

基于小波变换与自回归模型的网络流量预测^{*}

白翔宇^{1,2,3} 叶新铭^{1,2} 蒋海^{1,3}

(中国科学院计算技术研究所 北京 100080)¹ (内蒙古大学计算机学院 呼和浩特 010021)²

(中国科学院研究生院 北京 100080)³

摘要 本文提出一种基于小波变换与自回归模型的网络流量预测方法,将流量数据构成的原始序列进行小波分解,并将分解得到的近似部分和各细节部分分别单支重构到原级别上;对各个重构后的序列建立自回归模型,由所拟合的模型分别进行预测;结合各个重构后序列的预测结果,可以得到对原始序列的预测结果。实验结果表明,这种方法比传统的几种网络流量预测方法具有更高的预测准确度。

关键词 流量预测,小波变换,Mallat 算法,自回归模型

Network Traffic Predicting Based on Wavelet Transform and Autoregressive Model

BAI Xiang-Yu^{1,2,3} YE Xin-Ming^{1,2} JIANG Hai^{1,3}

(Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100080)¹

(College of Computer Science of Inner Mongolia University, Hohhot 010021)²

(Postgraduate School of Chinese Academy of Sciences, Beijing 100080)³

Abstract Network traffic prediction based on wavelet transform and autoregressive model is proposed. The original discrete series consisting of network traffic data is decomposed into approximate series and several detail series. The result of single branch reconstruction of each decomposed series is more unitary than the original series in frequency, and it can be built traffic model with autoregressive model. The prediction of the original series can be obtained by the synthesis of each reconstructed series' prediction result. As shown in a set of experiments, the novel method is of higher accuracy in comparison with the traditional ones.

Keywords Traffic prediction, Wavelet transform, Mallat algorithm, Autoregressive model

1 引言

小波变换理论是上世纪 80 年代后期发展起来的应用数学分支,近年来被广泛地应用于信号处理、图像处理、模式识别等科学领域。它具有多分辨率(Multi-Resolution),即多尺度的特点,可以由粗及精的逐步观察信号。小波变换是处理非平稳时间序列的有效方法之一^[1],通过小波分解一层一层分解到不同的频率通道上,分解后的时间序列在频率成分上比原始信号单一,并且小波分解对时间序列做了平滑。O. Renaud 等利用 A Trous 算法,对基于小波的时间序列预测进行了初步研究^[2]。

在计算机网络研究领域,网络流量预测一直备受关注,它使得提前发出预警成为可能(当检测到预测结果异常时),从而可以有效地改变传统的响应式网络管理方法。人们最初主要借鉴 PSTN 的流量模型,用 Poisson 模型来描述数据网络的流量模型。根据 Poisson 模型假设,随着数据源增加,累计流量将趋近一个平均量值。由于 Internet 的多构性及网络行为的高突发连续性,Paxson V 与 Floyd S 指出这种传统的 Poisson 模型已经不适用于 Internet 的流量描述与预测^[3]。大量研究表明,实际的网络流量具有自相似性^[4],是指统计意义上的自相似性,即它的统计特性独立于时间范围,这意味着相等周期内的中心化处理不改变过程的统计特性。

国内在这方面也进行了大量的研究工作。例如,丛锁等

给出了基于小波技术的网络流量特性刻画^[5],并提出一种基于小波变换的网络流量多重分形模型^[6],用于分析网络流量的自相似特征,但是没有将小波变换引入到对网络流量的预测中;邹柏贤介绍了基于 ARMA 模型的网络流量预测^[7],以及采用一种统计分析的方法对网络流量进行平稳化处理^[8],并说明使用该平稳方法可以有效地提高预测准确度。

如何提高预测准确度一直是网络流量预测的主要难题。本文基于时间序列分析的理论和方法^[9],将小波变换引入到对网络流量的预测中,提出一种基于小波变换和自回归模型的网络流量预测。通过小波变换把原始流量数据序列分解成细节部分和近似部分,然后再对近似部分和各细节部分分别进行单支重构;对各重构后所得到的序列,分别利用自回归模型进行预测;最后结合这些预测值可得到原始流量数据的预测结果。以实际采集到的网络流量数据为样本,我们运用本文方法进行预测实验,实验结果表明该方法比常用的几种网络流量预测方法都具有更高的准确度,从而也说明了小波变换在预测过程中的作用是明显的。

