

长程突发通信量的分数自回归预测

闻 勇^{1,2} 朱光喜² 谢长生¹

(华中科技大学计算机科学与技术学院 武汉 430074)¹ (华中科技大学电子与信息工程系 武汉 430074)²

摘 要 以数据包传输的通信量在不同网络条件下均表现出自相似性,自相似通信量在各时间尺度上均具有长程突发特性,其是以泊松过程为模型所描述的短程相关通信量所无法描述的。近来对自相似通信量的高精度测量与研究证实:网络中广泛存在的重尾特性是通信量自相似产生的原因。同时充分提取通信量的自相似性与重尾特性相关信息,是准确预测长程突发通信量的关键。在一种 α -基于平稳过程的自相似通信量模型基础上,提出两种独立的自回归预测方法:FAR(Fractional AutoRegressive)预测、FNAR(Fractional Nonlinear AutoRegressive)预测。对这两种预测值进行不同方案的混合预测得到最终预测结果,进一步提高预测精度。

关键词 长程突发,通信量,自回归,预测

中图法分类号 TP393 文献标识码 A

Fractional Autoregressive Prediction for Long Range Bursty Traffic

WEN Yong^{1,2} ZHU Guang-xi² XIE Chang-sheng¹

(College of Computer Science and Technology, Huazhong University of Science and Technology, Wuhan 430074, China)¹

(Department of Electronic and Information, Huazhong University of Science and Technology, Wuhan 430074, China)²

Abstract The traffic with data packet transmission in various network conditions exhibits convincingly self-similarity causing the long range burstiness which cannot be captured by traditional telecommunication traffic models based on Poisson process or Markov process. The updated explicit high-resolution measurement and researches for the traffic reveal that the heavy tailness existing extensively in the network brings about the self-similarity of the traffic. The information extraction from the self-similarity and long range dependence is the key fact for the exact prediction of the long range bursty traffic. Two distinctive AutoRegressive predictors based on α -stable self-similar traffic model were presented. The predictors including FAR(Fractional AutoRegressive), FNAR(Fractional Nonlinear AutoRegressive) can minimize the dispersion according to the criteria with infinite variance. The final predicted values with the different schemes were obtained by combining the previous two individual predicted values for the higher predicted precision.

Keywords Long range dependence, Traffic, Autoregressive, Prediction

自从 Leland 等提出网络通信量在广泛时间尺度上的统计特性具有自相似性(Self-Similarity),表现出长程突发之后^[1],全球研究人员对局域网(LAN)、广域网(WAN)、WWW、ISDN 及无线多媒体通信网等收集的高精度原始数据进行统计分析均证实:通信量中的自相似性始终普遍存在,且不因网络的拓扑结构、用户数量、服务类型等发生变化;基于泊松过程的电信网络通信量模型无法刻画及预测自相似网络量的长程相关性。随着网络快速发展,自相似通信量的预测对于流量控制与管理、网络协议设计、通信量排队分析等尤为关键。

最近研究发现^[2]:网络中广泛存在的重尾特性,即非高斯性是产生自相似性的根源。而目前几乎所有的自相似通信量预测方法均未同时考虑通信量的自相似性与重尾特性。本文在一种新的基于 α -平稳过程的自相似通信量模型的基础上,

对于长程相关通信量提出了两种分数自回归预测,实现在无限方差意义下的最小偏差预测。对这两种不同方法的预测值进行混合预测得到最后的预测结果,以期进一步提高预测精度。

1 相关背景回顾

对于一个随机变量 X ,若存在参数 $0 < \alpha \leq 2, \sigma \geq 0, -1 \leq \beta \leq 1$ 及实数 μ 使其特征函数有如下形式^[3]:

$$Ee^{(i\mu X)} = \begin{cases} \exp\{i\mu t - \sigma |t|^\alpha [1 - i\beta \tan(\frac{\alpha\pi}{2} \text{sign}(t))]\}, & \alpha \neq 1 \\ \exp\{i\mu t - \sigma |t| [1 - i\beta \frac{2}{\pi} \text{sign}(t) \log|t|]\}, & \alpha = 1 \end{cases} \quad (1)$$

其中参数 α 为平稳参数,参数 β, σ 及 μ 唯一,且

到稿日期:2008-10-08 返修日期:2008-12-17 本文受国家自然科学基金重大项目(No. 60496315),国家自然科学基金(No. 605020230),国家 863 计划(No. 2003AA12331005)资助。

