

基于非平稳型流量队列模型的 Internet 流量测量研究

杨家海¹, 吴建平¹, C Liu²

(11 清华大学信息网络工程研究中心, 北京 100084; 21 美国贝尔实验室)

摘 要: 针对大规模细粒度网络流量测量的现实困难, 本文引入一种非平稳型流量队列模型 NIT, 直接对粗粒度的流量采样进行建模. NIT 模型是大量活跃的流量队列的迭加, 每个队列内部的流量变化过程用分形高斯噪声过程 FGN 描述, 队列的到达过程形成非同构的泊松过程, 队列的生存周期服从指数分布. 对 CERNET 主干网的实际流量测量分析验证了 NIT 模型的有效性, 证实了 NIT 模型可用于基于各种粒度的流量测量的网络行为研究.

关键词: 互联网; 网络测量; 网络流量; 网络行为; 非平稳流量队列模型 NIT

中图分类号: TP393 **文献标识码:** A **文章编号:** 0372-2112 (2004) 05-0727-04

Internet Traffic Measurement Based on Nonstationary Traffic Train Model

YANG Jiahai¹, WU Jianping¹, C LIU²

(1. Network Research Center of Tsinghua University, Beijing 100084, China;

2. Bell Labs, Lucent Technologies, Murray Hill, NJ 07974, USA)

Abstract: In order to solve the practical problem in the fine time-scale traffic measurement of large-scale networks, such as Internet, the paper introduced a nonstationary traffic train (NIT) model, which aims to directly model the coarse time-scale traffic samples. NIT model is the superposition of a large number of active traffic train segments, each of which can be described with a fractional Gaussian noise process, while train arrivals form a nonhomogeneous Poisson process and train durations are exponential. The application of NIT model in the actual measurement and analysis of CERNET backbone traffic verifies the validation and effectiveness of NIT model, which confirms that NIT model can be used in the study of network behavior based on various time-scale traffic measurements.

Key words: internet; network measurement; network traffic; network behavior; nonstationary traffic train (NIT) model

1 引言

网络测量是网络行为研究的重要途径. 测量分析是基于实际的网络环境测量网络的行为变化. 其主要方法是收集网络运行数据, 通过统计方法分析网络行为的规律, 同时还可以监视网络行为的变化, 对网络状态做出判断, 发现网络中存在的问题. 因此测量分析对网络的运行管理也具有重要意义. 网络测量通常包括以下三个要素: (1) 测量对象, 即被测量的结点或链路, 以及该结点、链路的属性, 如链路的流量、延时、带宽使用率、丢包率, 或者路由器的分组转发效率、处理时延、CPU 或内存的使用率等; (2) 测量环境, 包括测量点的选择、测量设备等; (3) 测量方法: 不同的测量对象可能需采用不同的测量方法. 网络测量的方法有两种, 即主动测量和被动测量. 主动测量是通过将探测分组注入网络进行测量, 如通过在一端发送 UDP 或 ICMP 分组, 而在另一端接收该分组, 可以测量端到端的延时、丢包率等行为. 如斯坦福线性加速器中心的 PingER (Ping end-to-end reporting)^[1] 和 IEPM (Internet end-to-end

and process monitoring)^[2], 应用网络研究国家实验室 (NLNAR) 的 AMP (Active measurement project)^[3], 美国 NSF/DARPA 资助的国家 Internet 测量基础设施 NIMI^[4] 等都采用了主动测量. 被动测量是在网络的一处或多处部署数据采集器, 被动地收集流经这些地方的网络业务流, 进行分析, 提取业务特征, 获得性能数据, 如 NLNAR 的 PMA (Passive measurement analysis)^[3] 等. 和主动测量相比, 被动测量的优点是测量本身不会给网络运行造成额外的通信开销.

网络测量要研究和解决的问题非常多, 如测量指标体系定义、网络测量的体系结构 (包括数据采集、管理和表示等), 以及各类测量对象数据建模和分析等. 而且这些问题之间是互相关联的, 比如不同的测量对象通常所采用的测量方法及相应的建模和分析手段等也各不相同; 即使相同的测量对象如果采集的时间粒度不同, 可能也要采用不同的建模工具才能较准确地进行分析. 由于 Internet 流量的动态性和高突发性, 因此基于网络流量的测量分析研究一直是网络测量领域的难点. 本文将对这方面的问题进行初步的探讨.

