

# 基于相空间重构与 最小二乘支持向量机的时延预测

田中大<sup>1</sup>, 张 超<sup>1</sup>, 李树江<sup>1</sup>, 王艳红<sup>1</sup>, 沙 毅<sup>2</sup>

(1. 沈阳工业大学信息科学与工程学院, 辽宁沈阳 110870; 2. 东北大学计算机科学与工程学院, 辽宁沈阳 110819)

**摘 要:** 针对网络控制系统的时延预测问题, 提出一种基于相空间重构与最小二乘支持向量机的时延预测方法. 首先利用 0-1 测试法确定时延序列具有混沌特性, 引入相空间重构技术提高预测精度. 对实际采集的时延序列进行 Hurst 指数分析, 选择最小二乘支持向量机作为预测模型. 然后利用 C-C 方法确定时延序列相空间重构参数, 通过递归图确定时延序列的局部可预测性, 利用遗传算法对最小二乘支持向量机的参数进行离线优化. 最后通过优化后的最小二乘支持向量机并结合相空间重构对时延序列进行在线预测. 与其它预测方法进行了仿真对比, 结果表明本文方法具有更高的预测精度与更小的预测误差, 同时并未降低预测算法的实时性.

**关键词:** 网络控制系统; 相空间重构; 最小二乘支持向量机; 时延预测

**中图分类号:** TP273      **文献标识码:** A      **文章编号:** 0372-2112 (2017)05-1044-08

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2017.05.003

## Time-Delay Prediction Based on Phase Space Reconstruction and Least Squares Support Vector Machine

TIAN Zhong-da<sup>1</sup>, ZHANG Chao<sup>1</sup>, LI Shu-jiang<sup>1</sup>, WANG Yan-hong<sup>1</sup>, SHA Yi<sup>2</sup>

(1. College of Information Science and Engineering, Shenyang University of Technology, Shenyang, Liaoning 110870, China;

2. School of Computer Science and Engineering, Northeastern University, Shenyang, Liaoning 110819, China)

**Abstract:** In order to solve time-delay prediction problem of networked control system, a time-delay prediction method based on phase space reconstruction and least squares support vector machine is proposed in this paper. Firstly, 0-1 test algorithm for chaos is used to determine the chaotic characteristics of the time-delay sequence, and the phase space reconstruction technique is introduced to improve the prediction accuracy. The Hurst exponent of the real time-delay sequence is analyzed, and least squares support vector machine is selected as the prediction model. Then, C-C method is used to determine the parameters of phase space reconstruction. The partial predictability of time-delay is determined by recurrence plot. The parameters of least squares support vector machine are off-line optimized by genetic algorithm. Finally, the time-delay sequence is predicted by the optimized least squares support vector machine combined with the phase space reconstruction. Compared with other prediction methods, the simulation results show that the proposed method has higher prediction accuracy and smaller prediction error, and does not reduce the real-time performance of the algorithm.

**Key words:** networked control system; phase space reconstruction; least squares support vector machine; time-delay prediction

## 1 引言

网络控制系统的时延受网络拓扑结构、网络所采用的通信协议、路由算法、网络负载情况、网络传输速率以及数据包大小等因素的影响. 因此, 网络控制系统中

的时延具有时变、随机、非线性等特征. 随机变化的时延是影响系统性能的一个重要的因素<sup>[1]</sup>, 过大的时延会导致控制系统性能下降. 如何对网络控制系统时延进行精确的预测是一个重要的研究课题, 通过时延的预测, 控制系统可以提前做出反应与控制<sup>[2,3]</sup>.

针对网络控制系统的时延预测问题,很多学者进行了相关的研究工作。一些学者试图归纳时延序列的数学统计规律,建立时延序列的数学分布模型,这里包括文献[4]的马尔可夫分布模型,文献[5,6]的平移伽马分布等。但是这些数学模型建立过程过于理想化,同时模型中的分布参数难以求解,这些都极大的限制了基于统计分析预测方法的应用。其他学者则利用时延样本对时延序列进行建模与预测。按照选择模型的不同可分为线性预测模型与非线性预测模型。线性预测模型将时延序列视为平稳的时间序列,线性模型的代表主要为自回归模型<sup>[7,8]</sup>(Auto Regressive, AR)与自回归滑动平均模型<sup>[9]</sup>(Auto Regressive Moving Average, ARMA)。线性模型比较适合于季节性、周期性等特征平稳的时间序列预测。但是由于网络时延动态变化范围大、随机性强,因此线性预测模型不能全面反映时延序列的复杂变化特征,使得预测的精度受到限制。相对于线性模型,文献[10~13]使用神经网络作为时延预测模型,文献[14]利用支持向量机(Support Vector Machines, SVM)对时延进行预测,文献[15,16]则使用了最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)作为预测模型。虽然仿真与实际实验结果表明非线性模型较线性模型的预测精度有所提高,但也都存在一些问题。基于神经网络的时延预测方法易限于局部最优值以及过分依赖输入时延序列的自相关系数;而 SVM 或 LSSVM 预测模型的参数没有统一的确定方法,如何对于模型参数进行优化是一个需要解决的问题。

