

经验模式分解与时间序列分析在网络流量预测中的应用

田中大¹, 李树江¹, 王艳红¹, 高宪文²

(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 110004)

摘要: 提出一种经验模式分解和时间序列分析的网络流量预测方法. 首先, 对网络流量时间序列进行经验模式分解, 产生高低频分量和余量; 然后, 对各分量进行时间序列分析, 确保高频分量采用改进和声搜索算法优化的最小二乘支持向量机模型、低频分量和余量采用差分自回归滑动平均模型进行建模和预测; 最后, 将预测结果通过RBF神经网络进行非线性叠加, 得到最终的预测值. 仿真实验表明, 所提出方法具有更好的预测效果和更高的预测精度.

关键词: 网络流量; 经验模式分解; 时间序列; 自相似; 预测

中图分类号: TP393

文献标志码: A

Network traffic prediction based on empirical mode decomposition and time series analysis

TIAN Zhong-da¹, LI Shu-jiang¹, WANG Yan-hong¹, GAO Xian-wen²

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

2. College of Information Science and Engineering, Northeastern University, Shenyang 110004, China. Correspondent: TIAN Zhong-da, E-mail: tianzhongda@126.com)

Abstract: A network traffic prediction method based on empirical mode decomposition and time series self-similar analysis is proposed. Firstly, network traffic time-series high and low frequency components are generated by empirical mode decomposition. Then the component time series is analyzed to determine that the least squares support vector machine model optimized by using the improved harmony search algorithm is used for high frequency components modeling, and the auto regressive integrated moving average model is used for low frequency components modeling and remaining component modeling. Finally, the final prediction result is obtained by RBF neural network nonlinear superposition. Simulation results show that the proposed method has better prediction results and higher prediction accuracy.

Keywords: network traffic; empirical mode decomposition; time series; self-similar; prediction

0 引言

网络流量是目前网络管理的一个重要参数, 在网络资源有限的情况下设计网络的拥塞控制策略时, 网络流量的准确预测对于减少网络拥塞、合理分配资源、提高网络服务质量和发现网络异常行为等具有重要的作用^[1].

近年来研究发现, 网络流量即使在流量突变时也呈现出一定的变化规律, 这使得对网络流量序列进行分析、预测成为可能. 网络流量预测通常采用的方法是利用时间序列模型, 对流量特性进行分析刻画和建模, 在此基础上进行流量预测. 目前的流量预测模型包括基于短相关特性的自回归滑动平均(ARMA)模

型^[2-3]、差分自回归滑动平均(ARIMA)模型^[4-5]和基于长相关特性的差分自回归求和滑动平均(FARIMA)模型^[6]等线性模型. 文献[7]针对以上各模型进行了不同尺度下的预测精度研究, 通过仿真指出每个模型适应的时间尺度. 由于网络结构的动态变化, 网络流量时间序列已经超出传统意义上认为的泊松或者马尔可夫分布, 利用线性模型进行预测存在理论上的不足, 难以保证预测的精确性. 常见的非线性模型包括支持向量机(SVM)^[8]、人工神经网络^[9]和灰色模型^[10]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, 但是神经网络存在易陷于局部最优值、网络结构难以确定、需要较大的数据样本等缺点. 支持向量机虽然需要样本数小, 但是目前对于核

收稿日期: 2014-03-31; 修回日期: 2014-07-15.

基金项目: 国家自然科学基金重点项目(61034005).

作者简介: 田中大(1978—), 男, 讲师, 博士, 从事时间序列分析与预测的研究; 李树江(1966—), 男, 教授, 博士, 从事复杂工业过程建模与控制等研究.

函数及其参数的选择没有统一的方法,只能依据实验确定.而灰色模型只适合原始数据符合指数分布规律且数据变化不剧烈的情况下,因此网络流量的非线性预测模型也有着一定的限制.