2 网络流量测量面临的困难

当前,基于网络流量的测量分析和网络行为研究依然面临很多困难:(1)传统的 Poisson 过程已不再适用 统计分析方法和经典的随机过程理论虽然在传统电信网络,尤其是电话网络领域得到了较成功的应用,并据此建立了一套较成熟的流量和性能分析理论,但传统电话流量理论的基础是假定通信请求的到达是互相独立的,而且到达的间隔是指数分布的,即可以用一个 Poisson 过程来描述. Internet 流量的高突发性使之不能用传统的基于 Poisson 过程的流量模型来描述;(2)数据网络流量的自相似性特征 近年来,许多学者基于细粒度的网络测量数据,对数据网络的流量特性进行了大量的研究,包括对局域网流量数据的研究^[5,6],广域网流量数据的研究^[7-9],以及 ATM 网络的变比特率(VBR)流量的研究^[10]等.通过这些研究人们终于发现 Internet 流量具有典型的自相似性特征.也就是说用于描述研究对象的长期相关性的 Hurst 参数^[11]不随网络流量聚合级别的不同(或者说不同采样粒度的网络流量时间序列)而改变. Crovella 和 Bestavros 等人^[12]对 WWW 流量特征的研究显示,从 1 秒到 3 分钟之间的不同聚合级别,其 Hurst 参数均保持不变.然而仅仅认识到 Internet 流量的自相似性是不够的.由于 Internet 变数太大,有许多无法估计的因素,使得目前对于 Internet 行为的分析和理解仍然非常困难.一方面,Internet 上不同节点间的行为特点差别很大.如果仅研究一个或某些节点,无论多么精确,所得到的结果对于其他节点而言未必适用;另一方面,Internet 在不同时间段的行为特点变化很大.简单地根据某个时间段的行为分析对未来做一般的推断是不可靠的;(3)大规模测量的现实困难 针对 Internet 的多变性和异构性,一个解决策略是通过大规模的测量来了解不同时段、不同节点和不同网络环境下的行为.但是自相似性研究所采用的网络流量采样的时间粒度是很细的,比如秒级甚至毫秒级.对于如此细粒度的流量要大规模、长时间采样,在数据管理、存储空间和通信开销等方面都存在很大的问题.

另一方面,对于粗粒度的流量采样,比如 5 分钟的采样周期,对绝大多数网络来说是可以接受的,即允许进行网络行为分析和预测所需的较大规模的和较长时间的采样.网络流量从秒级到几分钟级的自相似性特征,提示我们应该存在某些方法来利用这类粗粒度的流量测量数据进行原先依赖于细粒度流量特性的流量工程研究.为此,我们在文[13]中提出了一个全新的非平稳型流量队列模型 NTT(Nonstationary Traffic Train),该模型基于粗粒度(5 分钟采样间隔)的样本数据建模,并能据此进行原先依赖于细粒度流量建模的网络测量和网络行为研究.换句话说,NTT 模型最大限度地保留了不同时间粒度的样本数据的统计特性. NTT 模型在以下两个重要的方面对常用的分形高斯噪声过程 FGN(Fractional Gaussian Noise)^[5,12,14]进行了推广和扩充:(1)NTT 模型考虑了各类主干网链路上常见的每日流量负载模式,能够处理工作日和非工作日引起的通信模式的改变,也能够处理一段时间段内的流量变化趋势;(2)长期相关性和自相似性只通过细粒度的流

量来建模,随着这种粒度的增加,长期相关性和自相似性将逐渐衰减.

3 NTT 模型

NTT 模型将由网络流量测量数据构成的时间序列看成是大量活跃的流量队列的迭加,每个队列内部的流量变化过程用分形高斯噪声过程 FGN 描述,队列的到达过程形成非同构的泊松过程,队列的生存周期服从指数分布.

定义 1 有限时间粒度 T 的流量计数过程 $x(Tt)$ 如果可以表示为: $x(Tt) = H(Tt) + z(Tt) + y(Tt) + e(Tt)$ (1) 则称 $x(Tt)$ 服从 NTT 模型. 其中 $H(Tt)$ 是均值确定的曲线,实际上是反映了每日流量的 驼峰曲线模式 0:

$$H(Tt) = A \int_0^T K(u) du + (Tt + u) du \quad (2)$$

其中 $K(\#)$ 对非负的密度函数 $K(\#)$ 满足等式(7),而 $\{z(Tt)\}$, $\{y(Tt)\}$ 和 $\{e(Tt)\}$ 是均值为 0 的独立的高斯过程. 其中 $z(Tt)$ 表示流量队列到达(离开)的变化过程,而 $y(Tt)$ 则表示每个队列内部流量的变化过程.

