实是不稳定的, 需要根据实际情况更新。综上所述, 日气温多元时间序列局部支持向量回归预测算法见算法二。

算法二

1. 输入: 日气温多元时间序列 $\{X, MF\}$
2. IF τ, m 需要更新 DO
3. 初始化: τ, m
4. 使用 C-C 方法和最小预测误差法
5. 得到最优集 $\{\tau_{best}, m_{best}\}$
6. END IF
7. 日气温多元时间序列相空间重构
8. 得到样本集 $X: \{x_{n+1}, X_n\}$
9. 分段提取预测点最近邻点组成近邻点集合 U
10. 建立 LSVR 预测模型, 得到预测值 Y
11. 评价预测结果, 若预测误差过大, 转 line 2
12. 输出: 预测值 Y

3 日气温预测实例

3.1 日气温预测模型

实验使用的数据来自中国 753 站资料包, 取站点 58 238 的数据进行研究, 选取了 1996~2012 年的每日气象数据, 共 6 210 天。

该气象数据一共包括 0~20 时降水量、极大风速和风向、平均本站气压、平均风速、平均气温、平均水汽压、平均相对湿度、日照时数、日最低本站气压、日最高本站气压、日最低气温、日最高气温、最大风速和最大风速的风向以及最小相对湿度 16 个气象因素。由于气象因素之间存在极大的数据差异, 依照式(9)进行数据归一化。

$$s = \frac{s - s_{\min}}{s_{\max} - s_{\min}} \quad (9)$$

将日最低气温(Daily Minimum Temperature, DMIT)和日最高气温(Daily Maximum Temperature,

DMAT)作为预测目标,其他气象因素作为备选,按1.2节的方法选出参与建模的气象因素。由于所有气象因素和日气温的相关系数 R 都通过了显著性水平检验,而当 $R \geq 0.3$ 时,表示变量之间存在中等强度以上的相关性,所以以此作为气象因素入选标准。依照第1.3节的最小预测误差法为每个入选的气象因素选取最合适的延迟时间和嵌入维数,初始的延迟时间范围为 $\tau \in [1, 11]$,嵌入维数范围为 $m \in [3, 11]$,最邻近点个数 $K = 10$,表1给出了最终的因子筛选结果。

表1 入选的气象因素及其相空间重构参数

入选气象因素	相关系数		相空间重构参数	
	DMIT	DMAT	τ	m
平均气温	0.98	0.98	1	8
平均水汽压	0.95	0.88	1	7
日最低气温	1	0.92	9	10
日最高气温	0.92	1	7	4
日最高本站气压	-0.89	-0.87	6	4
平均本站气压	-0.87	-0.85	3	8
日最低本站气压	-0.85	-0.83	4	10
最小相对湿度	0.30	-	3	6
日照时数	-	0.33	11	4

根据得出的延迟时间和嵌入维数对日气温多元时间序列相空间重构,设置对比实验一,分别采用常见的欧式距离公式获取最近邻点方法($K = 50$)和本文提出的分段提取最近邻点方法($K = 10$)进行日气温多元时间序列LSVR预测。设置对比实验二,分别用气象时间序列预测中常用的单元时间序列LSVR方法($K = 50$)和多元时间序列LSVR方法预测日气温。建立局部支持向量回归模型,核函数采用高斯径向基核函数,使用粒子群优化算法^[14]对模型参数进行寻优,保证模型的学习能力和泛化能力。

图1是日最低气温预测结果,图2是日最高气温预测结果,预测误差分别如图3~4所示。观察图1~4,可以看出分段提取最近邻点方法能有效提高预测精度,而多元时间序列的预测结果多数情况下要优于单元时间序列。