从目前的研究成果看,单一预测模型具有较大的预测误差,无法满足更准确的预测要求.针对单一预测模型的不足,组合预测模型是提高网络流量预测精度的发展方向.经验模式分解(EMD)是近年来提出的一种处理具有非平稳和非线性特征信号的方法,不需要预先设定基函数,具有自适应性,且经过经验模式分解之后得到的基本模式分量(IMF)突出了数据的局部特征.基于经验模式分解的优点,本文提出一种将经验模式分解与时间序列分析方法相结合的网络流量预测方法.首先,对原始网络流量序列进行EMD分解,得到对应的IMF分量;然后,通过时间序列分析法对高频IMF分量、低频IMF分量和余量进行分析,对高频分量选择最小二乘支持向量机建模和预测,同时提出一种改进的和声搜索算法进行最小二乘支持向量机的参数优化,对低频分量和余量选择ARIMA模型建模和预测;最后,将各个模型的输出预测值经过一个RBF神经网络进行非线性叠加,得到网络流量的预测结果.仿真实验结果表明,所提出的方法能够提高预测精度,减少预测误差.

1 经验模式分解

经验模式分解是由Huang等^[11]于1998年提出的一种新的信号处理方法,其本质是对时间序列进行平稳化处理,将原始信号分解为若干个本征模式函数,根据经验确定数据中有效信号的基本震荡模式.最低频的IMF分量通常代表原始信号的趋势,这些IMF需要满足如下条件:

- 1) 信号极值点的数量与过零点数量必须相等或最多相差一个;
- 2) 在任一点上,信号局部最大值与局部最小值定义的包络的均值为零.

经验模式分解的主要过程如下.

Step 1: 将原始信号序列 $x(t)$ 的所有极大值与所有极小值点分别用2条3次样条曲线拟合,得到 $x(t)$ 的上下两条包络线,计算两条包络线的均值, $m(t)$ 代表两条包络线的平均值,令 $h(t) = x(t) - m(t)$.

Step 2: 若 $h(t)$ 不满足IMF的要求,则重复Step 1求取新的 $x(t)$;若 $h(t)$ 满足IMF的要求,则令 $h(t)$ 为 $x(t)$ 的第1个IMF,同时求出 $x(t)$ 与该IMF的差值 $r(t)$.

Step 3: 将 $r(t)$ 作为待分解信号,重复上述过程直到剩余信号满足给定的终止条件($r(t)$ 足够小或者为

一单调函数).

经验模式分解的最终结果可以表示为

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t). \quad (1)$$

其中: $c_i(t)$ 为第 i 个IMF分量, r_n 为剩余分量.因此,经验模式分解可将原始信号 $x(t)$ 分解为 n 个不同频率的IMF与一个趋势项之和.

2 时间序列的自相似分析

对于网络流量时间序列,在经过EMD处理后得到若干个IMF分量,但是对这些IMF分量采用何种预测模型进行预测是一个重要问题.针对该问题,本文引入时间序列的自相似分析进行处理. Legend等^[12]指出网络流量具有自相似特征,相似性可用Hurst参数 H 衡量,当 $H = 0.5$ 时,表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,表明序列是反持久性的,当 $H \in [0.5, 1)$ 时,表明序列是持久性的,即具有自相似性, H 越大则序列的自相似性越大.因此,Hurst参数越大表明网络流量的自相似(长相关)程度越高^[13].目前典型的Hurst参数计算方法为R/S类分析方法,可以描述为

$$(R/S)_n = An^H. \quad (2)$$

其中: n 为样本个数; R 为重新标度的极差,且 $R = \max(X_{t,n} - \min X_{t,n}), t = 1, 2, \dots, n$; S 为标准差; H 为Hurst参数; A 为一常数.给出 $\lg(R/S)_n$ 关于 $\lg n$ 的关系图,利用最小二乘法求取斜率即为Hurst参数.

由以上叙述可知,对于一个时间序列,通过序列的Hurst参数可知采用何种模型进行预测是合适的.本文采集300组时间尺度为10 min的中国联通辽宁分公司3G网络一核心路由器的网络流入数据,利用R/S类方法对序列进行分析,其 $H = 0.7546$.可见,满足 $0.5 < H < 1$,网络流量序列具有自相似性.

下面将网络流量样本数据进行EMD处理,处理后得到6个IMF分量(IMF₁ ~ IMF₆)和1个余量 R_7 ,如图1所示.经过EMD处理后,各分量显示了变化的频率和振幅信息,其中IMF₁ ~ IMF₄代表高频分量,IMF₅ ~ IMF₆代表低频分量,余量 R_7 代表趋势分量.

