

遗传算法优化回声状态网络的网络流量预测

田中大¹ 高宪文² 李树江¹ 王艳红¹

¹(沈阳工业大学信息科学与工程学院 沈阳 110870)

²(东北大学信息科学与工程学院 沈阳 110819)

(tianzhongda@126.com)

Prediction Method for Network Traffic Based on Genetic Algorithm Optimized Echo State Network

Tian Zhongda¹, Gao Xianwen², Li Shujiang¹, and Wang Yanhong¹

¹(College of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870)

²(College of Information Science and Engineering, Northeastern University, Shenyang 110819)

Abstract Network traffic prediction is an important problem of network congestion control and network management. Network traffic time series have time-varying and nonlinear characteristics, So the prediction accuracy of traditional time series prediction method is relatively low and it is unable to establish accurate prediction model. Echo state network (ESN) has good performance in prediction and modeling of nonlinear chaotic system and is very suitable for network traffic time series prediction problem. In order to improve the prediction accuracy of network traffic, the network traffic nonlinear prediction method based on genetic algorithm optimized echo state network is proposed. Firstly, echo state network is used for network traffic prediction, then the genetic algorithm is used to optimize the parameters of the reservoir of the echo state network prediction model. Finally, the prediction accuracy of the prediction model is improved. The actual network traffic data from China Unicom in Liaoning Province is used for simulation verification. Three common prediction models including auto regressive integrated moving average (ARIMA) prediction model, Elman neural network prediction model and least square support vector machine (LSSVM) prediction model are compared, and the simulation results show that the proposed method has higher prediction accuracy with smaller prediction error and it can describe the network traffic characteristics of complex changes.

Key words network traffic; nonlinear; prediction; genetic algorithm(GA); echo state network(ESN)

摘要 网络流量预测是网络拥塞控制与网络管理的一个重要问题。网络流量时间序列具有时变、非线性特征,导致传统时间序列预测方法预测精度比较低,无法建立精确的预测模型。回声状态网络(echo state network, ESN)在非线性的混沌系统预测与建模方面有着良好的性能,非常适合网络流量的预测。为了提高网络流量的预测精度,提出一种基于遗传算法(genetic algorithm, GA)优化回声状态网络的网络流量非线性预测方法。首先利用回声状态网络对网络流量进行预测;然后利用遗传算法对回声状态网络预测模型中的储备池参数进行优化,提高预测模型的预测精度。通过中国联合网络通信公司辽宁分公司采集的实际网络流量数据进行了仿真验证。与差分自回归滑动平均模型(auto regressive integrated

moving average, ARIMA)、Elman 神经网络以及最小二乘支持向量机(least square support vector machine, LSSVM)这 3 种常见预测模型进行了对比,仿真结果表明提出的方法具有更高的预测精度与更小的预测误差,更能刻画网络流量复杂的变化特点.

关键词 网络流量;非线性;预测;遗传算法;回声状态网络

中图法分类号 TP393.1

网络流量是目前网络管理的一个重要参数,在设计网络的拥塞控制策略时,网络流量的准确预测是非常重要的^[1],通过网络流量预测可使网络管理者在网络性能恶劣之前采取有效的措施避免网络拥塞或者网络崩溃.

很多学者将网络流量看作线性模型,分别采用自回归滑动平均(auto regressive moving average, ARMA)模型^[2-3]、差分自回归滑动平均(auto regressive integrated moving average, ARIMA)模型^[4-5]、差分自回归求和滑动平均模型^[6-7](fractional auto regressive integrated moving average, FARIMA)等线性模型进行预测.文献[8]针对以上各个模型,研究了各个模型在不同时间尺度下的预测精度,通过仿真指出每个模型适应的时间尺度,但是随着网络复杂度的增加,网络流量特性已经超出传统意义上认为的泊松或者 Markov 分布了,因此利用线性模型进行预测存在理论上的不足,很难保证预测的精确性.而非线性模型的预测主要包括支持向量机^[9-10](support vector machine, SVM)、最小二乘支持向量机^[10](least square support vector machine, LSSVM)、人工神经网络^[11-12]以及灰色模型^[13]等,虽然非线性模型的预测精度较线性模型有了一定程度的提高,但是神经网络容易陷入局部最小点,网络结构难以确定.支持向量机虽然需要样本数小,但是其关键参数很难确定.而灰色模型只适合数据变化不是剧烈的情况下,因此网络流量的精确预测目前依然是一个亟待解决的问题.