本文第 2 节对小波分解及其单支重构进行介绍,采用的方法是 Mallat 算法;第 3 节给出我们的基于小波变换与自回归模型的流量预测方法;第 4 节叙述了预测实现过程,并给出应用于实际采集到的网络流量数据的预测结果;第 5 节是对预测结果进行比较分析,通过跟其它几种常用预测方法的预测误差比较,表明本文预测方法具有更高的预测精度;最后是

^{*} 基金项目:国家自然科学基金资助项目(60273021)。白翔宇 CCF 会员,博士生,讲师;叶新铭 CCF 高级会员,博士生导师,教授;蒋海 CCF 会员,博士生。

对全文的一个简单总结。

2 小波分解及其单支重构

第一个正交小波基是 Harr 于 1910 年构造的,但 Harr 小波基是不连续的。到上世纪 80 年代, Meyer, Daubechies 等人从尺度函数的角度出发构造出了连续正交小波基。1987 年, Mallat 等人提出多分辨率分析的概念和基于多尺度分析的小波基构造方法, 将小波正交基的构造纳入统一的框架之中, 提出了离散信号按小波变换分解和重构的快速小波算法。Mallat 算法的分解、重构公式如下所示:

$$\begin{cases} a_{j+1,k} = \sqrt{2} \sum_{p \in Z} \bar{h}_{p-2k} a_{j,p} \\ d_{j+1,k} = \sqrt{2} \sum_{p \in Z} \bar{g}_{p-2k} a_{j,p} \\ a_{j,k} = \sqrt{2} \sum_{p \in Z} h_{k-2p} a_{j+1,p} + \sqrt{2} \sum_{p \in Z} g_{k-2p} d_{j+1,p} \end{cases}$$

其中 $H = \{h_j\}_{j \in Z}$ 是低通滤波器, $G = \{g_j\}_{j \in Z}$ 是高通滤波器, $A^j = \{a_{j,1}, a_{j,2}, \dots, a_{j,k}\}$ 称为第 j 层的近似部分, $D^j = \{d_{j,1}, d_{j,2}, \dots, d_{j,k}\}$ 称为第 j 层的细节部分。上述分解形式中, 可以直接把 A^0 定义为待分解的原始网络流量序列。每次分解将序列分为近似部分和细节部分, 近似部分反映了序列的大致趋势, 而细节部分反映的是序列在细节上的差异。对近似部分可以进一步实施分解, 从而得到新的近似部分和细节部分。

Mallat 算法分解过程也可形象表示, 如图 1 所示。设分解层数为 j , 则原始序列经过算法分解成 D^1, D^2, \dots, D^j 和 A^1, A^2, \dots, A^j 分别为在分辨率 2^j 下的近似部分和细节部分。容易看出, 每进行一层分解, 序列的长度缩为分解前的 $1/2$ 。分解层数越高, 得到的序列的长度越短。




图 1 Mallat 算法分解过程

单支重构是指不对近似部分和细节部分同时进行重构, 而是对它们分别进行重构, 即在对某一部分进行重构时将其它部分置零。对近似部分 A^j 单支重构过程如图 2 所示, 各细节部分单支重构的方法与之类似。




图 2 近似部分 A^j 的单支重构过程

3 基于小波变换与 AR 模型的预测

自回归模型 $AR(p)$ 的形式表示为: $X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \epsilon_t$ 。其中参数 p 称为模型的阶数, $AR(p)$ 的基本假设是: X_t 仅与 X_{t-1}, \dots, X_{t-p} 有直接关系, 而在 X_{t-1}, \dots, X_{t-p} 已知的条件下, X_t 与 $X_{t-j} (j = p+1, p+2, \dots)$ 无关; ϵ_t 是一个白噪声序列, 其均值等于零, 方差为 σ_ϵ^2 , 且它与其它几部分独立。

对模型参数的估计方法, 通常有矩估计、最小二乘估计、极大似然估计等。AR 模型参数的矩估计形式如下:

$$\begin{bmatrix} \phi_1 \\ \phi_2 \\ \dots \\ \phi_p \end{bmatrix} = \begin{bmatrix} \rho_0 & \rho_1 & \dots & \rho_{p-1} \\ \rho_1 & \rho_0 & \dots & \rho_{p-2} \\ \dots & \dots & \dots & \dots \\ \rho_{p-1} & \dots & \dots & \rho_0 \end{bmatrix}^{-1} \begin{bmatrix} \rho_1 \\ \rho_2 \\ \dots \\ \rho_p \end{bmatrix}$$

$$\text{且 } \hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=k+1}^N X_t X_{t-k}}{\sum_{t=1}^N X_t^2}$$

