

基于 FAR 模型的网络通信量自适应预测

徐晓东¹ 饶云华² 邹雪城²

(重庆信科设计有限公司 重庆400065)¹ (华中科技大学电子科学与技术系 武汉430074)²

摘要 本文分析了网络通信量中存在的自相似现象,并讨论了自相似通信量的预测及其对于网络性能分析的重要意义,提出了一种考虑了网络通信量自相似性的自适应预测方法,该预测方法在利用通信量自相似性的同时也考虑了通信量的短程相关特性,能够对实际通信量进行良好的预测。最后用实验仿真验证了这种方法在通信量预测中的有效性。

关键词 FAR,通信量,预测,自适应

Adaptive Predictor of Network Traffic Based on FAR

XU Xiao-Dong¹ RAO Yun-Hua² ZOU Xue-Cheng²

(ChongQing Information Technology Designing CO.,LTD,Chongqing 400065)¹

(Dept. of Electronic Sci&Tech., Huazhong Univ. of Sci&Tech., Wuhan 430074)²

Abstract In this paper, the self-similar phenomenon in network traffic is analyzed. The prediction of self-similar traffic and its impact on the performance analysis of network system are also discussed. A adaptive predictor considered self-similarity of network traffic is proposed. This predictor takes account of the Long-Range Dependence and Short Range Dependence character of traffic at the same time, and can predict the real network traffic perfectly. At last some experiments confirm the validity of this predictor.

Keywords FAR, Traffic, Predictor, Adaptive

1. 引言

在网络通信量建模中,很长时间以来主要使用泊松过程来描述。泊松过程有着十分简单的相关函数结构,能够对短程相关(short-range dependence)通信量进行精确分析和有效控制,非常具有吸引力。

然而,自从 Leland 等^[1,2]的论文中第一次明确提出 LAN 中的通信量具有自相似性以来,研究人员发现在包括 WAN、ATM 等各种类型的网络中,虽然网络拓扑结构、用户数量、服务类型各不相同,但是这些网络通信量始终具有自相似性^[3~9]。

网络通信量的自相似性,也就是长程相关(long-range dependence)性质,对于网络性能和网络设计有着十分重要的影响和作用。目前已有许多这方面的研究,如输入网络通信量的长程相关性对于排队性能的影响^[10,11],以及自相似网络通信量在不同时间尺度上对于 TCP 性能的影响等^[12,13],这些研究都充分说明了通信量的自相似性对网络性能具有很大的影响,尤其在大时间尺度上更具有决定性的作用。

由于自相似网络通信量对网络性能的重要影响,在网络设计中如何利用这一性质来预测网络通信量,有效分配和利用网络资源以保证网络 QoS 及提高网络性能是非常有意义的。

在自相似网络通信量预测研究中,Gripenberg 和 Norros 等^[14]提出的分形布朗运动预测公式是自相似网络通信量理论预测的基础,该研究发现最近的数据对于下一步预测具有最大的影响。但是该公式在通信量预测中并不实用,因为一方

面利用该公式预测需要预先知道自相似过程的 Hurst 参数,另一方面在网络通信量中,除了长程相关性外还有短程相关性,而短程相关的预测不能用该公式取得;Shu Y. 等^[15]利用 FARIMA 模型进行预测,该模型满足网络通信量中具有长程相关性和短程相关性,但是该模型仍然需要在线估计通信量的 Hurst 参数,方法较为复杂并且由于 Hurst 参数估计的粗略性使得误差较大;T. Tuan 等^[12]利用通信量的自相似性质使用一种启发式的方法对通信量进行预测。该方法虽然简单,但是时间尺度、数据量的大小和 Hurst 参数的大小对于预测能力有较大的影响,使得该方法的精度较低;Ostring 等^[16~19]直接利用一般的时间序列的预测方法来进行预测,没有考虑自相似问题,所以效果也不明显。

针对以上方法的不足,我们考虑了网络通信量中同时存在的长程相关性和短程相关性,根据自相似性的特点提出了一种非参数的自适应预测算法。该算法进行预测时不用预先知道通信量的 Hurst 参数,又具有一定的精度。并且该方法计算量小,速度快,具有很强的实际应用意义。

本文第2节介绍了自相似的一些基本概念;第3节研究了自相似网络通信量的非参数预测算法;第4节对预测算法进行了验证,并且对结果进行了分析;最后对全文进行了总结。

2. 自相似过程理论

自相似过程是一种描述在统计意义上具有尺度不变性的随机过程。一个连续随机过程 $X(t)$ ($t=0,1,\dots$), 如果满足 $X(t)^D = a^{-H} X(at)$, $a > 1, t > 0, 0 < H < 1$, 那么这个过程就称为统计自相似的。如果对于任意有限维的联合概率分布等号