对6个IMF分量和余量分别进行R/S类分析,可得到各个序列的Hurst参数如表1所示.由表1中的Hurst参数计算结果看,高频分量IMF₁ ~ IMF₄具有较大的Hurst参数,反映序列具有长相关和强非线性特点,因此,采用对非线性序列具有良好预测效果的LSSVM进行建模和预测.IMF₅、IMF₆的低频分量和余量 R_7 反映了原始流量序列的随机波动特性,呈现一种周期非平稳的特征.本文利用游程检验




图1 经过EMD分解后的各分量和余量

表1 各分量的Hurst参数

分量	Hurst参数
IMF ₁ 分量	0.973
IMF ₂ 分量	0.901
IMF ₃ 分量	0.872
IMF ₄ 分量	0.865
IMF ₅ 分量	0.712
IMF ₆ 分量	0.656
R ₇ 余量	0.511

法^[14]对低频和余量时间序列进行平稳性判定, 经计算后得到 $|Z|_{IMF_5} = 2.8661$, $|Z|_{IMF_6} = 2.3312$, $|Z|_{R_7} = 2.0823$, 均大于在显著性水平 $\alpha = 0.05$ 下, Z 服从标准的 $N(0, 1)$ 正态分布的临界值 1.96, 因此可以判断 IMF₅、IMF₆ 和 R₇ 都是非平稳的时间序列. 利用 LB 统计量法^[15]对低频和余量时间序列进行非白噪声性判定, 计算得到 3 个时间序列的 p 值均接近于 0, 远小于显著性水平 0.05, 因此可以认为低频分量

IMF₅、IMF₆ 和余量 R₇ 均不具有白噪声特性, 不是随机性时间序列, 含有可以提取的信息. ARIMA 模型对非平稳、非白噪声时间序列能够有效地分析其数据序列相关性, 因此本文采用 ARIMA 预测模型对低频分量和余量进行建模和预测. 对于各个模型预测结果的叠加, 本文采用 RBF 神经网络进行非线性叠加, 其优点在于结构简单且收敛速度快, 能够逼近任意的非线性函数^[16].

3 改进和声搜索算法的 LSSVM 参数优化

时间序列经过 EMD 分解后, 其高频分量的预测精度直接影响最终的预测效果, 同时, LSSVM 的预测精度取决于 γ 和 σ^2 两个参数, 两个参数如何确定目前还没有统一的方法. 和声搜索 (HS) 算法是源于乐曲创作过程的模仿而出现的群智能优化算法^[17], 相关文献^[18-19]表明, HS 算法的优化性能强于遗传算法、模拟退火等算法. 本文提出一种改进的和声搜索算法 (IHS) 进行 LSSVM 参数的优化选择, 为进一步提高算法搜索效率, 作如下的改进: 参数 HMCR 应由大到小动态调节, 这样可以使 HS 算法先对和声记忆库内充分搜索, 迭代搜索后期转到和声记忆库外部搜索, 提高种群的多样性. 有

$$HMCR(t) = \begin{cases} HMCR(t-1) \times \rho, & HMCR(t) > HMCR_{max}; \\ HMCR_{min}, & HMCR(t) \leq HMCR_{min}; \\ HMCR_{max}, & t = 0. \end{cases} \quad (3)$$

在 HS 算法的初期, PAR 取值小有利于算法快速地搜索更好的区域; 在 HS 算法的后期, 较大的 PAR 利于算法跳出局部最优值. 因此, PAR 是从小到大变化的, 变化策略如下:

$$PAR(t) = \frac{PAR_{max} - PAR_{min}}{\sqrt{NI}} \times \sqrt{t} + PAR_{min}. \quad (4)$$

对于 BW, 在算法初期, 较大的 BW 有利于 HS 算法在较大的范围内搜索; 在算法后期, 较小的 BW 有利于小范围内的精确搜索. 因此, BW 应该由大至小变化, 变化策略如下:

$$BW(t) = BW_{min} + (BW_{max} - BW_{min}) \times e^{-t}. \quad (5)$$

标准 HS 算法在更新记忆库时, 新解 x_{new} 产生是随机地在记忆库中选择某个分量, 这样会导致算法搜索方向不定, 随机性较大. 本文参考遗传算法中的交叉运算思想, 参照标准 HS 算法产生一个新解 x_{new1} , 然后将 x_{new1} 随机与另一列分量进行单点交叉产生第 2 个新解 x_{new2} , 如果 $f(x_{new1}) < f(x_{new2})$, 则保留 x_{new1} , 否则保留 x_{new2} .