其中, $\hat{\rho}_k$ 称为样本自相关函数, 用 $\hat{\rho}_k$ 代替式中的自相关函数 ρ_k , 即可得到模型参数。另外, 令 $\hat{X}_t(s)$ 是 X_t 的 s 步预测结果, 于是预测表达式可表示如下:

$$\begin{cases} \hat{X}_t(s) = \sum_{i=1}^k \phi_i X_{t-i+1} & s=1 \\ \hat{X}_t(s) = \sum_{i=1}^{s-1} \phi_i \hat{X}_t(s-i) + \sum_{i=s}^k \phi_i X_{t+s-i} & 1 < s \leq p \\ \hat{X}_t(s) = \sum_{i=1}^k \phi_i \hat{X}_t(s-i) & s > p \end{cases}$$

令 $X = \{x_1, x_2, \dots, x_N\}$ 是需要进行预测的网络流量序列, 对其进行 Mallat 算法分解, 并对分解后的各层进行单支重构, 可以得到: $X = D_1 + D_2 + \dots + D_j + A_j$ 。其中, $D_1 = \{d_{1,1}, d_{1,2}, \dots, d_{1,N}\}, D_2 = \{d_{2,1}, d_{2,2}, \dots, d_{2,N}\}, \dots, D_j = \{d_{j,1}, d_{j,2}, \dots, d_{j,N}\}$ 分别是第 $1, 2, \dots, j$ 层细节部分单支重构后的序列, $A_j = \{a_{j,1}, a_{j,2}, \dots, a_{j,N}\}$ 是第 j 层近似部分单支重构后的序列, 则有 $x_k = d_{1,k} + d_{2,k} + \dots + d_{j,k} + a_{j,k} (1 \leq k \leq N)$ 。

现已知 X , 对 X 的 s 步预测结果 $\hat{X}(s)$ 可用下式得到:

$$\hat{X}(s) = \hat{D}_1(s) + \hat{D}_2(s) + \dots + \hat{D}_j(s) + \hat{A}_j(s)$$

其中 $\hat{D}_i(s) (i=1, 2, \dots, j)$ 是 D_i 的 s 步预测结果, $\hat{A}_j(s)$ 是 A_j 的 s 步预测结果。

于是, 则有:

$$\hat{x}_k(s) = \hat{d}_{1,k}(s) + \hat{d}_{2,k}(s) + \dots + \hat{d}_{j,k}(s) + \hat{a}_{j,k}(s)$$

其中 $\hat{x}_k(s)$ 是 x_k 的 s 步预测结果, $\hat{d}_{i,k}(s) (i=1, 2, \dots, j)$ 是 $d_{i,k}$ 的 s 步预测结果, $\hat{a}_{j,k}(s)$ 是 $a_{j,k}$ 的 s 步预测结果。由于分解后的序列在频率成分上比原始序列单一, 并且进行了平滑, 因此平稳性比原始序列要好。可分别对各部分用自回归模型预测, 然后进一步得到原始序列的预测结果。

4 网络流量预测实验

4.1 预测过程实现

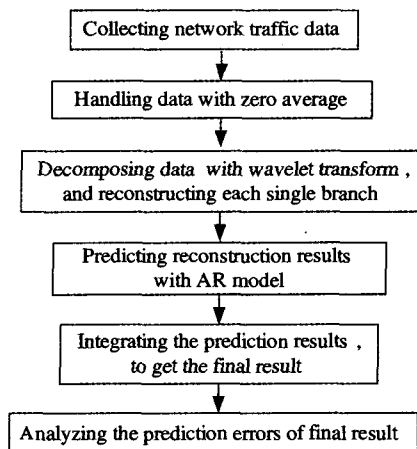


图 3 基于小波变换与自回归模型的预测过程

基于小波变换与 AR 模型的网络流量预测过程可描述如

图 3 所示,主要需经过数据采集、中心化处理、小波分解与重构、利用 AR 模型预测、结合各单个预测结果、预测误差分析等 6 个步骤。

图 4 所示是使用 AR 模型对一个单独序列进行预测的实现过程,主要包括模型定阶、参数估计、适应性检验、利用模型递推法(或逆函数法)预测等 4 个阶段。




图 4 使用 AR 模型的预测过程

4.2 实现结果

本文采用基于 SNMP 协议的流量数据采集方法,对 CERNET 内蒙古主节点一台 CISCO6509 设备某端口流出流量进行监测,监测时间是 2005 年 4 月 19 日至 21 日,采样时间间隔为 5 分钟。所得流量数据曲线如图 5(a)所示,可表示为: $X = \{X_i\}$, 其中 $i = 1, 2, 3, \dots, 864$ 。显然它具有很强的不规则性,而同时又表现出一定的周期性因素。