徐晓东 工程师,主要研究兴趣为多媒体通信。饶云华 博士研究生,主要研究兴趣为多媒体通信、计算机网络性能分析与 Network Processor 设计。邹雪城 博士生导师,主要研究方向为集成电路设计。

都成立,称为严格自相似;如果只是均值和方差相等,则称为宽自相似。

对于一个随机过程 $X(t)(t=0,1,\dots)$,如果自相关函数 $r(k)$ 为: $r(k) \sim k^{-D}L_1(k), k \rightarrow \infty, 0 < D < 1$, 其中 $\lim_{t \rightarrow \infty} L_1(tx)/L_1(x) = 1, x > 0$, 则 $X(t)$ 称为长程相关,即 $\sum_{k=0}^{\infty} r(k) \rightarrow \infty$ 。

常用的自相似过程主要有分形布朗运动(Fractional Brownian Motion,FBM)、分形高斯噪声(Fractional Gaussian Noise)、稳态分形过程和 FARIMA 过程等。

如果随机过程 $Y(t)(t$ 为实数)为高斯过程且为 H-sssi (self-similar stationary increment),则 $Y(t)$ 称为参数为 $H(1 < H < 1)$ 的分形布朗运动。

如果随机过程 $X(t)(t$ 为正整数)为具有参数 H 的分形布朗运动的增量过程,则称 $X(t)$ 为具有参数 H 的分形高斯噪声。

分形布朗运动的参数 H 满足 $0.5 < H < 1$ 时,则显示长程相关性, H 越大相关性越强。当 $H=0.5$ 时,则分形布朗运动简化为一般的布朗运动,其增量相互独立和无关,当 $H < 0.5$ 时,则为不稳定的(antipersistent)。

3. 自相似通信量的非参数预测算法

由于网络通信量中不仅具有短程相关性,而且还有长程相关性,这两种性质都会对预测产生影响,因此我们使用线性最小均方误差(linear minimum mean square error LMMSE)预测算法,同时根据自相似性的特点提出了一种非参数的自适应预测算法。该算法进行预测时不用预先知道通信量的 Hurst 参数,又具有一定的精度。并且该方法计算量小,速度快,具有很强的实际应用意义。

对于一个给定的网络通信量的时间序列 $x(k)(k=1,2,\dots,n)$,使用自适应预测算法,则下一通信量 $x(n+1)$ 的估计值 $y(n)$ 可表示为过去 p 个样本的加权和。

$$y(n) = [w_0 \ w_1 \ \dots \ w_{p-1}] [x(n) \ x(n-1) \ \dots \ x(n-p+1)]^T \quad (1)$$

其中 w_0, w_1, \dots, w_{p-1} 为 LMMSE 权值系数,可表示为

$$[w_0 \ w_1 \ \dots \ w_{p-1}] = [R(p) \ R(p-1) \ \dots \ R(1)]^{-1} \begin{bmatrix} R(0) & R(1) & \dots & R(p-1) \\ R(1) & R(0) & \dots & R(p-2) \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ R(p-1) & R(p-2) & \dots & R(0) \end{bmatrix} \quad (2)$$

其中 $R(n)$ 为时间序列的相关函数, p 为用于预测的样本的个数。恰当选取 p 的大小对于预测的有效性是很重要的。足够大的 p 值可以包含预测所需要的信息,但是太大的 p 在预测时计算量较大,本文中采用 Akaike information criterion (AIC) 来选取适合于该序列的 p 值。

由于(2)式计算量较大,在 LMMSE 的实际应用中采用改进的快速算法,该算法不需要先验知道序列的自相关函数,也避免了复杂的自相关函数的计算,因此在需要在线预测时是非常有用的。每一步预测的误差 $e(n) = y(n) - W(n)^T X(n)$ 反馈回去调整预测权值系数以减小预测的均方误差,所以权值 W 在每一步预测中都会调整。

其算法步骤如下:

a. 设定预测权值 W 的初值 $W(0)$ 。初始权值的设定对于减小预测误差,加快 W 的收敛速度是非常重要的。根据文[14]的结果可以知道,自相似通信量的最近一个值对于下一

值的影响最大,所以考虑 $X(n)$ 中的自相似性,我们将初始权值 $W(0)$ 设为 $W(0) = [0 \ 0 \ \dots \ 0 \ 1]^T$;

b. 对每一个新的预测数据,使用下面公式进行权值更新:

$$W(n+1) = W(n) + 2\mu e(n)X(n) \quad (3)$$

其中 μ 为步长,其实际计算值为 $0 < \mu < 1 / ((n+1) \sum_{i=0}^n x^2(i))$ 。当 $x(n)$ 为平稳序列, $w(n)$ 将收敛到最佳值。