为了推导出 NTT 模型,不妨将 x_{st} 看成是大量独立且具有相同分布特性的流量队列的计数(设时刻 t 的数量为 $m(t) = m$),每个流量队列本身是一个 FGN 过程,所有 FGN 过程拥有相同的参数 A , R^2 和 H . 如果对于时间粒度为 S 的网络流量,假设其采样点的时间为 $t = 0, 1, 2, 3, \dots$, 其 FGN 模型可以表示为:

$$x_{st} = AS + S^H R G_H(t) \quad (3)$$

其中 x_{st} 表示在时间间隔 $(S(t), S(t+1))$ 内的累计流量, $G_H(t)$ 表示平稳高斯过程,其均值为 0,那么,NTT 模型可以表示为:

$$x_{st} | \{m_{st} = m\} = AmS + S^H \sum_{i=1}^m R G_H^{(i)}(t) \quad (4)$$

这里我们将 A 解释为单位时间(即采样间隔)内每个队列的流量速率, H 是自相似性参数,也称为 Hurst 参数.

由于流量队列的计数过程 $m(S_t)$ 本身也是一个随机过程,可首先在在时间 $(0, S_t)$ 内到达的流量队列累计数构造一个隐含的泊松过程 $n(S_t)$,并令流量队列到达率(密度函数)为 $K(S_t)$ ($K(S_t) \geq 0$). 令队列的生存时间(周期)是均值为 L 的独立指数分布,再令 $A(S_t)$ 表示在时刻 S_t 时处于活跃的队列集合,那么 $m(S_t) = |A(S_t)| = \{n(S_t) - (0, S_t)$ 时间内消失的队列数}. 命题 1 描述了 $m(S_t)$ 的分布.

命题 1 假设 $m(0) \sim \text{Poisson}\{+(0)\}$, 即 $m(0)$ 服从给定初始均值为 $+(0)$ 的泊松分布,则: $m(S_t) \sim \text{Poisson}\{+(S_t)\}$, 而且自协方差函数满足:

$$\text{cov}\{m(S_s), m(S_t)\} = +(S_{\min\{s, t\}}) \exp\left\{-\frac{|S_t - S_s|}{L}\right\} \quad (5)$$

其中 $E\{m(S_t)\} = +(S_t)$, 对于任何 $S > 0$, 都有下列递推关系:

$$\begin{aligned} +(S_t + S) &= +(S_t) \exp\left\{-\frac{S}{L}\right\} + \exp\left\{-\frac{S}{L}\right\} \\ &\quad \# \int_0^S K(S_t + u) \exp\left\{-\frac{u}{L}\right\} du \quad (6) \end{aligned}$$

或等价地表示为: $+(S_t + S) / L = K(S_t)$ (7)

根据前面的定义和命题 1, 经过适当的推导, 可得到当时

间粒度 S 为无限小时的流量队列模型:

$$x_{St}^d = AS + (St) + AS^{1/2} (St) z(St) + R_S S^{1/2} (St) y(St) + RS^{1/2+1/2} (St) e(St), \quad (8)$$

其中 $\{z(t)\}$, $\{y(t)\}$ 和 $\{e(t)\}$ 是均值为 0 的、独立的高斯过程。 $\{e(t)\}$ 是白色噪声, 之所以包括进来是为了使该模型能够处理更多可能的意外变化, 比如由于测量本身引入的误差等。当 S 为有限值时, 经过极值求解过程, 也将得到公式 (8) 所表示的流量队列模型。详细的推导过程可以参阅文献 [13]。

4 对 CERNET 主干网流量的测量分析

利用上述模型, 我们从 CERNET 国家网络中心对 CERNET 主干网的部分链路流量进行了分析研究。

4.1 测量环境

基本测量环境如图 1 所示, 我们通过基于 SNMP 的简单数据采集工具对经过 CERNET 主干网的几个关键路由器的主要接口的分组计数 (locfInPktsSec 和 locfOutPktsSec) 进行了一段时间的 5 分钟间隔的采样, 这些路由器涉及国际出口路由器 Ra2; 和国内其它网络互联的路由器 Rx1, Rx2; 主干网路由器 Rb, 以及连接网络中心内部网络的路由器 Ri 等, 涉及的接口类型有 100Mbps 的快速以太网接口、高速串行口以及 155Mbps 的 POS 接口等。