图 5 中的(b)、(c)、(d)分别是经过一、五、十步预测,得到对应 $X_i (577 \leq i \leq 864)$ 的预测结果的误差,预测误差是指用预测值减去对应的实际值。其中所采用小波基为 Antonini 的 9/7 双正交小波(biorthogonal wavelet)^[11],分解层数是 5 层。由图可以知道,随着预测步长的增大,预测误差也随之增大,这与实际相符合,因为越远的数据显然越难以预测,因此其误差也相应变大。




图 5 预测效果图

5 比较分析

通常使用方差和均方差描述样本误差,但用于预测效果分析时,它们的表述意义不够直观。为了更好地评价流量预测的准确度,我们定义几种误差参数:绝对误差(AE, Absolute Error)、平均绝对误差(MAE, Mean Absolute Error)、相对误差(RE, Relative Error)、平均相对误差(MRE, Mean Relative Error)。

定义 1 设 \hat{x} 是一个网络流量预测值,且所对应的实际流量值为 x ,则预测的绝对误差 $E_A = |\hat{x} - x|$,相对误差 $E_R = \frac{|\hat{x} - x|}{x}$ 。设 $\hat{x}_1, \hat{x}_2, \dots, \hat{x}_m (m > 1)$ 是一系列连续的网络流量

预测值,所对应的实际值分别为 x_1, x_2, \dots, x_m ,那么预测的平均绝对误差 \bar{E}_A 和平均相对误差 \bar{E}_R 可如下计算得到:

$$\bar{E}_A = \frac{\sum_{i=1}^m |\hat{x}_i - x_i|}{m} \quad \bar{E}_R = \frac{\sum_{i=1}^m \frac{|\hat{x}_i - x_i|}{x_i}}{m}$$

由参数定义可以知道,绝对误差反映一个预测值偏离实际值的距离大小,平均绝对误差反映了一系列预测值偏离实际值的平均距离大小;相对误差反映一个预测值偏离实际值的比例,平均相对误差反映了一系列预测值偏离实际值的平均比例。

在不同的分解层数 $1 \leq L \leq 5$ 下,使用本文基于小波变换和自回归模型的方法,对图 5(a)所示原始流量数据进行预测,分别经过一、五、十步预测得到对应 $X_i (577 \leq i \leq 864)$ 的结果,预测结果的误差数据如表 1 所示。表 1 中数据表明,随着分解层数的增加,预测误差变小,即预测准确度提高,因为分解层数越多,分解后的各部分在频率成分上越单一。这也在一定程度上反映了小波变换在本文预测方法中所起的作用。

表 1 不同变换层数下的预测误差

| L | 1-step prediction | | 5-step prediction | | 10-step prediction | |
|---|-------------------|--------|-------------------|--------|--------------------|--------|
| | MAE | MRE | MAE | MRE | MAE | MRE |
| 1 | 0.878 | 0.822% | 4.538 | 4.389% | 9.102 | 9.012% |
| 2 | 0.734 | 0.679% | 3.530 | 3.376% | 7.796 | 7.538% |
| 3 | 0.699 | 0.637% | 2.723 | 2.573% | 6.693 | 6.448% |
| 4 | 0.692 | 0.634% | 2.329 | 2.311% | 4.555 | 4.621% |
| 5 | 0.669 | 0.617% | 2.222 | 2.186% | 4.093 | 3.882% |

为了比较本文基于小波变换和自回归模型方法的预测效果,我们采用如下三种具有代表性的对比方案:

- (1) 方案 A: 对图 5(a)所示网络流量序列零均值化后,直接使用自回归模型进行预测,然后得到原始流量的预测结果。
- (2) 方案 B: 对图 5(a)所示网络流量序列先使用参考文献[8]中提出的平稳化方法处理,然后用 AR 模型进行预测。
- (3) 方案 C: 对图 5(a)所示网络流量序列先使用参考文献[8]中提出的平稳化方法处理,然后用 ARMA 模型按参考文献[7]进行预测。

利用方案 A、B、C,分别经过一、五、十步预测得到对应 $X_i (577 \leq i \leq 864)$ 的预测结果,它们在不同预测步长下所产生的预测误差如表 2 所示。