虽然上述学者对于网络控制系统的时延预测问题进行了大量的研究工作,但是目前的研究存在着一个主要的问题:没有对时延序列的特性进行分析,也即预测模型的选择上存在着盲目性;同时这些研究方法都没有考虑到时延序列的混沌特性,而实际网络控制系统是一个时变的复杂系统,因此网络时延具有高度的非线性和不确定性。如果利用符合网络时延特性的非线性动力学理论进行建模并预测,就可提高时延的预测精度和可信度。目前,一些学者将混沌理论引入了实际的时间序列的预测之中,如文献[17]中的多相催化剂失活过程预测、文献[18]中的网络流量预测等。但是这些研究并未对其研究对象进行混沌特性的分析,如果对象不具备混沌特性,那么相空间重构技术的引入并不一定会带来预测精度的提高,相反会带来模型泛化能力的降低。

综上所述,本文将网络控制系统时延预测作为研究问题,利用 0-1 测试法对网络时延序列进行分析,确定了时延序列具有混沌特性。在此基础上,引入相空间重构技术来提高预测精度。在预测模型的选择上,通过

Hurst 指数分析,表明时延序列具有自相似性、非线性以及长相关的特性,因此选择 LSSVM 作为预测模型。针对 LSSVM 预测模型参数难以确定的问题,利用遗传算法对 LSSVM 预测模型中的超参数进行离线优化。最后通过相空间重构与 LSSVM 对时延序列进行在线预测。与其它预测方法进行了预测精度与算法复杂性的仿真对比,结果表明本文预测方法的有效性。

## 2 时延序列特性分析

通过时延测试软件采集了基于以太网的网络控制系统中 500 组时延数据,如图 1 所示。

从图 1 中可观察到,实际采集的网络时延序列具有一定的随机时变的特征,因此对时延序列进行特性分析是进行预测的前提与基础。




图1 时延序列样本




### 2.1 时延序列混沌特性分析

时间序列的混沌特性可通过 0-1 混沌测试法进行判定。如果时间序列的增长率  $K_c \approx 1$ , 则说明时间序列具有混沌特性;如果  $K_c \approx 0$ , 则表明时间序列不具有混沌特性<sup>[19]</sup>。利用 0-1 混沌测试法对实际采集的网络时延序列进行了分析,可得到图 2 所示的  $p(n)$  与  $q(n)$  的相图,图 3 所示的均方位移  $M(n)$  的变化图,图 4 所示的渐进增长率  $K_c$  的变化图。

从图 2~图 4 可观察到,网络时延序列的  $p(n)$  与  $q(n)$  的相图呈现布朗特性,均方位移  $M(n)$  随时间线性增长。同时计算可得到渐进增长率  $K_c$  为 0.9957,其  $K_c$  接近于 1,说明网络时延序列具有混沌特性。因此,本文后面将引入相空间重构技术来提高时延的预测精度。

### 2.2 时延序列相似性特性分析

Hurst 指数  $H$ <sup>[20]</sup> 可用来衡量时间序列的相似性。当  $H=0.5$  时时间序列是随机的,说明事件之间不相关;当  $H \in [0, 0.5)$  时表明时间序列是反持久性的;当  $H \in (0.5, 1)$  时表示时间序列是持久性的,也即具有自相似性。因此 Hurst 指数越大说明时间序列的自相似(长相关)程度越高、时间序列可预测性越强、预测误差越小<sup>[21]</sup>。时间序列的 Hurst 指数可通过 R/S 类分析方法(rescaled range analysis)进行计算,过程如下:

图2  $p(n)$ 与 $q(n)$ 的相图图3 均方位移 $M(n)$ 变化图图4 渐进增长率 $K_c$ 变化图

$$(R/S)_n = An^H \quad (1)$$

式中: $n$ 表示样本个数; $R$ 表示重新标度的极差,即 $R = \max(X_{l,n} - \min X_{l,n})$ , $l = 1, 2, \dots, n$ ;  $S$ 为序列的标准差; $H$ 为Hurst指数; $A$ 为一常值. 利用 $\lg(R/S)_n$ 与 $\lg n$ 的关系图,通过最小二乘法计算关系图的斜率即可得到Hurst指数.

通过R/S类分析方法对采集的时延序列进行分析与计算,结果如图5所示.