闻 勇(1969-),男,博士后,主要研究方向为计算机网络、数据挖掘、智能计算等,E-mail:yongwen@yahoo.cn;朱光喜(1945-),男,教授,博士生导师,主要研究方向为移动通信等;谢长生(1957-),男,教授,博士生导师,主要研究方向为计算机存储技术等。

$$\text{sign } t = \begin{cases} 1 & \text{当 } t > 0 \\ 0 & \text{当 } t = 0 \\ -1 & \text{当 } t < 0 \end{cases} \quad (2)$$

则称 X 是 α -平稳分布 $S_{\gamma, \beta, \mu}(\alpha)$ 。

LFSM (Linear fractional stable motion) 是随机过程 $\{L_{\alpha, H}(a, b; t), -\infty < t < \infty\}$, 定义如下:

$$L_{\alpha, H}(a, b; t) = \int_{-\infty}^{\infty} f_{\alpha, H}(a, b; t, x) M(dx) \quad (3)$$

其中: $f_{\alpha, H}(a, b; t, x) = a((t-x)_+)^{H-1/\alpha} - ((-x)_+)^{H-1/\alpha} + b(((t-x)_+)^{H-1/\alpha} - ((-x)_+)^{H-1/\alpha})$

其中 a, b 是实数, $|a| + |b| > 0, 0 < \alpha < 2, 0 < H < 1, H \neq 1/\alpha$, M 是具有 Lebesgue 控制测度和偏斜密度 $\beta(x)$ 的 \mathbf{R} 空间上的 α -平稳随机测度。

LFSM 的平稳增量过程 LFSN (Linear Fractional Stable Noise) 过程 $N_{\alpha, H}(i)$ 表示如下:

$$N_{\alpha, H} = L_{\alpha, H}(a; b; i+1) - L_{\alpha, H}(a; b; i) \quad (4)$$

这里 M 为具有 Lebesgue 控制测度 α -平稳测度。由 LFSN 定义知: 当 $H > 1/\alpha$ 时, $N_{\alpha, H}(i)$ 呈现出长程相关; 当 $H < 1/\alpha$ 时, $N_{\alpha, H}(i)$ 呈现出负相关。这表明: 当具有无限方差的独立信息来源多路复用时, 其聚集网络通信量趋于极限时服从 α -平稳分布。虽然无限方差仅为一个表示无限持续时间的理论概念, 但它在有限长度的时间序列中是可以观察到的, 且平稳 $i. i. d.$ 随机变量的线性叠加也服从 α -平稳分布, 这是利用 LFSN 对网络通信量刻画的原因。

基于 LFSN 过程的网络通信量的模型表示为^[4]:

$$M(i) = C_1 N_{\alpha, H}(i) + C_2 \quad (5)$$

其中 $M(i)$ 表示在单位时间内到达的包数量; $N_{\alpha, H}(i)$ 是参数为 $\beta=0, \sigma=1, \mu=0, H > 1/\alpha$ 的 LFSN 过程。该模型式(5)有 4 个参数, 其物理含义分别为: 参数 α 描述网络通信量的突发程度, 参数 H 描述通信量的自相似程度, 参数 C_2 描述通信量的平均速率, 参数 C_1 描述通信量中相对于平均速率的偏差程度。

2 通信量预测

FARIMA (Fractional AutoRegressive Integrated Moving Average, 即分数自回归集滑动平均) 过程可同时描述通信量的长程相关性和短程相关性, 是长程相关通信量的有效预测工具。FARIMA(p, d, q) 具有下列形式:

$$\Phi(B)\Delta^d X_n = \Theta(B)\epsilon_n \quad (6)$$

这里: $\Delta^d = (1-B)^{-d}, d = H - 1/\alpha, \Phi(B) = 1 + \Phi_1 B + \dots + \Phi_p B^p, \Theta(B) = 1 + \Theta_1 B + \dots + \Theta_q B^q, p$ 是自回归阶数, q 是滑动平均阶数, B 是后向算子。模型 FARIMA(p, d, q) 中 $\{\epsilon_n | n = \dots, -1, 0, 1, \dots\}$ 若是一白噪声序列即为高斯假设, 基于通信量模型式(5)的 FARIMA 预测模型中 $\{\epsilon_n\}$ 为具有无限方差的 α -平稳新息, 是非高斯假设。目前已知的 FARIMA 预测方法几乎都是针对高斯过程的, 即 $d = H - 1/2$ 时, 这些预测都不包括通信量的重尾信息。参数 $d = H - 1/\alpha$ 中的参数 H 是描述通信量的自相似程度, 参数 α 是刻画通信量的非高斯程度, 即重尾特性的, 故参数 d 充分体现通信量自相似性与重尾性的内在关系, 其大小是通信量长程突发程度的标志。充分利用参数 d 的信息是准确预测长程突发通信量的关键。