选用如下 Sphere 函数进行本文 IHS 算法的性能验证:

$$f = \sum_{i=1}^n x_i^2, x_i \in [-100, 100]. \quad (6)$$

其中: 标准 HS 算法参数为

$$\text{HMCR} = 0.9, \text{PAR} = 0.3, \text{BW} = 0.01;$$

IHS 算法参数为

$$\text{HMCR}_{\max} = 1, \text{HMCR}_{\min} = 0.4,$$

$$\rho = 0.97, \text{PAR}_{\max} = 0.9, \text{PAR}_{\min} = 0.4,$$

$$\text{BW}_{\min} = 0.0001, \text{BW}_{\max} = 1.$$

两种算法迭代次数均为 5 000, $\text{HMS} = 6$, 变量 x_i 数量 $n = 4$. 表 2 为标准 HS 算法和 IHS 算法的搜索结果和最佳适应度.

表 2 搜索结果和最佳适应度

算法	搜索结果	最佳适应度值
标准 HS	$x_1 = 0.1576, x_2 = 0.0641$ $x_3 = 0.2936, x_4 = -0.3010$	0.6125
IHS	$x_1 = -0.0013, x_2 = 0.0011$ $x_3 = -0.0004, x_4 = -0.0004$	0.0011

通过 Sphere 函数验证了 IHS 算法的收敛速度和精度均优于标准的 HS 算法. 下面给出基于 IHS 算法的 LSSVM 参数优化流程.

Step 1: 初始化 IHS 算法参数, 设定待优化参数 γ 和 σ^2 的取值范围, 样本序列进行归一化处理.

Step 2: 建立训练样本的输入集 $X = \{x_k, x_{k-1}, \dots, x_{k-m}\}$, $k = m+1, m+2, \dots, m+N-1$, 输出集 $Y = \{x_{k+1}, x_k, \dots, x_{k-m+1}\}$, $k = m+2, m+3, \dots, m+N$.

Step 3: 确定 IHS 算法优化适应度函数为网络流量实际值与预测值的均方根误差 (RMSE), 即

$$\text{fitness}(i) = \sqrt{\sum_{i=1}^N \frac{(y_i - \hat{y}_i)^2}{N}}. \quad (7)$$

Step 4: 利用 IHS 算法结合适应度函数反复迭代进行参数的优化, 直至满足结束条件.

Step 5: 输出最佳参数 γ, σ^2 、平均适应度和最佳适应度.

4 本文的网络流量预测模型

基于 EMD 和时间序列分析的网络流量预测步骤如下.

建模过程.

Step 1: 对长度为 N 的原始网络流量序列进行 EMD 分解, 形成 k 个高频 IMF 分量、 n 个低频 IMF 分量和一个余量 R .

Step 2: 对 k 个高频 IMF 分量利用 IHS 算法进行 LSSVM 参数的优化, 建立 LSSVM 预测模型.

Step 3: 对 n 个低频 IMF 分量和余量 R 通过 AIC 准则建立 ARIMA 模型.

Step 4: 完成 IMF 分量和余量预测模型后, 将各模型的预测值作为输入、实际网络流量值作为输出进行 RBF 神经网络的建模.

预测过程.

Step 5: 设当前时刻为 t , 采用滑动窗口机制维持输入流量序列长度为 N , 将 t 时刻的网络流量实际值放入队列头部, 尾部最旧的值舍弃.

Step 6: 对序列进行 EMD 处理, 生成 IMF 分量和余量 R .

Step 7: 构造每个高低频 IMF 分量和余量的输入集, 通过各自的模型进行 $t+1$ 时刻流量的预测.

Step 8: 将各个预测模型的预测值构造为 RBF 神经网络的输入, 经过 RBF 神经网络计算得到 $t+1$ 时刻流量的最终预测值.