由 Jaeger 和 Haas^[14]在 2001 年所提出的回声状态网络(echo state network, ESN)是一种新型的递归神经网络,在非线性混沌系统预测建模方面与传统的递归神经网络相比有了较大改进.1)通过预设 ESN 网络内部连接权值矩阵的谱半径来保证储备池内部递归网络的稳定性;2)利用线性回归算法训练唯一要求计算的输出权值.学习算法本身属于凸优化,因此避免了陷入局部极小值的问题.回声状态网络一经提出便成为学术界的研究热点,并应用到各种不同领域,尤其是时间序列的预测问题^[15-17].

本文首先对网络流量时间序列进行自相似性分析,确定网络流量时间序列的非线性特点.在此基础上,针对具有非线性特点的网络流量的预测问题,提出一种利用回声状态网络进行网络流量预测的方法,同时为了解决储备池参数影响回声状态网络预测精度的问题^[18],利用遗传算法(genetic algorithm, GA)进行储备池参数的优化.对中国联合网络通信公司辽宁分公司的接入网某路由器的实际网络流量数据进行了仿真,仿真结果对比表明本文的方法具有较高的预测精度.

1 网络流量的自相似性分析

1994 年 Leland 等人^[19]指出网络流量具有自相似特征,相似性可用 Hurst 指数 H 来衡量.当 $H=0.5$ 时说明网络流量序列是随机游动的,事件之间不相关;当 $H \in [0, 0.5)$ 时说明序列是反持久性的;当 $H \in (0.5, 1)$ 时表示序列是持久性的,也即具有自相似性, H 越大则序列的自相似性越大.因此 Hurst 指数越大说明网络的自相似(长相关)也即非线性程度越高^[20].目前典型的 Hurst 指数计算方法为 R/S 类分析方法(rescaled range analysis),其方法可描述为

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

其中, n 为样本个数; R 为重新标度的极差,也即 $R = \max(X_{t,n}) - \min(X_{t,n})$, $t=1, 2, \dots, n$; S 为标准差; H 为 Hurst 指数; A 为一常数.作出 $\lg(R/S)$ 关于 $\lg n$ 的关系图,利用最小二乘法求取数据点斜率即 Hurst 指数.本文仿真中对网络流量序列进行了自相似性分析,可知网络流量具有强非线性特点.

2 回声状态网络

回声状态网络将网络隐层设计成一个具有很多神经元组成的稀疏网络,通过调整网络内部权值的特性达到记忆数据的功能.其内部的动态储备池(dynamic reservoir, DR)包含了大量稀疏连接的神

经元,蕴含系统的运行状态,并具有短期记忆功能,而非线性系统的动态特性即由 DR 产生.图 1 为 ESN 网络结构图^[21]:




Fig. 1 Echo state network structure.

图 1 ESN 网络结构

2.1 ESN 学习算法

设系统具有 K 个输入单元、 N 个内部处理单元,同时具有 L 个输出单元.输入单元、内部状态、输出单元在时刻 k 的值分别为

$$\begin{aligned} \mathbf{u}(k) &= [u_1(k), u_2(k), \dots, u_K(k)]^T, \\ \mathbf{x}(k) &= [x_1(k), x_2(k), \dots, x_N(k)]^T, \\ \mathbf{y}(k) &= [y_1(k), y_2(k), \dots, y_L(k)]^T. \end{aligned} \quad (2)$$

与传统神经网络相比,ESN 的隐层由较多神经元构成的循环网络形成动态储备池 DR.为使 DR 内部具有动态记忆能力,权值 $\mathbf{W}$ 通常保持连接度为 5%~10%,谱半径(spectral radius, SR)小于 1.