由式(6)定义可知: 一个 FARIMA(p, d, q) 过程可以看

作由一个 FARIMA($0, d, 0$) 驱动的 ARMA(p, q) 过程。方差无限意义下的 FARIMA 预测十分困难, 而 ARMA(p, q) 在参数 q 分别取零时退化为 AR 过程。增加 AR 过程的阶数时, AR 预测等价于 ARMA 预测, 由式(6)可知

$$X_n = \sum_{j=0}^{\infty} u_j \epsilon_{n-j} \quad (7)$$

其中, u_i 是 $X_n = \Phi(B)^{-1} \Delta^{-d} \epsilon_n$, 其解的存在性与收敛性见文献[4]。我们提出两种分数 AR 预测, 即分数线性 AR (Fractional AutoRegressive, 简称 FAR) 预测、分数非线性 AR (Fractional Nonlinear AutoRegressive, 简称 FNAR) 预测。

2.1 FAR 预测

基于 α -平稳新息 (innovation) 的线性 AR 预测模型为:

$$X_n = \sum_{i=1}^p a_i X_{n-i} + \epsilon_n \quad (8)$$

若假定通信量服从式(4), 根据通信量模型式(5)可知新息

$\epsilon_n = X_n - \hat{X}_n$ 同样服从式(4), 所以有下式:

$$\hat{X}_n = \sum_{i=1}^p a_i X_{n-i} \quad (9)$$

因为 α -平稳变量所属的 l_p -范数空间中的 AR 系数的最小估计方法可以看作 l_1 -范数空间中最小绝对值估计与 l_2 -范数空间中最小平方估计方法的一般化。

若 X_1 和 X_2 是联合 $S\alpha S, \alpha > 1$, 且假定 Γ 是随机矢量 (X_1, X_2) 的谱测度, X_1 在 X_2 的协变是实数:

$$[X_1, X_2]_{\alpha} = \int_{\mathbb{S}_2} s_1 s_2^{(\alpha-1)} \Gamma(ds) \quad (10)$$

其中: $s^{(p)} = |s|^p \text{sign } s$ 。设 $\{X_i | i = 1, \dots, \infty\}$ 为 α -平稳随机变量, 若对预测偏差 $\hat{\epsilon} \in [\hat{\epsilon}, X_{n+1-i}]_{\alpha} = 0$, 则存在协变正交。

若有 $\{a_i [\hat{\epsilon}, X_{n+1-i}]_{\alpha} = 0\}$, 使得 $E[X_i, aX | X] = 0$, 则称 \hat{X}_{n+k} 为协变正交线性预测 (Covariation Orthogonal Linear Predictor, 简称 COLP)。在 COLP 意义下存在无偏估计方法, 即: 对于所有平稳随机变量 X_n , 其协变正交一步前向无偏预测为:

$$\hat{X}_{n+1} = \sum_{i=1}^n a_i X_{n+1-i} \quad (11)$$

利用 l_p -范数空间的分数低价矩 (Fractional Low Order Moments, 简称 FLOMs) 可以得到 AR 模型的系数, 即下列线性等式:

$$Ca = B \quad (12)$$

其中, $B = [\lambda(1) \lambda(2) \dots \lambda(P)]^T, a = [a_1 a_2 \dots a_p]^T$, 且

$$C = \begin{bmatrix} \lambda(0) & \lambda(-1) & \dots & \lambda(1-P) \\ \lambda(1) & \lambda(0) & \dots & \lambda(2-P) \\ \vdots & \vdots & \ddots & \vdots \\ \lambda(P-1) & \lambda(P-2) & \dots & \lambda(0) \end{bmatrix} \quad (13)$$

其中: $\lambda(k) = \frac{E\{X_n X_{n-k}^{(\alpha-1)}\}}{E\{|X_{n-k}|^{\alpha}\}}$ 。

最后根据式(9)得到 FAR 的预测值。

$$\hat{X}_{\text{FAR}} = \Delta^d \hat{X}_{\text{AR}} \quad (14)$$

2.2 FNAR 预测

基于 α -平稳新息的 NAR 模型可以表示为下列多项式:

$$X_n = \sum_i a_i^{(1)} X_{n-i} + \sum_i \sum_j a_{i,j}^{(2)} X_{n-i} X_{n-j} + \dots + \epsilon_n \quad (15)$$