Step 9: 令 $t = t+1$, 返回 Step 5, 直至结束.

注意到, EMD 分解生成的 IMF 分量的个数与输入原始序列的长度有关, 如上文网络流量序列长度为 300 时, 得到 6 个 IMF 分量和 1 个余量. 同时, 本文采用未来一步预测以表明预测方法的有效性, 如果需要多步预测, 则只需在建模时按照多步预测建模即可.

5 仿真分析

仿真所用的样本数据仍然采用 300 组网络流量数据, 同时采集了另外 50 组网络流量数据进行模型的检验. 对 $\text{IMF}_1 \sim \text{IMF}_4$ 建立 IHS 优化的 LSSVM 模型, 对 IMF_5 、 IMF_6 、 R_7 建立 ARIMA 模型. IHS 优化算法参数为 $\text{HMCR}_{\max} = 1$, $\text{HMCR}_{\min} = 0.4$, $\rho = 0.95$, $\text{PAR}_{\max} = 0.95$, $\text{PAR}_{\min} = 0.35$, $\text{BW}_{\min} = 0.0001$, $\text{BW}_{\max} = 1$, 迭代次数为 100, $\text{HMS} = 6$. 待优化参数取值范围为 $\gamma \in [0.001 \ 1000]$, $\sigma^2 \in [0.001 \ 1000]$, 适应度函数取预测值与实际值的均方根误差. 表 3 给出了 LSSVM 的建模结果.

表 3 LSSVM 模型参数

分量	参数	平均适应度	最佳适应度值
IMF ₁	$\gamma = 5.78$	1.2338	0.5782
	$\sigma^2 = 30.2$		
IMF ₂	$\gamma = 0.41$	0.4408	0.062
	$\sigma^2 = 2.35$		
IMF ₃	$\gamma = 7.11$	0.8128	0.7367
	$\sigma^2 = 12.71$		
IMF ₄	$\gamma = 8.33$	0.0949	0.064
	$\sigma^2 = 0.97$		

当 4 个 LSSVM 模型建立完毕后, 对 50 组网络流量测试样本的 4 个 IMF 分量进行预测. 图 2 为各个 IMF 分量的实际值与预测值的对比, 由图 2 可知, 建立的模型的预测值能够很好地拟合实际值. 通过 AIC 准则对 IMF_5 、 IMF_6 和余量 R_7 建立 ARIMA 模型, 参数如表 4 所示.

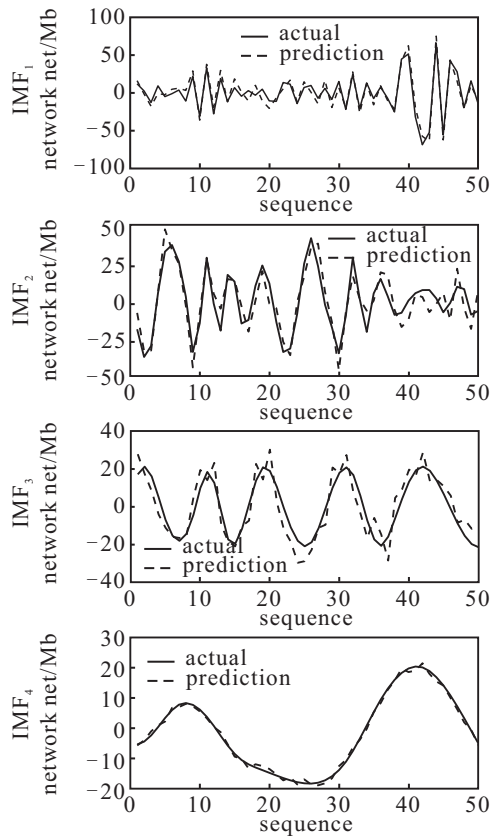


图2 IMF₁~IMF₄ 预测值与实际值对比曲线

表4 ARIMA 模型参数

分量	模型参数	AIC
IMF ₅	$p = 3, d = 1, q = 2$	9.32
IMF ₆	$p = 2, d = 1, q = 2$	6.12
R_7	$p = 2, d = 1, q = 1$	-2.06