表 2 几种方案的预测误差对比表

| | 1-step prediction | | 5-step prediction | | 10-step prediction | |
|---|-------------------|--------|-------------------|--------|--------------------|---------|
| | MAE | MRE | MAE | MRE | MAE | MRE |
| A | 1.632 | 1.571% | 5.696 | 5.606% | 10.448 | 10.466% |
| B | 1.204 | 1.185% | 2.891 | 3.001% | 4.151 | 4.512% |
| C | 1.142 | 1.073% | 2.617 | 2.846% | 4.138 | 4.321% |

对比表 1 和表 2 中数据可以看出,本文方法的预测误差比方案 A 的预测误差减小了 60% 以上,这表明小波分解和重构在预测过程中的作用是非常明显的。对比本文方法和方案 B、C 的误差数据,可知道,本文方法在预测效果上比参考文献

(下转第 54 页)

的方向。至于可部署性问题,我们认为性能的改善和可部署性之间应该存在一个较好的折衷。

• 控制理论、优化理论的应用研究。从以上的思路和算法的分析介绍中,不难看出,它们虽然对网络传输性能有所改善,但其自身几乎都存在着这样或那样的问题。其直接原因就是这些算法的设计都是针对局部的某一具体问题,依靠直觉的推断,根据经验改进算法,缺乏一套有效的、系统的理论分析工具对算法的设计进行指导。控制理论、优化理论作为相当成熟的系统理论,有相当多的方法可以借鉴到网络性能优化中来。近来,国内外的很多专家学者都认识到了可以应用控制理论、优化理论中的方法来解决网络中的问题,并做了一些尝试工作^[18,19]。然而,由于网络自身的复杂性,这方面的研究还不成熟。所以,如何有效地将控制理论、优化理论的思想运用于日趋复杂的网络中,来指导目前单纯根据经验来改进算法的不足,将是一个未来研究的热点问题,也是一个难点问题。

结束语 本文对高速网络环境下的传输性能优化研究进行了分类,并重点分析了各分类中一些代表性的思路。同时在文中给出了几个较有价值的热点研究方向,希望能起到抛砖引玉的作用。

参考文献

- 1 Internet2. Internet2 NetFlow; Weekly Reports, 2002. URL: <http://netflow.internet2.edu/weekly/>
- 2 Weigle E, Feng Wu-chun. Dynamic Right-Sizing: a Simulation Study. In: Proceedings of IEEE International Conference on Computer Communications and Networks (ICCCN), October 2001
- 3 Van Jacobson, Braden R, Bor-man D. TCP extensions for high performance. RFC1323, May 1992
- 4 Semke J, Mahdavi J, Mathis M. Automatic TCP Buffer Tuning. In: Proceedings of ACM SIGCOMM, October 1998

(上接第 49 页)

[7,8]所采用的方法要好,可以有效地降低预测误差。这些证明,基于小波变换与自回归模型的方法,对网络流量预测是可行、有效的,并且比常用的预测方法具有更高的预测准确度。

结论 本文提出一种基于小波变换与自回归模型的网络流量预测方法,先将网络流量数据经过 Mallat 算法分解与单支重构,然后对重构后的近似部分和各细节部分别建立自回归模型,进而实现原始网络流量的预测。实验结果表明,该方法比传统的几种预测方法具有更高的预测精度,这表明小波变换在网络流量预测中的作用是显著的。对于这种方法还可以从如下两个方面进行改进:(1)在对单支重构得到的序列建立模型时,如果再辅以其它平稳化方法可以进一步提高预测准确度,比如:对数变换、差分、季节差分,甚至包括参考文[8]的平稳方法。(2)基于小波变换的预测方法,还可以跟其它常用模型结合使用,比如:ARMA 模型、ARIMA 模型等,由于这些模型比 AR 模型通常具有更好的预测效果,因此这类结合方法的预测准确度更高。

值得一提的是,在基于小波变换的预测中,还存在确定分解层数以及选用合适小波函数的问题。分解层数越多,分解后的信号在频率成分上越单一,各部分的平稳性也越好,但是随着分解层数的增加,所需的计算量也显著增大,因此分解层数的选择应适中。选用不同的小波函数,得到的预测效果会略有不同,比较常用的滤波器有:Battle 和 Lemarie 的 27-系数滤波器(简称 B-L 小波),I. Daubechies 的 4-系数滤波器(简称 D-4 小波),I. Daubechies 的 20-系数滤波器(简称 D-20 小