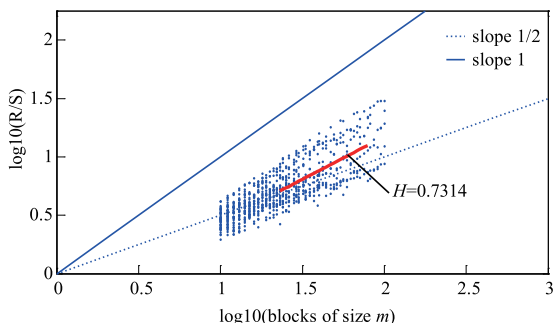


图5 时延序列的Hurst指数

计算关系图的斜率可得到时延序列的Hurst指数是0.7314,满足 $0.5 < H < 1$ ,说明时延序列具有自相似性、非线性以及长相关的特性. 相关研究表明LSSVM模型对于非线性和长相关的时间序列具有良好的预测性能,因此选择LSSVM作为时延序列的预测模型. 针对LSSVM预测模型中参数难以确定的问题,选择具有良好全局优化能力的遗传算法对预测模型的参数进行优化.

### 3 相空间重构

相空间重构是非线性动力学理论应用的重要基础,是混沌时间序列非线性预测与刻画时间序列动力学特征不变量的计算前提. 混沌时间序列的判定、分析与预测都是在重构相空间中进行的<sup>[22]</sup>. 通过上文的0-1测试法的分析表明时延序列具有混沌特性,因此相空间重构技术的引入可提高网络时延序列的预测精度.

相空间重构技术是通过观察系统的一个或多个分量,将其在某些固定时间延迟点上的观测量作为新的坐标,由它们来确定多维状态空间的另一点. 对于本文

的时延序列 $d_1, d_2, \dots, d_N$ ,  $N$ 为序列的长度,可通过得到合适的嵌入维数 $m$ 和延迟变量 $\tau$ 来构造一 $m$ 维相空间.

$$D_i = [d_i, d_{i+\tau}, \dots, d_{i+(m-1)\tau}] \quad (2)$$

其中: $i = 1, 2, \dots, N - (m-1)\tau$ .

本文利用C-C方法进行 $m$ 与 $\tau$ 的选取<sup>[23]</sup>,该方法认为 $m$ 与 $\tau$ 具有相关性,通过关联积分来得到时延序列的最优延迟 $\tau_d$ 与数据依赖的最大时间 $\tau_w$ . 延迟时间 $\tau_d$ 确保 $d_i$ 相互依赖,但不依赖于 $m$ . 而时间窗口 $\tau_w$ 依赖 $m$ 且随 $m$ 变化<sup>[17]</sup>. 由于C-C方法利用统计结果获得,因此运算量少,实现简单. C-C方法计算过程如下.

取 $m = 2, 3, 4, 5$ ;  $r_i = i \times 0.5\sigma$ ,  $i = 1, 2, 3, 4$ ,  $\sigma$ 为时延序列标准差,按照下列公式进行参数计算.

$$\bar{S}(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{i=1}^4 S(m, r_i, t) \quad (3)$$

$$\Delta\bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, t) \quad (4)$$

$$S_{cor}(t) = \Delta\bar{S}(t) + |\bar{S}(t)| \quad (5)$$

上述公式中的 $\bar{S}(t)$ 与 $\Delta\bar{S}(t)$ 可反映时延序列的自相关特征,寻找 $\Delta\bar{S}(t)$ 的第一个局部极小值或 $\bar{S}(t)$ 的第一次过零点所对应的 $t$ 可作为最优延迟时间 $\tau$ . 同时考虑 $\bar{S}(t)$ 与 $\Delta\bar{S}(t)$ ,最佳嵌入窗 $\tau_w$ 可通过寻找 $S_{cor}(t)$ 的全局极小值对应的 $t$ 来得到. 根据式(6)即可求取最佳的嵌入维数 $m$ .

$$\tau_w = (m-1)\tau_d \quad (6)$$

### 4 最小二乘支持向量机

标准的SVM算法求解二次规划问题时非常复杂,因此Suykens等在标准SVM基础上将SVM中损失函数设为误差平方和,将不等式约束改为等式约束,减少了待定参数,同时将二次规划问题转化为线性方程组求解,降低了算法求解的复杂度<sup>[24]</sup>.

LSSVM用如下形式的函数对网络控制系统时延进行估计<sup>[25]</sup>:

$$y = \mathbf{w}^T \Phi(x) + b \quad (7)$$

输入空间通过非线性函数 $\Phi(\cdot)$ 映射到高维的特征空间,使得输入空间的非线性拟合问题转变为高维特征空间的线性拟合问题. 给定延序列的训练集 $\{x_i$ ,

$y_i\}, i = 1, 2, \dots, N$ , 根据风险最小化原理, 回归问题可以表示为如下的约束优化问题:

$$\min J(\mathbf{w}, \mathbf{e}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2, \gamma > 0 \quad (8)$$

$$y_i = \mathbf{w}^T \Phi(x_i) + b + e_i \quad (9)$$

其中:  $x_i$  为输入集合,  $y_i$  为输出集合,  $\gamma$  为正则化参数,  $b$  为常值偏差. 该优化问题可通过拉格朗日函数求解.