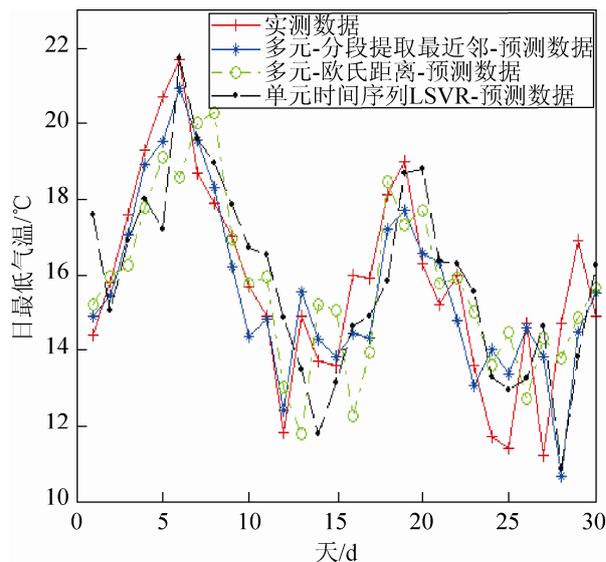


图1 2012年58238站点30天日最低气温预测结果

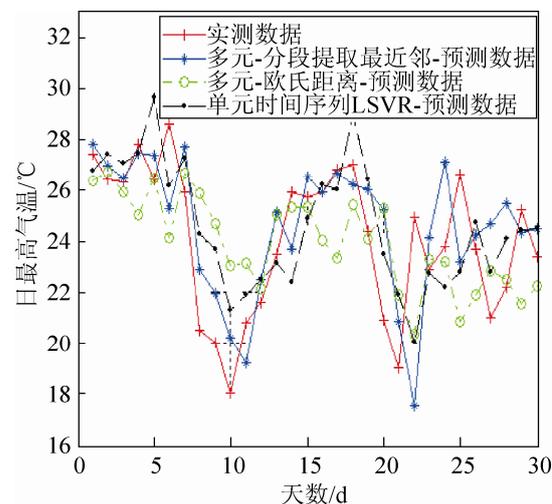


图2 2012年58238站点30天日最高气温预测结果

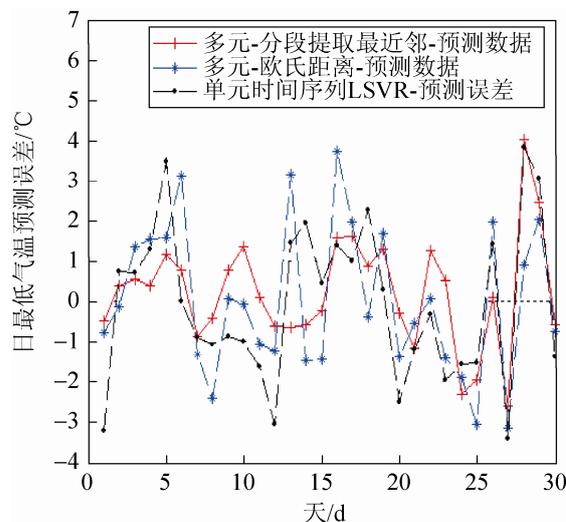


图3 2012年58238站点30天日最低气温预测误差

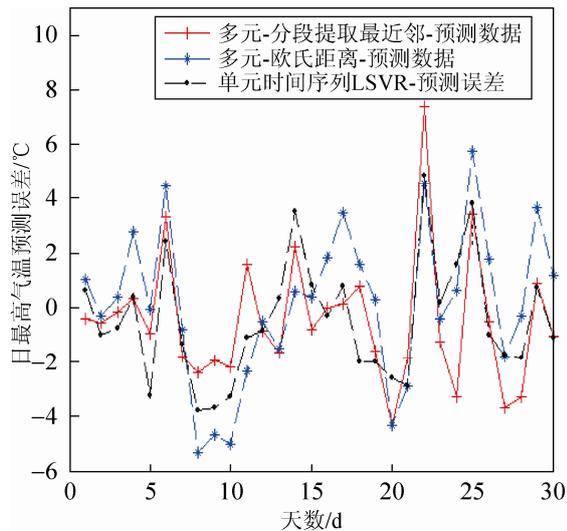


图 4 2012 年 58 238 站点 30 天日最高气温预测误差

3.2 预测结果评价

为定量评价预测结果,采用常见的气象回归预测评价方法:平均绝对误差 E_{MAE} 、均方根误差 E_{RMSE} 和对比实验中误差减少的百分比 I 来评价模型的预测效果。