由于通信量中长程相关与短程相关并存,在预测时间较长时,长程相关不可避免地会对预测产生影响。FAR (fractional auto-regressive) 模型不仅具有长程相关性,也具有短程相关性,所以我们下面利用 FAR 模型来分析这一影响。

首先我们介绍 FARIMA (p, d, q) 过程,定义一个 FARIMA (p, d, q) 随机过程 $Z = (Z_k, k=0, 1, 2, \dots)$ 具有如下形式:

$$\phi(B)\Delta^d Z_k = \theta(B)\epsilon_k \quad (4)$$

其中 $\epsilon_k, k=0, 1, 2, \dots$ 为白高斯过程, $\phi(B) = 1 - \phi_1(B) - \dots - \phi_p(B)$ 为自回归(AR)项, $\theta(B) = 1 - \theta_1(B) - \dots - \theta_q(B)$, 为滑动平均(MA)项。

后向算子 $BZ_k = Z_{k-1}$, Δ 表示差分算子,分形差分算子 $\Delta^d = (1 - B)^d = \sum_k C_k^d (-B)^k$, 其中 $C_k^d (-1)^k = \frac{\Gamma(-d+k)}{[\Gamma(-d)\Gamma(k+1)]}$, $\Gamma(\cdot)$ 表示 Γ 分布。

在这里采用模型 FARIMA ($p, d, 0$),也就是 FAR 模型,可以写作 $\phi(B)\Delta^d Z_k = \epsilon_k$, 其中 $\Delta^d Z_k$ 和 $\phi(B)$ 都表示短程相关过程,我们将其带入式(1)和(2)来代替 $x(n)$, 可得对下一步的预测为:

$$y(n) = W(n)^T X(n) = W(n)^T \Delta^d Z(n) \quad (5)$$

由(5)式可以看出,当自适应预测算法用于预测具有长程相关性的网络通信量 $Z(n)$ 时,其权值也可以看作是一个变量 $W(n)^T \Delta^d$, 也就是说我们可以把 $W(n)^T \Delta^d$ 作为对同时具有长程相关与短程相关的随机过程 $Z(n)$ 的估计权值,前面我们已经提到 Δ^d 为分形差分算子,所以在自相似存在的情况下会对权值 W 产生影响,权值的调整使得预测变为非线性,这一点与没有考虑长程相关时的权值是不一样的。

从而可以进一步得到其预测误差为:

$$e(n) = z(n+1) - W(n)^T \Delta^d Z(n) \quad (6)$$

我们同样使用 LMMSE 方法的快速算法来进行权值更新为:

$$W(n+1) = W(n) + 2\mu e(n)Z(n) \quad (7)$$

由于 $\Delta^d = (1-B)^d = \sum_k C_k^d (-B)^k$, 根据文[14]可知自相似通信量预测中最近的值对预测值影响最大,同时文[15]也指出在进行 FARIMA 模型拟合时一般最高阶为3,而更高的阶数对预测精度并没有大的改善,因此可以近似地将 $\sum_k C_k^d (-B)^k$ 中 k 的值设为3。同时在该式中还需要知道参数 d 的值,由于在网络通信量中一般 d 的值为0.25,因此我们可以将 d 的初始值设为0.25。由于权值的调整是一个不断调整的过程,因此随着预测权值调整的进行将自适应地调整,并逐步收敛。

我们利用这种改善了了的自适应预测算法,仍然采用前面所提到的算法步骤进行预测。

4. 自相似通信量非参数预测的仿真与分析

为了验证上面我们提出的预测方法的有效性,我们利用实际的自相似通信量进行仿真分析。文[4]中指出 VBR 视频

通信量具有自相似性,所以我们采用德国柏林大学通信网络组 MPEG-4(第二版)标准编码的“星球大战”视频序列来进行预测。

首先使用 AIC 方法估计 W 权值的阶数^[20]为12,将视频序列进行归一化处理,然后利用上一节中算法进行预测,图1和图2分别显示了使用该算法进行预测的序列与实际序列和预测误差。