训练样本通过 $\mathbf{W}_{in}$ 完成对内部单元的连接并实现训练数据的采集,使 DR 记忆相应的信息,通过 DR 状态向量与目标输出的线性回归过程最小化平均误差得到 $\mathbf{W}_{out}$,ESN 的学习步骤为

$$\mathbf{x}(k+1) = f(\mathbf{W}_{in} \times \mathbf{u}(k+1) + \mathbf{W}_{back} \mathbf{x}(k)), \quad (3)$$

$$\mathbf{y}(k+1) = f_{out} \times (\mathbf{W}_{out} \times (\mathbf{u}(k+1), \mathbf{x}(k+1))), \quad (4)$$

其中, f, f_{out} 分别为 DR 内部神经元、输出层神经元激活函数; $\mathbf{W}_{in}, \mathbf{W}, \mathbf{W}_{out}, \mathbf{W}_{back}$ 分别为输入层到储备池的 $N \times K$ 阶、储备池的 $N \times N$ 阶、储备池到输出层的 $L \times (K + N + L)$ 阶、输出层反馈到储备池的 $N \times L$ 连接权值矩阵.

2.2 权值计算

利用网络实际输出 $\hat{\mathbf{y}}(k)$,逼近期望输出 $\mathbf{y}(k)$:

$$\mathbf{y}(k) \approx \hat{\mathbf{y}}(k) = \sum_{i=1}^L \mathbf{W}_i^{out} x_i(k). \quad (5)$$

也就是希望计算权值矩阵满足系统均方误差最小,即求解如下目标:

$$\min \frac{1}{P-m+1} \sum_{k=m}^P (\mathbf{y}(k) - \sum_{i=1}^L \mathbf{W}_i^{out} x_i(k))^2, \quad (6)$$

进而可归结形式为:

$$\mathbf{W}_{out} = (\mathbf{M}^{-1} \times \mathbf{T})^T, \quad (7)$$

其中, $\mathbf{M}$ 为输入 $x_1(k), x_2(k), \dots, x_N(k), k = m, m+1, \dots, P$ 构成的 $(P-m+1) \times N$ 的矩阵; $\mathbf{T}$ 为输出 $\mathbf{y}(k)$ 构成的 $(P-m+1) \times 1$ 的列矩阵.

2.3 储备池的关键参数

ESN 的性能由储备池的 4 个参数决定,简要介绍储备池的 4 个参数:

1) 储备池内部连接权谱半径 SR. 其为连接权矩阵 $\mathbf{W}$ 的绝对值最大的特征值,记为 $\lambda_{max}, \lambda_{max} < 1$ 是保证网络稳定的必要条件.

2) 储备池规模 N . 其为储备池中神经元的个数,储备池的规模选择与样本个数有关,对网络性能影响很大,储备池规模越大 ESN 对给定动态系统的描述越准确,但是会带来过拟合问题.

3) 储备池输入单元尺度(input scale, IS). 其为储备池的输入信号连接到储备池内部神经元之前需要相乘的一个尺度因子,即对输入信号进行一定的缩放.一般需要处理的对象非线性越强, IS 越大.

4) 储备池稀疏程度(sparse degree, SD). 其表示储备池中神经元之间的连接情况,储备池中并不是所有神经元之间都存在连接. SD 表示储备池中相互连接的神经元占总的神经元 N 的百分比,其值越大,非线性逼近能力越强^[22].

在本文第 5 节将会给出储备池参数对于 ESN 预测精度的影响效果.