$$E_{MAE} = \frac{1}{N'} \sum_{i=1}^N \left| \hat{x}_i - x_i \right| \quad (10)$$

$$E_{RMSE} = \sqrt{\frac{\sum_{i=1}^N \left(\hat{x}_i - x_i \right)^2}{N'}} \quad (11)$$

$$I = \frac{E_c - E}{E_c} \times 100\% \quad (12)$$

式(10)~(12)中: \hat{x}_i 为气温的预测值; x_i 为气温的实测值; N' 为测试集样本的个数。表 2 中百分比 I_1 为使用分段提取最近邻点方法对比欧氏距离方法减少的预测误差率, I_2 为使用多元时间序列建模对比单元时间序列减少的预测误差率。

分析 3.1 节 30 天的日气温预测结果时,除了评价 30 天总预测误差(1-30 d),还将预测结果分成第 1 个 10 天(1-10 d)、第 2 个 10 天(11-20 d)和第 3 个 10 天(21-30 d) 3 个阶段进行分析,结果如表 2 所示。从表 2 可以看出,基于多元时间序列的日气温局部预测模型在短期内(10 天以内)的预测效果

比较良好,日最低气温的预测平均绝对误差在 0.7°C ,日最高气温在 1.4°C 。文献[4]指出由于气温数据具有较强的随机性,因此模型具有 1°C 左右的误差是可以接受的。随着时间的延长,特别是在 20 天以后,模型的预测精度显著下降。20 天以后均方根误差明显增大,预测值和真实值偏差越来越大,模型在逐渐失效。

表 2 不同时间段的日气温预测效果

类别	时间间隔/d	$E_{MAE}/^\circ\text{C}$	$E_{RMSE}/^\circ\text{C}$	$I_1/\%$	$I_2/\%$
最低气温	1-10	0.69	0.77	44.25	45.84
	11-20	0.79	0.95	54.72	51.34
	21-30	1.69	2.04	-7.33	13.57
	1-30	1.06	1.37	30.42	34.66
最高气温	1-10	1.45	1.75	41.92	31.19
	11-20	1.40	1.83	17.25	2.59
	21-30	2.66	3.29	-16.01	-34.05
	1-30	1.83	2.40	14.96	0

I_1 表示本文所使用的分段排序提取最近邻点的方法使日最低气温预测误差下降了 30% 以上,在 20 天以内有效提高了预测精度,对日最高温度的预测短期内也有着良好的作用。这表明分段排序提取最近邻点的方法更能保留每个气象因素对气温的作用,提取的最近邻点更接近预测点的实测值。 I_2 说明使用多元时间序列建模的预测结果要优于使用单元时间序列,预测误差最高下降 50%。

仿真实验中,30 天日最高气温的预测精度不如日最低气温,计算两样本该 30 天序列的自相关系数,见式(13),计算结果如图 5 所示。

$$r_k = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2} \quad (13)$$

时间序列的平稳性表现在随着阶数 k 的增加,序列的自相关系数 r 下降并趋于 0,图 5 中日最低气温的自相关系数下降速度快于日最高气温,说明预测的 30 天日最低气温序列的平稳性较好于日最高气温序列,导致前者预测结果精度高于后者。