建立好 ARIMA 模型后, 对 50 组网络流量测试样本的 2 个 IMF 分量和 1 个余量进行预测, 图 3 为 2 个 IMF 分量和余量的实际值与预测值的对比。由图 3 可见, 建立的模型预测值很好地拟合了实际值。

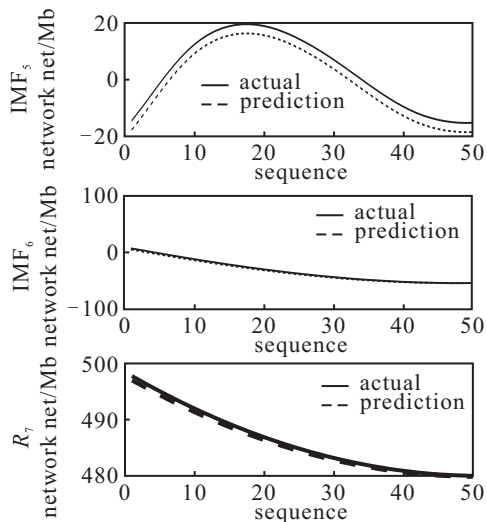


图3 IMF₅、IMF₆ 和 R_7 预测值与实际值对比曲线

当高频分量 IMF₁~IMF₄、低频分量 IMF₅~IMF₆ 和余量 R_7 的模型建立完毕后, 将预测值进行叠

加即可得到最终的预测值。本文未采用直接叠加的方法, 而是通过 RBF 神经网络进行非线性叠加。RBF 神经网络的训练参数为: 输入层为 7, 中间层为 20, 输出层为 1, 采用的径向基核函数宽度为 3, 迭代目标取为 0.001。图 4 为 50 组网络流量测试样本的最终预测值与实际值对比曲线。




图4 50组网络流量最终预测值与实际值对比曲线

为了对比本文方法的预测效果, 选择 ARIMA 方法^[4]、LSSVM^[8]、Elman 神经网络^[9]3 种典型的单一预测模型进行对比。ARIMA 方法采用 AIC 准则确定参数为 $p=4, q=2, d=1$ 。LSSVM 方法利用交叉验证得到参数 $\gamma = 3.17, \sigma^2 = 1.57$ 。Elman 神经网络的参数为输入层为 10, 中间层为 30, 输出层为 1, 最大迭代次数为 5000。图 5 为 3 种方法预测值与实际值对比曲线。

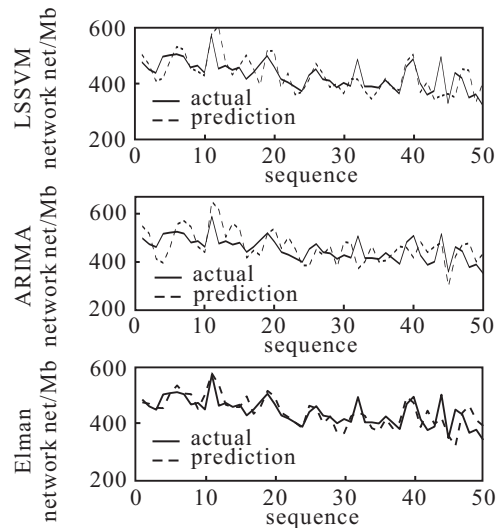


图5 其他3种方法预测值与实际值对比曲线

为了定量说明本文对于网络流量的预测精度, 采用 RMSE、平均绝对误差 (MAE)、平均绝对百分比相对误差 (MAPE)、平均相对百分比误差 (MPE) 作为评价指标。表 5 为 4 种方法的性能评价指标对比。

表5 预测方法评价指标的对比

预测方法	RMSE	MAE	MAPE	MPE
本文方法	3.83	3.95	0.94	0.12
LSSVM	35.13	24.95	5.59	-0.54
ARIMA	52.18	43.84	9.67	-2.22
Elman NN	41.01	30.01	6.64	0.38

由图 4、图 5 和表 5 可见, 本文所提出的基于经验模式分解与时间序列分析的网络流量预测方法较单

一的预测方法具有更好的预测效果和更高的预测精度.