2.4 基于 ESN 的网络流量预测

假设时刻 k 的网络流量为 $t(k)$,时刻 k 之前的网络流量历史数据可表示为一个网络流量序列 $\mathbf{T}(k)$,其可表示为

$$\mathbf{T}(k) = [t(k), t(k-1), \dots, t(k-m)], \quad (8)$$

其中, m 为嵌入维数.

设当前时刻 k 为预测原点,预测时域长度为 h ,网络流量序列的预测问题可表述为给定 $\{\mathbf{T}(k)\}$ 以及时刻 k 之前的网络流量值来预测时刻 $k+h$ 的网络流量值.

按照 ESN 算法, $\mathbf{T}(k)$ 作为输入、 $t(k+h)$ 作为输出对 ESN 网络进行训练,确定输入输出的映射关系

即可对网络流量进行预测,具体预测过程描述如下:

Step1. 确定训练样本长度 L 、预测时域长度 h 以及输入数据嵌入维数 m ,建立输入训练集 $\{T(k), k=m+1, m+2, \cdots, L-h\}$, 输出训练集 $\{t(k+h), k=m+1, m+2, \cdots, L-h\}$.

Step2. 初始化 ESN 参数 IS, SR, N, SD 等.

Step3. 按照式(6)、式(7)进行网络训练,计算输出权矩阵.

Step4. 将网络流量序列按 Step1 转换,通过式(3)、式(4)预测未来时刻 $k+h$ 的网络流量.

Step5. 将下一采样时刻测得的网络流量实际值放入网络流量序列,利用滑动窗口法去除最旧的网络流量数据,返回 Step4,直至预测结束.

从以上相关描述可知,ESN 的储备池参数以及网络流量时间序列历史数据嵌入维数 m 对于 ESN 预测模型的非线性预测精度有着重要的影响,为了找到最合适的储备池参数与 m ,本文采用遗传算法对参数寻优,提高预测的精度.

3 遗传算法优化 ESN

遗传算法利用生物遗传学的观点,通过自然选择、交换和变异等机制实现种群的进化,具有强大的全局搜索能力,可以在较短时间内搜索到全局最优解^[23].

3.1 个体编码

ESN 进行网络流量预测需要的参数 m, SR, N, IS, SD ,其个体设计如图 2 所示,前 n_1 位代表 m ,后面的 n_2 位代表 SR ,后面的 n_3 位代表 N ,再后面的 n_4 位代表 IS ,最后面的 n_5 位代表 SD .



Fig. 2 The individual structure of ESN parameters.

图 2 ESN 参数个体结构

个体的各位二级制串通过式(9)转化为十进制来表示模型的实际参数:

$$p = \min p + \frac{\max p - \min p}{2^j - 1} \times d, \tag{9}$$

其中, p 为参数十进制值, $\min p$ 为参数的最小值, $\max p$ 为参数的最大值, j 为参数二进制串长度, d 为参数二进制串的十进制值.

3.2 种群初始化

标准的 GA 算法其初始种群为随机产生,具有很大地不确定性和不均匀性,不能很好地包含全局

最优解信息,出现局部最优问题,因此本文中采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.

3.3 适应度函数

GA 的搜索目标为找到最合适的 m, SR, N, IS, SD ,从而提高网络流量的预测精度,因此适应度函数应与预测模型的精度相关.设第 i 次迭代优化中,网络流量预测值与实际值的均方根误差(root mean square error, RMSE)为

$$RMSE(i) = \sqrt{\frac{1}{L} \sum_{k=1}^L (t_k - \hat{t}_k)^2}, \tag{10}$$

其中, L 为网络流量序列长度, t_k 与 $\hat{t}_k$ 分别为时刻 k 网络流量的实际值与 ESN 的输出预测值.为计算方便,第 i 次迭代优化个体的适应度函数直接取为预测误差的误差均方根,即为

$$fitness(i) = RMSE(i). \tag{11}$$

3.4 遗传算子设计

1) 选择算子. 计算个体适应度值,按照适应度大小排序,适应度越小说明误差越小则为最优的个体,利用个体保持策略选择 R 个最优个体进入下一代,其余 $n-R$ 个个体交叉、变异操作产生新的个体进入下一代.