其中, X_n, ϵ_n 为 α -平稳随机变量。确定式(8) r 阶数后, 要确定其相应的参数。根据 Gauss-Markov 定理: AR 过程新息序列服从高斯分布时, 最佳线性无偏估计是基于最小平方 (Least

Square,简称LS)准则的,且其参数最大似然估计(Maximum Likelihood Estimation,简称MLE)等于LS估计。这里通过求解 l_p -范数最小化问题的根,获取AR系数:

$$\hat{a} = \operatorname{argmin}_{\hat{a}} \sum_{n=1}^L |X_n - \sum_{k=1}^m a_k X_{n-k}|^p \quad (16)$$

这里 $\hat{a} = [a_1, \dots, a_m]^T$,对于 $k \leq 0$ 且 $-1 < p < \alpha$,式(9)成立。

LPN(l_p -范数)估计法的两个边界分别为最小绝对偏差估计(Least Absolute Deviations Estimator,简称LAD估计)与LS估计法。对于 $i=1, \dots, N$ 存在 $a_i(L) \stackrel{(LPN)}{\rightarrow} a_i$ 。当误差函数为:

$$\rho(\cdot) = \sum_{n=M}^N \rho(X_n - a_1 X_{n-1} - \dots - a_M X_{n-M}) \quad (17)$$

当 $\rho(\cdot)$ 满足Lipschitz条件时,基于SaaS的AR过程的M-估计收敛。对于线性 l_1 -范数最小化,采用递归重加权值最小平方(Iteratively Reweighted Least Squares,简称IRLS)。若 $x_n = [x_n x_{n-1} \dots x_{n-N+1}]^T$, s 是期望信号,最小化下式: $J = \sum |s_n - a^T x_n|^p$,即两边求导:

$$\partial J / \partial a_j = -\sum p |r_n|^{p-1} x_{n-j+1} \operatorname{sign}(r_n) = 0 \quad (18)$$

其中残差矢量为: $r_n = s_n - a^T x_n$ 。因 $\operatorname{sign}(r_n) = r_n / |r_n|$,上式为: $\partial J / \partial a_j = -\sum p |r_n|^{p-1} x_{n-j+1} = 0$ 。若对角线权值矩阵为: $W = \operatorname{diag}(|r_n|^{p-2})$ 。其求和等式可表示为矩阵形式:

$$\nabla_a J = X^T W (Xa - s) = 0 \quad (19)$$

其中, $a = [a_1 a_2 \dots a_M]^T$

$$X = \begin{bmatrix} X_1 & 0 & \dots & 0 \\ X_2 & X_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ X_L & X_{L-1} & \dots & X_{L-N+1} \end{bmatrix}$$

AR预测算法如下:

- 1) $\hat{a}(0) = (X^T X)^{-1} X^T U$
- 2) $r_i(k) = [U - X \hat{a}(k)]_i$;
- 3) $w_{ii}(k) = p |r_i(k)|^{p-2}$
- 4) $\hat{a}(k+1) = [(X^T W(k+1) X)^{-1} X^T W(k) U]$
- 5) 若 $\{ ||r(k+1)||_p - ||r(k)||_p \} / ||r(k)||_p < \epsilon$ 则停止;否则转到步骤2)。

其中: $a(k)$ 是AR第 k 次递归的参数矢量, U 是数据矢量,矢量 $X_k = (X_1, \dots, X_L)^T$, U 是 α -新息矢量, $||r(k)||_p$ 是 l_p -范数。 w_{ii} 是矩阵 W 的对角线上在 i 上的值:

$$w_{ii} = \begin{cases} |r_i|^{p-2}, & |r_i| > \epsilon \\ e^{p-2}, & |r_i| < \epsilon \end{cases} \quad (20)$$

其中: ϵ 为一个极小的正数。

将矩阵 X 定义为 $X^{(K)} = [X^{(1)} X^{(2)} \dots X^{(K)}]$ 可以得到式(15)的解。这里 K 为非线性阶数, $X^{(i)}$ 为Volterra扩展的 i 价多项式的矩阵。本文预测实验取 $K=2$ 。

根据式(9)得到FNAR的预测值,即,

$$\hat{X}_{FNAR} = \Delta^d \hat{X}_{NAR} \quad (21)$$

2.3 混合预测

对上述两种预测方法的预测值采用两种方案进行混合预测以期提高预测精度。

2.3.1 混合预测方案一

采用RLS(Recursive Least Square)算法进行混合预测,最终的预测值为:

$$\hat{x}_{RLS}(n) = \lambda_1 \hat{x}_1(n) + \lambda_2 \hat{x}_2(n) \quad (22)$$