$$L(\mathbf{w}, b, \mathbf{e}, \mathbf{a}) = J(\mathbf{w}, \mathbf{e}) - \sum_{i=1}^N a_i (\mathbf{w}^T \Phi(x_i) + b + e_i - y_i) \quad (10)$$

$a_i$  为拉格朗日乘子, 分别对  $\mathbf{w}, b, \mathbf{e}, \mathbf{a}$  求取偏微分并化简可得到下式:

$$\begin{bmatrix} 0 & \mathbf{l}^T \\ \mathbf{l} & \Omega + \gamma^{-1} \mathbf{l} \end{bmatrix} \begin{bmatrix} b \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (11)$$

其中:  $\mathbf{y} = [y_1, \dots, y_N]^T, \mathbf{l} = [1, \dots, 1], \mathbf{a} = [a_1, \dots, a_N]^T, \Omega_{ij} = K(x_i, x_j), K(x_i, x_j)$  是核函数. 对于已知的时延序列训练集  $\{x_i, y_i\}$ , 通过式(11)即可求出参数  $\mathbf{a}$  与  $b$ . 同时, 给定实际集合  $x$ , 结合训练集中的  $x_i$ , 按照式(12)即可得到时延预测模型的输出预测值.

$$y = \sum_{i=1}^N a_i K(x, x_i) + b \quad (12)$$

本文 LSSVM 模型的核函数选择如下式所示的径向基函数.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (13)$$

由上述建模过程可知, 基于径向基核函数的 LSSVM 预测模型预测性能主要取决于参数  $\gamma$  与  $\sigma^2$ . 为了得到最佳的  $\gamma$  与  $\sigma^2$ , 本文利用遗传算法对参数进行优化, 方法如下:

**Step 1** 对  $\gamma$  与  $\sigma^2$  进行个体编码.

**Step 2** 利用均匀设计产生初始种群, 确保初始种群的多样性与个体分步的均匀性.

**Step 3** 将时延实际值与预测值的均方误差 (Mean Squares Error, MSE) 作为适应度函数.

**Step 4** 利用时延样本序列对 LSSVM 训练, 记录每组参数的时延预测精度与每个个体的适应度值.

**Step 5** 从群体中选择性能最好的个体进入下一代, 其余个体进行选择、交叉和变异操作, 产生新的种群.

**Step 6** 结束条件判断, 若满足则输出最佳的  $\gamma$  与  $\sigma^2$ , 否则继续优化过程.

## 5 时延预测模型

假定输入时延序列  $d_i, i = 1, 2, \dots, N$ , 经过相空间重构后得到相空间  $D_i$  的各维分量为  $d_i, d_{i+\tau}, \dots, d_{i+(m-1)\tau}$ , 其中的  $m$  与  $\tau$  可通过 C-C 方法得到. 获得  $m$  与  $\tau$  后即

可得到 LSSVM 的预测样本集, 其中输入样本集  $\{X\}$  如式(14)所示, 输出样本集  $\{Y\}$  如式(15)所示, 利用输入输出集通过遗传算法对 LSSVM 进行离线优化训练, 即可得到时延预测模型. 当 LSSVM 模型建立之后可利用历史时延序列对未来时刻时延进行在线预测.

$$X = \begin{bmatrix} d_1 & d_{1+\tau} & \dots & d_{1+(m-1)\tau} \\ d_2 & d_{2+\tau} & \dots & d_{2+(m-1)\tau} \\ \vdots & \vdots & \dots & \vdots \\ d_{N-(m-1)\tau} & d_{N-(m-1)\tau+1} & \dots & d_{N-1} \end{bmatrix} \quad (14)$$

$$Y = \begin{bmatrix} d_{2+(m-1)\tau} \\ d_{3+(m-1)\tau} \\ \vdots \\ d_{N-1} \\ d_N \end{bmatrix} \quad (15)$$

本文基于相空间重构与最小二乘支持向量机的时延预测模型可表示为图 6 所示:

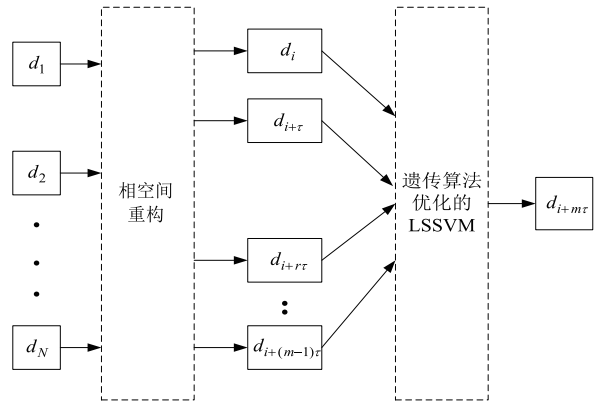


图6 基于相空间重构与最小二乘支持向量机的时延预测模型

综上所述, 本文的时延预测步骤如下:

**Step 1** 通过 C-C 方法对时延序列  $d_i$  进行相空间重构.

**Step 2** 利用式(3)、(4)、(5)分别计算时延序列的  $\bar{S}(t), \Delta \bar{S}(t)$  以及  $S_{cor}(t)$ .

**Step 3** 确定相空间重构参数  $\tau$  与  $m$ .

**Step 4** 对时延序列按照公式(14)、(15)得到 LSSVM 预测模型的输入与输出集.

**Step 5** 利用遗传算法对 LSSVM 进行参数寻优, 获得优化参数  $\gamma$  与  $\sigma^2$ .

**Step 6** 利用优化后的 LSSVM 预测模型, 结合相空间重构对时延序列进行在线预测.

## 6 仿真

仿真数据为上文的 500 组时延数据, 其中前 400 组数据用于训练, 后 100 组数据用于预测精度的测试.

首先需要得到时延序列的相空间重构参数. 利用 C-C 方法进行相空间重构, 计算得到  $\bar{S}(t)$ 、 $\Delta\bar{S}(t)$ 、 $S_{cor}(t)$  的曲线如图 7 所示.

如图 7 所示,  $\Delta\bar{S}(t)$  的第一个局部极小值位于 2, 因此确定时延参数  $\tau$  为 2. 同时  $S_{cor}(t)$  的全局最小值位于 14, 根据式 (6) 可确定嵌入维数  $m$  为 8.




图7  $S(t)$ ,  $\Delta S(t)$ 与 $S_{cor}(t)$ 曲线图




图8 时延序列相空间三维图




图9 时延序列相空间递归图

RP 计算方法如下.

$$s_{i,j} = \|D_i - D_j\|, i = 1, 2, \dots, N - (m - 1)\tau, \quad (16)$$

$$j = 1, 2, \dots, N - (m - 1)\tau$$

$$R(i, j) = H(\varepsilon_i - s_{i,j}) \quad (17)$$

$\varepsilon_i$  为介质距离, 可取定值.  $H(r)$  为 Heaviside 单位函数.

$$H(r) = \begin{cases} 1, & r \geq 0 \\ 0, & r < 0 \end{cases} \quad (18)$$

从图 9 的递归图中可观察到, 在整个递归值平面上递归图并非均匀分布, 而且存在与主对角线平行的直线段, 因此网络时延序列可看作一混沌时间序列, 在局部范围内具有可预测性, 因此相空间重构技术的引入是必要的.

为了衡量预测精度, 本文采用了 4 个性能指标. 目前对于时间序列预测效果的评价指标包括均方根误差 (Root Mean Square Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)、绝对误差 (Absolute Error, AE)、平均相对误差 (Mean Relative Error, MRE) 等. RMSE、MAE、MAPE 对较大的预测误差不存在正负抵消的情况, 算法简单, 能够准确评价预测模型的整体性能. 而 AE 与 MRE 等评价指标由于将正负误差相互抵消, 会导致对预测效果的错误判断. 因此本文选择 RMSE、MAE 以及 MAPE 作为评价指标. 而可靠性则代表了预测算法预测精度的置信程度, 本文也将可靠性列入性能指标. 4 个性能指标的定义如下:

(1) RMSE

$$e_{rmse} = \sqrt{\frac{1}{N} \sum_{i=1}^N (d_{pre}(i) - d_{act}(i))^2} \quad (19)$$

(2) MAE

$$e_{mae} = \frac{1}{N} \sum_{i=1}^N |d_{pre}(i) - d_{act}(i)| \quad (20)$$

图 8 为相空间的三维图, 图中显示相空间中空间点对间距离趋于均匀分布, 吸引子包含信息量较大, 因此  $\tau$  为 2 的取值较为合理.

根据原始时延序列相空间重构之后的  $D_i$ , 可计算得到如图 9 所示的递归图 (Recurrence Plot, RP).

(3) MAPE

$$e_{mape} = \frac{1}{N} \sum_{i=1}^N \left\{ |d_{pre}(i) - d_{act}(i)| / d_{act}(i) \right\} \times 100\% \quad (21)$$

(4) 可靠性

$$R^{(1-a)} = \left[ \frac{\xi^{(1-a)}}{N} - (1-a) \right] \times 100\% \quad (22)$$

上面各式中,  $d_{pre}(i)$  是时延的预测值,  $d_{act}(i)$  是时延的实际值,  $N$  为序列长度,  $\xi^{(1-a)}$  为在置信度  $1 - \alpha$  下实际值落入预测置信区间的个数.

将用于训练的 400 组时延序列样本按公式 (14)、(15) 转换为输入  $X$  和输出  $Y$  的形式. 文中遗传算法的参数为: 迭代进化次数 200, 种群数量 20, 交叉概率 0.8, 变异概率 0.2,  $\gamma$  与  $\sigma^2$  编码位数都为 10, 其中  $\gamma$  取值范围为 0 ~ 10000,  $\sigma^2$  为 0.001 ~ 1000, 经过遗传算法寻优后得到 LSSVM 算法的参数  $\gamma = 718.75$ ,  $\sigma^2 = 3.129$ , 最佳适应度值 (MSE) 为 2.21. 图 10 给出了遗传算法适应度变化曲线.