2) 交叉算子. 在个体上,分别选择 3 个交叉点,然后与另外一个个体的相应部分进行交叉操作,操作执行完毕后对生成个体进行检验,验证其是否在参数选择范围内,若不在则重新交叉操作.

3) 变异算子. 对个体的 3 部分采用传统翻转变异方法进行变异操作,随机选取个体上的 1 位,按照 0 变为 1、1 变为 0 的规则进行变异操作,随之检验变异后个体是否在参数取值范围内,若不在则重新进行变异.

4 基于 GA 优化 ESN 的网络流量预测模型

GA 优化的 ESN 网络流量预测模型流程如图 3 所示.

从图 3 可知,本文的 GA 优化 ESN 的网络流量预测步骤可描述如下:

Step1. ESN 参数编码与 GA 参数设置. 将网络流量 ESN 预测模型待优化参数 m, SR, N, IS, SD 进行染色体基因编码;进行 GA 参数设置,如交叉概率、变异概率等;随机产生一组 ESN 预测模型参数值的染色体.

Step2. 按照 2.4 节描述,对网络流量序列进行




Fig. 3 The flow chart of GA optimized ESN network traffic prediction model.

图 3 基于 GA 优化 ESN 网络流量预测模型流程图

预测. 采用式(11)的适应度函数, 计算种群中各个个体的适应度, 通过适应度函数衡量优化参数的优劣.

Step3. 根据个体适应度, 通过轮盘赌法, 具有较高适应度值的染色体被复制; 通过单点交叉法按照交叉概率将 2 条染色体中的基因进行随机交换, 按照变异概率将染色体中的基因编码“0”与“1”互换.

Step4. 重复 Step2 到 Step4, 使初始确定的一组待优化参数不断进化, 直到满足结束条件.

Step5. 对得到的最优解译码, 得到优化的参数 m, SR, N, IS, SD .

5 仿 真

本文采集了 250 组中国联合网络通信公司辽宁分公司 169 接入网某路由器的网络流量数据, 数据采集尺度为 10 min, 通过前 200 组数据对 ESN 预测模型进行训练, 后 50 组数据进行预测模型预测精度的验证. 图 4 为 250 组网络流量数据, 从图 4 中可看

出网络流量数据具有时变与非线性的特征. 本文仿真中预测时域长度设为 1, 也即单步预测.




Fig. 4 Network traffic sequence.
图 4 网络流量序列

利用 R/S 类分析方法对网络流量序列进行分析, 如图 5 所示, 用直线拟合这些 $\lg(R/S)$ 关于 $\lg n$ 的数据点, 直线斜率即为 Hurst 指数, 其 $H=0.9012$, 显然满足 $0.5 < H < 1$, 可知网络流量序列具有自相似性同时具有强烈的非线性特征. 这也从侧面说明 ARMA 等线性模型无法完成对网络流量时间序列的精确预测.




Fig. 5 Hurst parameter of network traffic sequence.
图 5 网络流量序列的 Hurst 指数

储备池的参数对于 ESN 网络流量预测模型的预测精度有着重要的作用, 为了说明这些参数对预测精度的影响, 图 6 给出了谱半径 SR 的变化范围为 $[0.1, 1)$, 变化步长为 0.05, 储备池规模 N 的变化范围为 $[20, 200)$, 变化步长为 1, 嵌入维数 $m=10$, 输入单元尺度 $IS=0.1$, 储备池稀疏程度 $SD=0.3$, 网络流量预测值与实际流量值之间均方根误差 $RMSE$ 的分布.

图 7 给出了谱半径 $SR=0.5$, 储备池规模 $N=30$, 输入单元尺度 $IS=0.1$, 储备池稀疏程度 $SD=$

0.3 时,嵌入维数 m 为 1~20 时预测误差的 $RMSE$ 分布.