LRS算法中参数 λ 估计原理见文献[5]。

2.3.2 混合预测步骤

- 1)对原始数据进行预处理得到一个均值为零的新时间序列;
- 2)对该序列进行参数 (H, α) 估计,并得到参数 d 的值;
- 3)对序列分别进行FAR, FNAR预测,得到独立预测值;
- 4)对两种独立预测值分别采用LRS方案进行混合预测,得到序列的混合预测值;
- 5)对上述结果采用与步骤1)相反的过程得到原始数据的最终预测结果。

3 预测实验与结果分析

对于实际数据进行无限方差意义下的FAR, FNAR最小偏差预测,相对偏差的定义如下:

$$\operatorname{Disp}^d = \left(\frac{1}{L} \sum_{j=1}^L \left| \frac{\hat{x}_j - x_j}{x_j} \right|^d \right)^{\frac{1}{d}} \quad (23)$$

预测实验为进一步预测,实际踪迹为数据集BC-Oct8Ext^[7]与无线多媒体CDMA数据集^[8]。采用FAR, FNAR预测及最后的两种混合预测对于数据集BC-Oct89Ext分别在0.1秒、1秒和10秒3个时间尺度进行预测,对于CDMA数据集分别1秒、10秒和100秒3个时间尺度进行预测。图1、图2分别为BC-Oct89Ext数据集和CDMA数据集在3个不同时间尺度上的混合预测结果。




图1 实际数据BC-Oct89Ext与图2 CDMA实际数据与其混合预测值的比较

预测试验结果表明:FAR, FNAR预测算法对于具有重尾特性的自相似网络通信量在广泛时间尺度范围均能准确地预测,预测偏差较高斯算法精度标准68%更小,且简洁快速。最后的两种混合预测方法均能进一步提高预测精度。

结束语 本文在充分提取网络通信量自相似性与重尾程度信息的基础上提出了两种对于具有长程突发通信量的分数自回归预测方法,在无限方差准则下实现对通信量在广泛时间尺度内的最小偏差预测。对于这两种独立的预测值进行两种不同方案的混合预测,可以提高最终预测结果的精度,对实际踪迹的预测实验证实了上述结论。在以后的工作中,我们期望将这些预测方法应用到网络性能分析与网络管理之中。

参考文献

- [1] Leland W, Taqqu M, Willinger W, et al. On the Self-Similar Nature of Ethernet Traffic (Extended Version) [J]. IEEE/ACM Transactions on Networking, 1994, 2: 1-15

(下转第96页)

需求层的关注点空间,然而并没有给出具体的多维分离模型,并且文献[14]的工作仅限于需求阶段。文献[15]针对模型驱动软件项目过程采用多种开发方式、缺少系统化方法指导的问题,提出了一种模型驱动过程框架设计方法。该方法采用一般化、行为化和抽象化作为元关注维,对开发方式进行比较,并结合这三维的期望演化曲线,给出过程实现模型框架。然而该文所描述的三维只是一个抽象概念框架,并不对应具体软件系统的开发过程。

结束语 非功能属性的处理长期以来一直困扰着软件开发人员,成为软件工程领域内一个热点和难点问题。本文立足于软件体系结构设计的早期阶段,提出一种多维分离非功能属性的建模方法。该方法通过“1+X”模型,将软件体系结构的非功能属性划分为X个维度,并进一步细化为包含多个非功能子属性的集合,同时提供了软件体系结构的非功能属性库,采用XML对非功能属性和子属性进行了规约。“1+X”模型直观地描述了在软件体系结构设计阶段对非功能属性和功能属性所采用的不同处理方式。在实际系统的软件体系结构设计中,可以借助本文所提供的非功能属性库选取适合的非功能属性,直接重用非功能属性及其子属性的规约。本文提出的方法,为处理软件体系结构的非功能属性提供了一种新的思路。