为了对比本文预测方法的有效性, 与文献 [8] 中基于 AR (AR 阶数为 5)、文献 [13] 中 Elman 神经网络 (输入层数为 20, 最大迭代次数 3000, 迭代目标 0.0001, 隐




图10 遗传算法优化LSSVM适应度曲线

层个数为 10,输出层个数为 1,采用迭代循环完成多步预测)、文献[14]中未经过相空间重构的 LSSVM(利用工具箱中的网格法得到参数  $\gamma = 32.03, \sigma^2 = 4.361$ ) 3种单预测模型及文献[15]中的 IFS-LSSVM( $\gamma = 7.38, \sigma^2 = 182.36, m = 17$ )、文献[16]中的 KPCA 优化 LSSVM(嵌入维数  $m$  为 10, KPCA 核参数  $\sigma^2 = 10000$ , 阈值  $E = 85\%$ , LSSVM 参数  $\gamma = 425.75, \sigma^2 = 26.38$ )、文献[17]中的相空间重构与 SVM(相空间重构参数取为本文一致, SVM 参数优化后为  $C = 23.24, \varepsilon = 0.06, \gamma = 4.91$ )、文献[24]中的迭代误差补偿 LSSVM(迭代误差补偿次数为 3,  $m = 8, \tau = 2, \gamma_1 = 538.42, \sigma_1^2 = 7.38, \gamma_2 = 178$ 。

$36, \sigma_2^2 = 3.57, \gamma_3 = 1326.54, \sigma_3^2 = 46.59$ ) 4种混合预测模型进行了对比分析. 实际值与预测值拟合曲线如图 11 所示. 图 11 表明本文预测方法曲线的拟合度更好.

图 12 是本文预测方法与其它 7 种预测方法的预测误差分布,从图中可观察到本文方法的预测误差更小. 图 13 是 8 种预测方法的误差直方图的对比,从图中可观察到本文方法的预测误差分布更加均匀,也就是随着预测步长的增加,预测误差变化范围较小,说明预测误差受预测步长的影响较小.




图11 8种预测方法的实际值与预测值拟合曲线




图12 8种预测方法的预测误差对比

表 1 给出了文中用到的 8 种预测方法的 RMSE、MAE、MAPE 性能指标的对比,从性能指标可知本文的预测方法优于其它的预测方法. 图 14 是 8 种预测方法可靠性的对比图,从实际值落入预测置信区间的个数上也可看出本文的预测方法要优于其它的 7 种预测方法. 图 13 与图 14 的对比结果表明本文方法具有更好的性能指标. 表 2 给出了文中的 8 种预测方法预测模型的训练时间以及对时延序列进行 100 步预测所需时间的对比(CPU 为 Intel i3-4030, 4GB 内存, Windows 7 操作系统, 仿真软件 Matlab R2010b),从表 2 可知本文的预测方法在训练时间上要略长于单一预测模型,与其它 4 种混合预测模型比较接近,而在线预测时间上与其它

预测方法差别不大,因此本文在提高预测精度的同时并未增加算法的复杂性.

表 1 预测算法性能指标对比

预测方法	RMSE	MAE	MAPE
本文方法	1.594	0.931	0.635
Elman 神经网络	3.411	2.124	1.446
LSSVM	3.305	1.932	1.311
AR	4.437	2.917	1.982
KPCA 优化 LSSVM	1.777	1.547	1.054
IFS-LSSVM	1.887	1.639	1.116
相空间重构与 SVM	1.779	1.566	1.068
迭代误差补偿 LSSVM	1.776	1.538	1.047