Fig. 6 $RMSE$ distribution of prediction error when SR and N changed.

图6 SR 与 N 变化时预测误差的 $RMSE$ 分布




Fig. 7 $RMSE$ distribution of prediction error when m changed.

图7 m 变化时预测误差 $RMSE$ 分布

图8给出了谱半径 $SR=0.5$, 储备池规模 $N=30$, 嵌入维数 $m=10$, 输入单元尺度 IS 的变化范围为 $[0.01, 1)$, 变化步长为 0.05, 储备池稀疏程度 SD 的变化范围为 $[0.01, 1)$, 变化步长为 0.05 时预测误差 $RMSE$ 的分布.




Fig. 8 $RMSE$ distribution of prediction error when IS and SD changed.

图8 IS 与 SD 变化时预测误差的 $RMSE$ 分布

从图6、图7与图8可以看出,嵌入维数 m 和储备池参数对于预测精度会造成不同的影响,因此如何根据网络流量训练集选择合适的模型参数是一个重要的问题,直接影响最后 ESN 预测的精度.

本文利用 GA 算法进行预测模型参数的寻优,预测模型中待优化的参数 m, SR, N, IS, SD 都采用十进制编码,编码位数都为 10、种群数量为 20,进化迭代次数为 200、变量变化范围: $m \in [1, 20], SR \in [0.01, 1], N \in [10, 100], IS \in [0.01, 1], SD \in [0.01, 1]$,交叉概率为 0.8,变异概率为 0.1,同样利用上面的 250 组网络流量数据,适应度函数取为网络流量预测值与实际值的均方根误差 $RMSE$,经过 GA 优化后得到的预测模型参数:嵌入维数 $m=11$, $SR=0.313, N=58, IS=0.0139, SD=0.0565$. 适应度变化曲线如图9所示:




Fig. 9 The fitness curve of genetic algorithm.

图9 遗传算法适应度变化曲线

利用遗传算法寻优得到的参数,对 50 组网络流量数据进行了预测精度的验证,图10为本文方法网络流量预测值与实际值的对比图.

为了进行本文方法预测精度的对比,与文献[5]中的 ARIMA、文献[10]中的 LSSVM、文献[11]中的 Elman 神经网络这 3 种典型的预测方法进行了对比.其中,ARIMA 方法采用赤池信息准则(AIC)确定参数为: $p=9, q=8, d=1$; LSSVM 方法利用网格法交叉验证得到参数: $\gamma=277.07, \sigma^2=33.95$, 嵌入维数为 10; Elman 神经网络的参数:输入层为 10, 中间层为 10, 输出层为 1, 最大迭代次数为 4 000. 图11至图13为这 3 种预测方法网络流量预测值与实际值的对比曲线. 表1与表2分别为本文方法与其他 3 种方法预测误差的 $RMSE$ 以及平均绝对误差(mean absolute error, MAE)的对比.




Fig. 10 The comparison of network traffic prediction and actual value in proposed method.

图 10 本文方法网络流量预测值与实际值对比




Fig. 11 The comparison of network traffic prediction and actual value of Elman neural network.

图 11 Elman 神经网络方法网络流量预测值与实际值对比




Fig. 12 The comparison of network traffic prediction and actual value of LSSVM.

图 12 LSSVM 方法网络流量预测值与实际值对比




Fig. 13 The comparison of network traffic prediction and actual value of ARIMA.