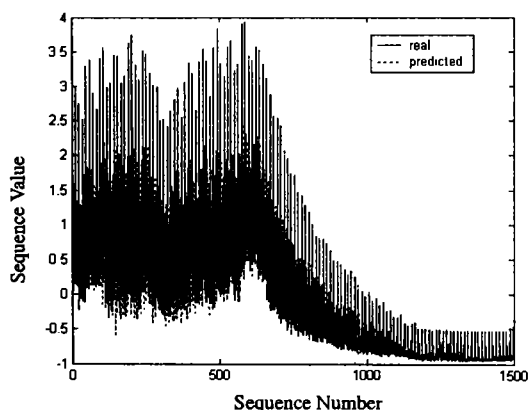


图1 实际和预测的归一化视频序列




图2 考虑自相似性值的自适应预测的预测误差

从图2我们可以看到,预测开始时误差较大,随着预测的进行权值逐渐调整到最佳值,预测误差于是逐渐减小,但是却不




图3 常规自适应预测的预测误差

为了比较考虑了网络通信量中自相似性质的自适应预测算法与一般自适应 LMMSE 预测算法的效果,我们将采用一

般自适应 LMMSE 预测算法进行预测的估计误差表示如图3所示。

从图3我们可以看到预测误差的不收敛,这主要是因为视频序列具有自相似性质,当序列比较平滑的时候,其预测效果较好。当序列中猝发比较严重时,由于常规自适应预测是线性预测,不能及时跟踪和反映这种变化,于是就出现了这种震荡。这也说明了考虑自相似性质后的预测相对来说能更好地调整预测权值,从而取得较好的效果。

结论 在网络通信量的自适应预测中,由于网络通信量中同时具有长程相关性和短程相关性,其中的长程相关性必然对于预测产生影响。然而常规的自适应预测算法对于短程相关序列具有较好的效果,但是却没有考虑长程相关性,所以在实际预测中直接利用常规自适应预测往往效果不明显。

在考虑网络通信量中同时具有长程相关和短程相关性质的基础上,我们利用 FARIMA 模型提出了一种可以应用于实际的快速自适应预测算法。与一般自适应预测算法相比较,该算法能够很好地反映通信量中的长程相关性,从而保证了预测效果。通过实际视频序列的模拟实验,证明了这种预测算法的有效性。

参考文献

- 1 Leland W E, Taqu M S, Willinger W, et al. On the Self-Similar nature of Ethernet traffic. ACM/SIGCOMM'93, San Francisco, 1993. 183~193
- 2 Leland W E, Taqu M S, Willinger W, et al. On the Self-Similar nature of Ethernet traffic (Extended version). IEEE/ACM Transactions on Networking, 1994, 1(1): 1~15
- 3 Paxson V, Floyd S. Wide area traffic: the failure of Poisson modeling. ACM Sigcomm'94, London, UK, 1994. 267~268
- 4 Garrett M W, Willinger W. Analysis, modeling and generation of self-similar VBR video traffic. ACM Sigcomm'94, London, UK, 1994. 269~280
- 5 Addie R, Zuckerman M, Neame T. Fractal traffic: measurements, modeling and performance evaluation. INFOCOM'95, 1995. 977~984
- 6 Duff E S. Fluid flow aspects of solidification modelling: simulation of low-pressure die casting. [PhD thesis]. Department of Mining and Metallurgical Engineering, University of Queensland, 1994
- 7 Erramilli A, Pruthi P, Willinger W. Recent developments in fractal traffic modeling. ITC'95 Seminar, 1995. 240~251
- 8 Crovella M E. Self-similarity in World Wide Web traffic evidence and possible causes. IEEE/ACM Transactions on Networking, 1997, 5(6): 835~846
- 9 Erramilli A, Willinger W. Fractal properties in packet traffic measurements. ITC Regional Seminar, Petersburg, 1993
- 10 Norros I. On the use of fractional Brownian motion in the theory of connectionless networks. IEEE Journal on Selected Areas in Communications, 1995, 13(6): 953~962
- 11 Erramilli A, Narayan O, Willinger W. Experimental queueing analysis with Long-Range Dependent packet traffic. IEEE/ACM Trans. On Networking, 1996, 4(2): 209~223
- 12 Tuan T, Park K. Multiple time scale congestion control for self-similar network traffic. Performance Evaluation, 1999, 36-37: 359~386
- 13 Park K, Willinger W. Self-Similar network traffic and performance evaluation. Wiley Interscience, 2000
- 14 Gripenberg G, Norros I. On the prediction of fractional Brownian motion. Journal of Applied Probability, 1996, 33: 400~410
- 15 Shu Y, Jin Z. Traffic prediction using FARIMA models. ICC'99, 1999. 22~26
- 16 Ostring S, Sirisena H. The influence of long range dependence on traffic prediction. ICC2001, 2001. 1000~1005
- 17 Ostring S, Sirisena H, Hudson I. Rate control of elastic connections competing with long-range dependent network traffic. IEEE Transactions on Communications, 2001, 49(6): 1092~1101
- 18 Park K, Tuan T. Multiple time scale TCP: harnessing proactivity in self-similar burstiness. ITC 17, 2001. 421~432
- 19 Sang A, Li S Q. A predictability analysis of network traffic. Computer Networks, 2002, 39: 329~345
- 20 Adas A M. Using adaptive linear prediction to support real-time VBR video under RCBR network service model. IEEE/ACM Transactions on Networking, 1998, 6(5): 635~644