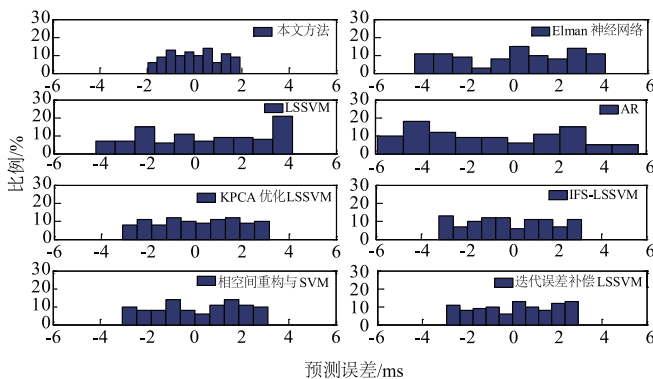


图13 8种预测方法预测误差直方图对比

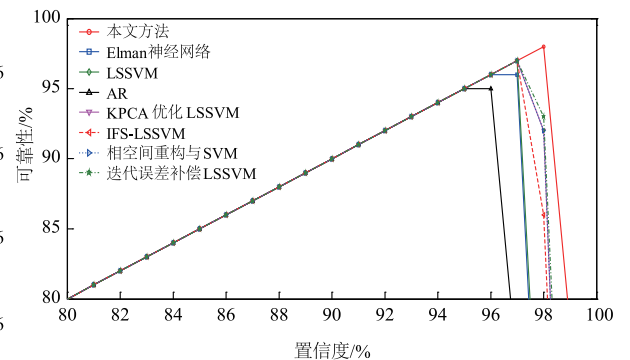


图14 8种预测方法可靠性对比

表 2 预测算法训练与预测时间对比

预测方法	训练时间(s)	100 步预测时间(s)
本文方法	72.31	0.139
Elman 神经网络	30.25	0.117
LSSVM	96.37	0.135
AR	29.36	0.097
KPCA 优化 LSSVM	65.38	0.131
IFS-LSSVM	68.27	0.136
相空间结构与 SVM	83.27	0.152
迭代误差补偿 LSSVM	287.59	0.407

从图 11 中曲线拟合程度、图 12 ~ 图 13 的误差分布、表 1 与图 14 中的性能指标的对比可知本文的预测方法在预测精度上高于其它的单一或混合预测方法。同时,表 2 显示本文预测方法并未增加算法复杂度,可满足实际应用。

## 7 结论

文中研究了网络控制系统中时延的预测问题,并提出了利用相空间重构与最小二乘支持向量机的预测方法。利用 0-1 测试法确定时延序列的混沌特性,引入相空间重构将时延序列映射到特征空间来提高预测精度。通过时延序列的 Hurst 指数选择 LSSVM 作为预测模型,并利用遗传算法对预测模型中的参数进行优化。通过建立的预测模型对实际采集的时延数据进行了预测效果的仿真验证。结果表明文中提出的预测方法能够有效地预测网络时延,具有较好的精度,可以反映时延序列的总体变化趋势,同时预测方法的复杂度并未增加。

由于网络时延具有随机性与突发性,因此没有任何一个预测方法或模型能够拟合所有情况下的时延分布特性。更好的预测方法应该对时延序列进行更多特性的分析来找出更加适合的模型。同时通过小波变换、经验模式分解等方法对序列分解与重构,对其中的各分量依据其特点分别建模预测是本文未来的研究方向。

## 参考文献

[1] Tian Z D, Gao X W, Gong B L, et al. Time-delay compensation method for networked control system based on time-delay prediction and implicit PIGPC[J]. International Journal of Automation and Computing, 2015, 12(6): 648-656.

[2] Tian Z D, Gao X W, Li K. A hybrid time-delay prediction method for networked control system[J]. International Journal of Automation and Computing, 2014, 11(1): 19-24.

[3] Zhang J, Luo D Y. Analysis of time delay and packet dropouts based on state observer for a kind of Networked con-

trol system[J]. Journal of Networks, 2014, 9(2): 466-473.

- [4] Karagiannis T, Molle M, Faloutsos M. Long-range dependence: Ten years of Internet traffic modeling[J]. IEEE Internet Computing, 2004, 8(5): 57-64.
- [5] Fu X H, Fu X. A predictive Algorithm for time delay Internet network[A]. 2011 International Conference on Electronics, Communications and Control, ICECC 2011-Proceedings[C]. Piscataway, United States: IEEE. 2011. 666-669.
- [6] Zhao J P, Gao X W. Time-delay analysis and estimation of Internet-based robot teleoperation system[A]. 2009 Chinese Control and Decision Conference, CCDC 2009[C]. Piscataway, United States: IEEE. 2009. 4643-4646.
- [7] Li H, Xiong N, Park J H, et al. Predictive control for vehicular sensor networks based on round-trip time-delay prediction[J]. IET Communications, 2010, 4(7): 801-809.
- [8] Shi W G, Shao C, Sun Z Y. The algorithms of improved GPC network time-delay compensation based on online time-delay estimation[J]. Journal of Convergence Information Technology, 2011, 6(3): 46-54.
- [9] Medjiah S, Taleb T, Ahmed T. Sailing over data mules in delay-tolerant networks[J]. IEEE Transactions on Wireless Communications, 2014, 13(1): 5-13.
- [10] 田中大, 高宪文, 李琨. 网络控制系统的自适应预测控制[J]. 应用科学学报, 2013, 31(3): 303-308.  
Tian Zhongda, Gao Xianwen, Li Kun. Adaptive predictive control of networked control system[J]. Journal of Applied Sciences-Electronics and Information Engineering, 2013, 31(3): 303-308. (in Chinese)
- [11] Tian Z D, Shi T. Time-delay prediction method based on improved genetic algorithm optimized echo state network[A]. Proceedings of the 2015 Chinese Intelligent Systems Conference[C]. New York: Springer-Verlag. 2016. 209-220.
- [12] Han C W. Fuzzy neural network-based time delay prediction for networked control systems[J]. Applied Mathematics & Information Sciences, 2014, 8(1): 407-413.
- [13] Rahmani B, Markazi A H D, Mozayani N. Real time prediction of time delays in a networked control system[A]. 2008 3rd International Symposium on Communications, Control, and Signal Processing, ISCCSP2008[C]. Piscataway, United States: IEEE. 2008. 1242-1245.
- [14] Wang T, Wang H, Wang P. Application of support vector machine in networked control system with delayed variable sampling period[A]. Proceedings-2010 3rd IEEE International Conference on Computer Science and Information Technology, ICCSIT 2010[C]. Piscataway, United States: IEEE. 2010: 127-130.