图 13 ARIMA 方法网络流量预测值与实际值对比

MAE 的定义为

$$MAE = \frac{1}{L} \sum_{k=1}^L |t_k - \hat{t}_k|. \tag{12}$$

Table 1 The RMSE Comparison of Prediction Error of Several Prediction Methods

表 1 4 种方法预测误差的 RMSE 对比

Prediction Methods	RMSE
Our Method	4.6124
LSSVM	81.8351
Elman	32.363
ARIMA	44.5907

Table 2 The MAE Comparison of Prediction Error of Several Prediction Methods

表 2 4 种方法预测误差 MAE 对比

Prediction Methods	MAE
Our Method	2.1916
LSSVM	61.3992
Elman	24.9007
ARIMA	38.25

从图 10 至图 13 以及表 1、表 2 中对比可发现，本文提出的基于 GA 优化 ESN 的网络流量预测方法较其他几种方法具有更高的预测精度和更小的预测误差。预测精度提高的原因：1) 回声状态网络本身具有较好的非线性预测能力；2) 通过遗传算法进行回声状态网络预测模型参数的寻优，避免了参数选择的盲目性，因此提高了预测的精度。

6 结 论

针对网络流量的非线性预测问题而提出一种利用 ESN 进行网络流量预测的方法,采用遗传算法完成 ESN 预测模型中参数的选择优化,通过对实际网络中获得的网络流量数据进行了预测效果的仿真,仿真结果表明提出的基于 GA 优化 ESN 的网络流量预测方法具有很好的预测效果,可以精确地刻画非线性网络流量的变化.对于未来进行拥塞控制、网络管理优化等问题提供了良好的基础.

未来的研究工作是在预测模型中引入相空间重构方法,相空间重构方法可通过考察系统的一个或多个分量来确定多维状态空间的另一点,结合回声状态网络可进一步提高预测精度.

致谢 中国联合网络通信公司辽宁省分公司集团客户响应中心的顾斌工程师为本文提供了网络流量数据,在此表示感谢!