在今后的一段时间内将进一步完善非功能属性库,明确“1+X”模型中1与X之间的关系及其规约方法,研究非功能子属性向体系结构构成元素映射的映射规则。

参 考 文 献

- [1] Chung L, Nixon B A, Yu E, et al. Non-Functional Requirements in Software Engineering [M]. Norwell; Kluwer Academic Publishers, 2000
- [2] Xu L, Ziv H, Richardson D, et al. Towards Modeling Non-Functional Requirements in Software Architecture[EB/OL]. http://trese.cs.utwente.nl/early-aspects-AOSD2005/Papers/12_XuZivRichardsonLiu_UCIrvineCSFullerton.pdf
- [3] Kiczales G, Lamping J, Mendhekar A, et al. Aspect-Oriented Programming[C]//Proceedings of 11th European Conference on Object-Oriented Programming (ECOOP1997). New York; Springer-Verlag, 1997; 220-242
- [4] Tarr P, Ossher H, Harrison W, et al. N Degrees of Separation: Multi-Dimensional Separation of Concerns[C]//Proceedings of the 21st Int'l Conf. on Software Engineering (ICSE1999). Washington; IEEE, 1999; 107-119
- [5] Wen Jing, Shi Ying, Zhang Lin-lin. Architectural design of the

Online Auction System with Aspect-Oriented Software Architecture Design approach[C]//Proceedings of 2008 IEEE International Conference on e-Business Engineering (ICEBE 2008). Los Alamitos; IEEE, 2007; 5-12

- [6] Eeles P. Capturing architectural requirements[R]. 2004
- [7] Rashid A, Moreira A, Araujo J. Modularization and Composition of Aspectual Requirements[C]//Proceedings of the 2nd on Aspect-Oriented Software Development. New York; ACM, 2003; 11-20
- [8] Dai L, Cooper K, Wong W E. Modeling and Analysis of Performance Aspects for Software Architecture; a UML-based approach [J]. Software Engineering and Knowledge Engineering, 2006, 16(3): 347-378
- [9] Xu L, Ziv H, Alspaugh T A, et al. An Architectural Pattern for Non-functional Dependability Requirements [J]. Systems & Software, 2006, 79(10): 1370-1378
- [10] Bagheri H. Injecting Security as Aspectable NFR into Software Architecture[C]//Proceedings of the 14th Asia-Pacific Software Engineering Conference (APSEC'07). 2007; 310-317
- [11] Bagheri H, Mirian-Hosseinabadi S H, Esfahani H C. An Aspect Enhanced Method of the NFR Modeling in Software Architecture[C]//Proceedings of 10th International Conference on Information Technology (ICIT 2007). 2007; 240-242
- [12] Bashir I, Serafini E, Wall K. Securing Network Software Applications; Introduction[J]. Communications of the ACM, 2001, 44(2): 28-30
- [13] Sutton S, Rouvellou I. Modeling of Software Concerns in Cosmos[C]//Proceedings of the 1st International Conference on Aspect-oriented Software Development (AOSD'02). New York; ACM Press, 2002; 127-133
- [14] Moreira A, Araujo J, Rashid A. Multi-Dimensional Separation of Concerns in Requirements Engineering [C] // Proceedings of 13th Requirements Engineering Conference (RE'05). Washington; IEEE, 2005; 285-296
- [15] 段玉聪, 顾毓清. 多维关注分离的模型驱动过程框架设计方法[J]. 软件学报, 2006, 17(8): 1707-1716
- [16] Pinto M, G'amez N, Fuentes L. towards the Architectural Definition of the Health Watcher System with AO-ADL[C]//Proceeding of the Early Aspects Workshop at ICSE 2007. May 2007; 94-114
- [17] Auction System[OL]. http://igl.epfl.ch/research/use_cases/RE-A2-case-studies/auction/problem-description.html
- [18] 杨放春, 龙湘明. 软件非功能属性研究[J]. 北京邮电大学学报, 2004, 27(3): 1-12

(上接第 81 页)

- [2] Adler R, Feldman R, Taqqu M. A Practical Guide to Heavy Tails[M]. Birkhauser, Boston; Chapman & Hall, 1998
- [3] Samorodnitsky G, Taqqu M. Stable Non-Gaussian Random Processes[M]. London; Chapman & Hall, 1994
- [4] 闻勇. 具有重尾特性的自相似网络通信量建模及预测[D]. 武汉: 华中科技大学, 2006

- [5] Rice J. Mathematical Statistics and Data Analysis, Second Edition[M]. Wadsworth Inc, 1995
- [6] Li H X, Chen C L, Huang H P. Fuzzy Neural Intelligent Systems; Mathematical Foundation and the Applications in Engineering[M]. FL; CRC Press, 2001
- [7] URL; <http://ita.ee.lbl.gov/html/traces.html>
- [8] URL; <http://crawdad.cs.dartmouth.edu/data.php>