6 结 论

本文针对具有自相似性特征的网络流量预测精度较差的问题,利用经验模式分解、时间序列分析的方法对网络流量的建模和预测进行了研究.网络流量时间序列经过EMD分解后,各分量呈现不同的自相似和相关性,通过高低频分量和余量分析,针对其特性采用不同的预测模型进行预测,从而提高了预测的精度.仿真实验表明,所提出的方法较单一预测模型的预测效果和预测精度均有一定程度的提高,预测方法是有效的.

参考文献(References)

- [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] Tan X L, Tan Z F, Fang W J. Network traffic prediction model based on wavelet transform and ARMA[J]. Int Review on Computers and Software, 2012, 7(5): 2543-2560.
- [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] Wang J. A process level network traffic prediction algorithm based on ARIMA model in smart substation[C]. 2013 IEEE Int Conf on Signal Processing, Communications and Computing. Kunming, 2013: 1-5.
- [5] Yadav R K, Balakrishnan M. Comparative evaluation of ARIMA and ANFIS for modeling of wireless network traffic time series[J]. Eurasip J on Wireless Communications and Networking, 2014, 1: 15.
- [6] 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.
(Dong C L. Scheme of networked congestion control based on DWT and FARIMA[J]. J of Chinese Computer Systems, 2011, 32(5): 931-934.)
- [7] 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.
(Jiang M, Wu C M, Zhang M, et al. Research on the comparison of time series models for network traffic prediction[J]. Acta Electronica Sinica, 2009, 37(11): 2353-2358.)
- [8] Liao W J, Balzen Z. LSSVM network flow prediction based on the self-adaptive genetic algorithm optimization[J]. J of Networks, 2013, 8(2): 507-512.
- [9] Wang J S, Wang J K, Zhang M Z, et al. Prediction of Internet traffic based on Elman neural network[C]. Chinese Control and Decision Conf. Guilin, 2009: 1248-1252.
- [10] 孙韩林, 金跃辉, 崔毅东, 等. 粗粒度网络流量的灰色模型预测[J]. 北京邮电大学学报, 2010, 33(1): 7-11.
(Sun H L, Jin Y H, Cui Y D, et al. Large-time scale network traffic short-term prediction by grey model[J]. J of Beijing University of Posts and Telecommunications, 2010, 33(1): 7-11.)
- [11] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proc of the Royal Society of London Series A, 1998, 454(1971): 903-905.
- [12] Legend W E, Taqu M S. On the self-similar nature of Ethernet traffic[J]. IEEE/ACM Trans on Networking, 1994, 2(1): 1-15.
- [13] Qian B, Rasheed K. Hurst exponent and financial market predictability[C]. Proc of the 2nd IASTED Int Conf on Financial Engineering and Applications. Cambridge, 2004: 203-209.
- [14] Yuan H Y, Mei J P, Song H Y, et al. Test data compression for system-on-a-chip using count compatible pattern run-length coding[J]. J of Electronic Testing-Theory and Applications, 2014, 30(2): 237-242.
- [15] Chuang W H, Chen C E. Detecting number of coherent signals in array processing by ljung-box statistic[J]. IEEE Trans on Aerospace and Electronic Systems, 2012, 48(2): 1739-1747.
- [16] 王韶, 杨江平, 李逢兵, 等. 基于经验模式分解和神经网络的短期风速组合预测[J]. 电力系统保护与控制, 2012, 40(10): 6-11.
(Wang S, Yang J P, Li F B, et al. Short-term wind speed forecasting based on EMD and ANN[J]. Power System Protection and Control, 2012, 40(10): 6-11.)
- [17] Geem Z W, Kim J H, Loganathan G V. A new heuristic optimization algorithm: Harmony search[J]. Applied Mathematics and Computation, 2001, 76(2): 60-68.
- [18] Mahdavi M, Fesanghary M, Damangir E. An improved harmony search algorithm for solving optimization problem[J]. Applied Mathematics and Computation, 2007, 188(2): 1567-1579.
- [19] Lee K S, Geem Z W. A new meta-heuristic algorithm for continuous engineering optimization, harmony search theory and practice[J]. Computer Methods in Applied Mechanics and Engineering, 2005, 194(36/37/38): 3902-3933.