参 考 文 献

- [1] Alarcon-Aquino V, Barria J A. Multiresolution FIR neural-network-based learning algorithm applied to network traffic prediction [J]. IEEE Trans on Systems, Man and Cybernetics: Part C—Applications and Reviews, 2006, 36(2): 208-220
- [2] Gao Bo, Zhang Qinyu, Liang Yongsheng, et al. Predicting self-similar networking traffic based on EMD and ARMA [J]. Journal on Communications, 2011, 32(4): 47-56 (in Chinese)
(高波, 张钦宇, 梁永生, 等. 基于 EMD 及 ARMA 的自相似网络流量预测[J]. 通信学报, 2011, 32(4): 47-56)
- [3] Laner M, Svoboda P, Rupp M. Parsimonious fitting of long-range dependent network traffic using ARMA models [J]. IEEE Communications Letters, 2013, 17(12): 2368-2371
- [4] Yuan Xiaofang, Chen Nannan, Wang Dong, et al. Traffic prediction models of traffics at application layer in metro area network [J]. Journal of Computer Research and Development, 2009, 46(3): 434-442 (in Chinese)
(袁小坊, 陈楠楠, 王东, 等. 城域网应用层流量预测模型[J]. 计算机研究与发展, 2009, 46(3): 434-442)
- [5] Wang Jin. A process level network traffic prediction algorithm based on ARIMA model in smart substation [C] // Proc of the 3rd IEEE Int Conf on Signal Processing, Communications and Computing. Piscataway, NJ: IEEE, 2013: 1-5
- [6] Dong Chunling. Scheme of network congestion control based on DWT and FARIMA [J]. Journal of Chinese Computer Systems, 2011, 32(5): 931-934 (in Chinese)
(董春玲. 一种结合 DWT 和 FARIMA 的网络拥塞控制机制[J]. 小型微型计算机系统, 2011, 32(5): 931-934)
- [7] Ren Xunyi, Yang Yu, Zhang Junfeng, et al. Parameter estimation and application of time-varying FARIMA model [J]. International Journal of Advancements in Computing Technology, 2011, 3(3): 89-94
- [8] Jiang Ming, Wu Chunming, Zhang Min, et al. Research on the comparison of time series models for network traffic prediction [J]. Acta Electronica Sinica, 2009, 37(11): 2353-2358 (in Chinese)
(姜明, 吴春明, 张旻, 等. 网络流量预测中的时间序列模型比较研究[J]. 电子学报, 2009, 37(11): 2353-2358)
- [9] Liu Xingwei, Fang Xuming, Qin Zhenhua, et al. A short-term forecasting algorithm for network traffic based on chaos theory and SVM [J]. Journal of Network and Systems Management, 2011, 19(4): 427-447
- [10] Wang Haifeng, Hu Dejin. Comparison of SVM and LS-SVM for regression [C] //Proc of the 2nd Int Conf on Neural Networks and Brain. Piscataway, NJ: IEEE, 2005: 279-283
- [11] Wang Junsong, Wang Jiukun, Zhang Maohua. Prediction of Internet traffic based on Elman neural network [C] //Proc of the 21st Chinese Control and Decision Conf. Piscataway, NJ: IEEE, 2009: 1248-1252
- [12] Chen Yuehui, Yang Bin, Meng Qingfang. Small-time scale network traffic prediction based on flexible neural tree [J]. Applied Soft Computing, 2012, 12(1): 274-279
- [13] Cao Jianhua, Yuan Liu, Yue Dai. Network traffic prediction based on error advanced DGM(1,1) model [C] //Proc of the 3rd Int Conf on Wireless Communication Networking and Mobile Computing. Piscataway, NJ: IEEE, 2007: 6353-6356
- [14] Jaeger H, Haas H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication [J]. Science, 2004, 304(5667): 78-80
- [15] Deihimi A, Showkati H. Application of echo state networks in short-term electric load forecasting [J]. Energy, 2012, 39(1): 327-340
- [16] Sheng Chunyang, Zhao Jun, Liu Ying, et al. Prediction for noisy nonlinear time series by echo state network based on dual estimation [J]. Neurocomputing, 2012(82): 186-195
- [17] Li Decai, Han Min, Wang Jun. Chaotic time series prediction based on a novel robust echo state network [J]. IEEE Trans on Neural Networks and Learning Systems, 2012, 23(5): 787-797
- [18] Lukosevicius M, Jaeger H. Reservoir computing approaches to recurrent neural network training [J]. Computer Science Review, 2009, 3(3): 127-149
- [19] Leland W E, Taqqu M S, Willinger W, et al. On the self-similar nature of Ethernet traffic (extended version) [J]. IEEE/ACM Trans on Networking, 1994, 2(1): 1-15
- [20] Qian Bo, Rasheed K. Hurst exponent and financial market predictability [C] //Proc of the 2nd IASTED Int Conf on Financial Engineering and Applications. Calgary, AB, Canada: Acta, 2004: 203-209

[21] Ozturk M C, Xu Dongming, Principe J C. Analysis and design of echo state networks [J]. Neural Computation, 2007, 19(1): 111-138

[22] Wang Se, Yang Xiaojian, Wei Chengjian. Harnessing non-linearity by sigmoid-wavelet hybrid echo state networks (SWHESN) [C] //Proc of the 6th World Congress on Intelligent Control and Automation. Piscataway, NJ: IEEE, 2006; 3014-3018

[23] Qi Hongli, Zhao Hui, Liu Weiwen, et al. Parameters optimization and nonlinearity analysis of grating eddy current displacement sensor using neural network and genetic algorithm [J]. Journal of Zhejiang University-Science A Applied Physics & Engineering, 2009, 10(8): 1205-1212



Tian Zhongda, born in 1978. Received his PhD degree from Northeastern University of Control Theory and Control Engineering. Lecturer. His research interests include time series prediction, time-delay compensation and scheduling for networked control system.



Gao Xianwen, born in 1955. Professor and PhD supervisor in Northeastern University. His research interests include complex industrial process modeling and intelligent optimal control theory and application.



Li Shujiang, born in 1966. PhD and professor in Shenyang University of Technology. His research interests include complex industrial process modeling and intelligent optimal control theory.



Wang Yanhong, born in 1967. PhD and professor in Shenyang University of Technology. Her research interests include production scheduling and optimization, advanced manufacturing information system.