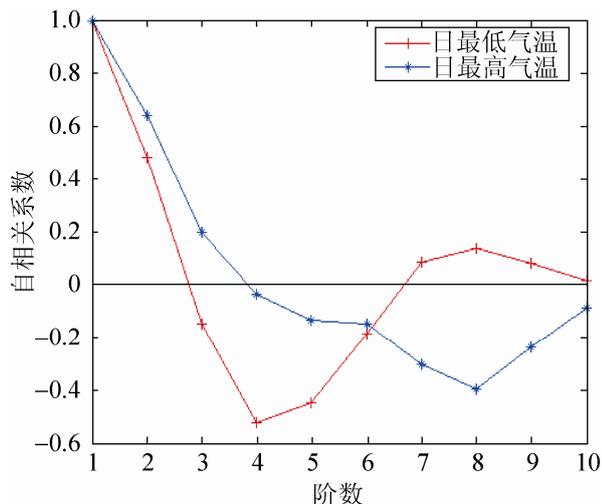


图 5 30 天日气温时间序列各阶自相关系数

4 结论

本文提出了一种针对每日气温数据的多元时间序列局部预测模型。通过对不同气象因素的时间序列数据进行处理,使用 C-C 方法和最小预测误差法求取每个序列的延迟时间和嵌入维数,构造日气温多元时间序列样本集。为了保留每个气象因素对气温变化的作用,采用分段提取最近邻点的方法建立 SVR 局部预测模型。通过仿真实验,基于每日气温数据的多元时间序列 SVR 局部预测模型在短期内(10 天以内)能够更好的实现日最低、最高气温的提前一天的预测,分段排序提取最近邻点的方法有效地选取了更符合预测目标特征的最近邻点集合,提高了预测精度。

参考文献:

[1] Narendra Babu C, B Eswara Reddy. Predictive Data Mining on Average Global Temperature Using Variants of ARIMA models [C]// IEEE, Advances in Engineering,

Science and Management. USA: IEEE, 2012: 75-80.

- [2] 金志风, 符国槐, 黄海静, 等. 基于 BP 神经网络的杨梅大棚内气温预测模型研究 [J]. 中国农业气象, 2011, 32(3): 362-367.
- [3] Shipra Banik, Mohammed Anwer. Soft Computing Models to Predict Daily Temperature of Dhaka [C]// IEEE, Computer and Information Technology. USA: IEEE, 2010: 256-260.
- [4] 张颖超, 郭栋, 熊雄. 自动站气温数据异常的补偿方法[J]. 计算机应用, 2014, 34(3): 888-891, 897.
- [5] 张宜阳, 卢继平, 孟洋洋. 基于经验模式分解和混沌相空间重构的风电功率短期预测 [J]. 电力系统自动化, 2012, 36(5): 24-28.
- [6] 朱志宇, 姜长生, 张冰. 基于支持向量回归的混沌序列预测方法 [J]. 电工技术学报, 2005, 20(6): 57-61.
- [7] 行鸿彦, 龚平, 徐伟. 嵌入窗方法确定混沌系统重构参数的仿真研究 [J]. 系统仿真学报, 2013, 25(6): 1219-1225. (Xing Hongyan, Gong Ping, Xu Wei. Simulation Research of Chaos System Reconstruction Parameters Based on Embedded Window [J]. Journal of System Simulation (S1004-731X), 2013, 25(6): 1219-1225.)
- [8] 陆振波, 蔡志明, 姜可宇, 等. 基于改进的 C-C 方法的相空间重构参数选择 [J]. 系统仿真学报, 2007, 19(11): 2527-2529, 2538. (Lu Zhenbo, Cai Zhiming, Jiang Keyu. Determination of Embedding Parameters for Phase Space Reconstruction Based on Improved C-C Method [J]. Journal of System Simulation (S1004-731X), 2007, 19(11): 2527-2529, 2538.)
- [9] 黄磊, 舒杰, 姜桂秀. 基于多维时间序列局部支持向量回归的微网光伏发电预测 [J]. 电力系统自动化, 2014, 38(5): 19-24.
- [10] Vapnik V N. The nature of statistical learning theory [M]. New York, USA: Springer, 1995: 280-292.
- [11] 尹传环, 牟少敏, 田盛丰. 局部支持向量机的研究进展 [J]. 计算机科学, 2012, 39(1): 170-174.
- [12] 唐贤伦, 李洋, 李鹏. 多智能体粒子群优化的 SVR 模型预测控制 [J]. 控制与决策, 2014, 29(4): 593-598.