- [15] 田中大,李树江,王艳红,等. IFS-LSSVM 及其在时延序列预测中的应用[J]. 电机与控制学报,2015,19(11):104-110.  
Tian Zhongda, Li Shujiang, Wang Yanhong, et al. IFS-LSSVM and its application in time-delay series prediction [J]. Electric Machines and Control, 2015, 19(11): 104-110. (in Chinese)
- [16] 田中大,高宪文,李琨. 基于 KPCA 与 LSSVM 的网络控制系统时延预测方法[J]. 系统工程与电子技术,2013,35(6):1281-1285.  
Tian Zhongda, Gao Xianwen, Li Kun. Networked control system time-delay prediction method based on KPCA and LSSVM[J]. Systems Engineering and Electronics, 2013, 35(6):1281-1285. (in Chinese)
- [17] 韩晓霞,谢刚,韩晓明,等. 基于相空间重构和支持向量机的多相催化剂失活预测[J]. 控制与决策,2012,27(6):953-956.  
Han Xiaoxia, Xie Gang, Han Xiaoming, et al. Application of phase space reconstruction and support vector regression for forecasting of catalyst deactivation [J]. Control and Decision, 2012, 27(6):953-956. (in Chinese)
- [18] 温祥西,孟相如,马志强,等. 小时间尺度网络流量混沌性分析及趋势预测[J]. 电子学报,2012,40(8):1609-1616.  
Wen Xiangxi, Meng Xiangru, Ma Zhiqiang, et al. The chaotic analysis and trend prediction on small-time scale network traffic [J]. Acta Electronica Sinica, 2012, 40(8):1609-1616. (in Chinese)
- [19] Khatibi R, Sivakumar B, Ghorbani M A, et al. Investigating chaos in river stage and discharge time series [J]. Journal of Hydrology, 2012, (414-415):108-117.
- [20] Soares H C, da Silva L, Lobao D C, et al. Hurst exponent analysis of moving metallic surfaces [J]. Physica A: Statistical Mechanics and its Applications, 2013, 392(21):5307-5312.
- [21] 田中大,李树江,王艳红,等. 基于 ARIMA 补偿 ELM 的网络流量预测方法[J]. 信息与控制,2014,43(6):705-710.  
Tian Zhongda, Li Shujiang, Wang Yanhong, et al. Network traffic prediction method based on extreme learning machine with ARIMA compensation [J]. Information and Control, 2014, 43(6):705-710. (in Chinese)
- [22] 张春涛,马千里,彭宏. 基于信息熵优化相空间重构参数的混沌时间序列预测[J]. 物理学报,2010,59(11):7623-7629.  
Zhang Chuntao, Ma Qianli, Peng Hong. Chaotic time series prediction based on information entropy optimized parameters of phase space reconstruction [J]. Acta Physica Sinica, 2010, 59(11):7623-7629. (in Chinese)
- [23] Kim H S, Eykholt R, Salas J D. Nonlinear dynamics delay times, and embedding windows [J]. Physica D: Nonlinear Phenomena, 1999, 127(1):48-60.
- [24] 唐舟进,任峰,彭涛,等. 基于迭代误差补偿的混沌时间序列最小二乘支持向量机预测算法[J]. 物理学报,2014,63(5):050505.  
Tang Zhoujin, Ren Feng, Peng Tao, et al. A least square support vector machine prediction algorithm for chaotic time series based on the iterative error correction [J]. Acta Physica Sinica, 2014, 63(5):050505. (in Chinese)
- [25] Huang X L, Shi L, Suykens J A K, et al. Asymmetric least squares support vector machine classifiers [J]. Computational Statistics and Data Analysis, 2014(70):395-405.

## 作者简介



田中大(通信作者) 男,1978年11月出生,辽宁沈阳人.沈阳工业大学信息科学与工程学院讲师,博士.研究方向为网络控制系统时延补偿、混沌时间序列预测、复杂工业过程建模与控制等.

E-mail: tianzhongda@126.com



张超 男,1992年3月出生,山东滕州人.沈阳工业大学信息科学与工程学院硕士研究生.研究方向为网络控制系统时延补偿.