- 5 Floyd S. High Speed TCP for Large Congestion Windows. RFC 3649, December 2003
- 6 Dunigan T, Mathis M, Tierney B. A TCP Tuning Daemon. SuperComputing (SC), November 2002
- 7 Ostermann S, Allman M, Kruse H. An Application-Level solution to TCP's Satellite Inefficiencies. In: Workshop on Satellite-based Information Services (WOSBIS), November 1996
- 8 Sivakumar H, Bailey S, Grossman R. Pockets: The Case for Application-level Network Striping for Data Intensive Applications Using High Speed Wide Area Networks. In: Proceedings of Super Computing, November 2000
- 9 Hacker T, Noble B, Athey B. Improving Throughput and Maintaining Fairness Using Parallel TCP. In: Proceedings of IEEE Infocom 2004, March 2004
- 10 Kelly T. Scalable TCP: Improving Performance in HighSpeed Wide Area Networks. ACM Computer Communications Review, April 2003
- 11 Xu Lisong, Harfoush K, Rhee I. Binary Increase Congestion Control for Fast Long-Distance Networks. In: Proceedings of IEEE Infocom 2004, March 2004
- 12 Cheng Jin, Wei D X, Low S H. FAST TCP: motivation, architecture, algorithms, performance. IEEE Infocom, March 2004
- 13 Cheng Jin, Wei D X, Low S H, et al. FAST TCP: From Theory to Experiments [ED/OL]. <http://netlab.caltech.edu/>, 2003
- 14 Tan LS, Yuan C, Zukerman M. FAST TCP: Fairness and queuing issues. IEEE Communications Letters, 2005, 9 (8): 762~764
- 15 Katabi D, Handley M, Rohrs C. Congestion Control for High Bandwidth-Delay Product Networks. In: Proceedings of ACM SIGCOMM 2002, August 2002
- 16 Xia Y, Subramanian L, Stoica I, et al. One more bit is enough. ACM SIGCOMM Computer Communication Review, 2005, 35 (4): 37~48
- 17 Chiu D, Jain R. Analysis of the increase and decrease algorithms for congestion avoidance in computer networks [J]. Computer Networks and ISDN Systems, 1989, 17(1): 1~14
- 18 Shor M H, Lik W J. Application of control theory of modeling and analysis computer system. <http://www.cse.ogi.edu/~kangli/>
- 19 Habibipou F, Khajepour M, Galily M. Application of control engineering methods to congestion control in differentiated service networks. Control Engineering Practice, 2006, 14(4): 425~435

波),以及 Antonini 的一组双正交小波基对应的滤波器等。从定性、定量两个方面,对基于小波变换的预测方法进行误差分析,以进一步提高网络流量预测的准确度,是我们下一步的主要研究工作。

参考文献

- 1 Yu I, Kim C. A Novel Short-Term Load Forecasting Technique Using Wavelet Transform Analysis [J]. Electric machines and power systems, 2000, 28: 537~549
- 2 Renaud O, Starck J L, Murtagh F. Wavelet-based Forecasting of Short and Long Memory Time Series [EB/OL]. http://www.unige.ch/ses/metri/cahiers/2002_04.pdf, May 2002
- 3 Paxson V, Floyd S. Wide-area Traffic: The failure of Poisson modeling [J]. IEEE/ACM Trans, Networking, 1995, 3: 226~244
- 4 Tsybakov B. Self-similar Process in Communications Networks [J]. IEEE Trans on Information Theory, 1998, 44(5): 1713~1725
- 5 韩良秀,丛锁.基于小波技术的网络流量特性刻画[J].小型微型计算机系统,2001,2(9):1110~1113
- 6 丛锁,韩良秀.基于离散小波变换的网络流量多重分形模型[J].通信学报,2003,24(5):3~8
- 7 邹柏贤,刘强.基于 ARMA 模型的网络流量预测[J].计算机研究与发展,2002,39(12):1645~1652
- 8 邹柏贤,姚志强.一种网络流量平稳化方法[J].通信学报,2004,25(8):14~23
- 9 王振龙.时间序列分析[M].中国统计出版社,2002
- 10 Mallat S. A theory for multiresolution signal decomposition: The wavelet representation [J]. IEEE Trans Pattern Anal Mach Intel, July 1989, 11: 674~693
- 11 Antonini M, et al. Image coding using wavelet transforms. IEEE Trans. on Image Processing, 1992, 1(2): 205~220