图 1 CERNET 主干网测量环境

4.1.2 初步分析结果

图 2 给出了一个 100Mbps 快速以太网接口七天的流量曲线 (locfInPktsSec), 测量的时间粒度是 5 分钟, 其中, 粗线表示的是 NIT 模型的每日模式 $H(Tt)$ 。我们也对其它接口的一周 (7 天) 的分组计数流量数据进行了分析和统计, 发现这些数据具有明显的每日模式: 每天从上午 7 点半以后, 流量级别开始快速上升, 大约到上午 10 点半到 11 点左右达到第一个峰值, 然后流量级别开始回落, 第二个波峰出现在下午 3 点到 6 点之间, 在晚上 7 点半左右到 10 点之间还有一个波峰, 晚上 10 点以后流量逐渐回落直到次日凌晨 6 点左右到达谷底, 然后又开始一个新的周期, 波峰的均值速率几乎是凌晨 6 点左右时的最低速率的 8 倍, 在早上 8 点左右其负载的增长速率超过了每小时 90%。很显然, 在为这种网络流量建模的时候, 我们必须考虑到这种明显的“每日模式”。从所得的曲线图中我们也发现: 和早上流量级别的迅速上升相比, 夜间流量级别的下降则是一个比较渐进的过程。此外, 我们也发现, 随着时间的推移, 这些数据在向着均值的一个方向移动, 这就是在许多网络流量中都已经观察到的长期相关性。

将 NIT 模型应用于所测量的网络流量数据, 我们得到 A

约为 0.006, A 的估计值很小, 这意味着所选用的样本数据事实上是由大量的分组队列 (如: Mean rate/ A) 所构成的, 也就是说同时存在很多数据流 (flows), 这和 CERNET 作为国内第二大互联网运营商的实际情况是相符合的。与此同时, 由于 z ($\#$) 是和 A 成正比的, A 的值小也意味着由于流量队列到达/离开过程而引起的分组计数的变化相对较小。 H 的值约为 0.9, 远大于 0.5, 这说明 5 分钟采样粒度的网络流量依然具有很强的自相似特性。另外, R_e 的值非常小 (< 0.001) 这说明 NIT 模型中的噪声过程 $e(t)$ 是可以忽略的。

5 NIT 模型的进一步应用

NIT 模型在主干网流量测量建模和网络行为预测等方面有广泛的应用前景, 上一节我们已经对 CERNET 主干网的流量进行了定性的分析, 这一节我们首先通过对实际数据和模拟数据的定量对比进一步论述 NIT 模型的建模能力和建模的精确性, 再定性地讨论一下 NIT 模型在网络行为研究方面的可能应用。

5.1 主干网聚合流量的建模和解释

我们通过 NIT 模型生成了一系列模拟流量数据, 并和 CERNET 主干网中采集的实际数据进行对比分析。图 3 给出了时间粒度为 $T=300$ 秒时的实际流量和由 NIT 模型产生的模拟数据曲线。图 3(a) 是根据 CERNET 采集的一个路由器端口 (单向) 的 6 个工作日的流量画的; 图 3(b) 是根据 NIT 模型产生的 8 天模拟数据画的。灰色的平滑曲线是估计的“每日模式”。很显然, 模拟的流量曲线和实际曲线有许多相同的特性: 二者都有明显的每日模式, 离中趋势等。当然也存在某些方面的不同, 比如通常在实际数据曲线中往往见得比较多的突发性, 在模拟数据曲线中, 却相对较少。




图 2 每日流量模式: 7 个工作日的数据和估计曲线

(注: 为表示方便, 我们选用流量的平方根为纵坐标)

此外, 我们也比较了 $T=10$ 秒时的实际流量和模拟流量的特性。需要强调的是: 这里 10 秒钟的模拟数据是通过用 300 秒的样本数据训练得到的 NIT 模型产生的, 我们发现 10 秒钟的模拟数据的确和 10 秒钟的实际数据具有相同的趋势 (每日模式, 离中趋势), 尽管在整个学习的过程中并未涉及 10 秒钟的样本数据, 但 NIT 模型已经很好地推断出它们的特征。限于篇幅, 这里未给出相应的曲线图。

5.1.2 网络行为预测

NIT 模型基于粗粒度样本数据建模, 但能保持细粒度流量的统计特性, 因此 NIT 模型在网络行为研究和预测方面有很现实的应用前景。一方面, 通过 NIT 模型, 实施基于大规模




图 3 300 秒时间粒度的实际数据和模拟数据曲线

测量的网络行为分析和预测变得可行, 因为我们不再需要为了行为研究的目的, 专门再对网络实施大规模的测量, 许多已经为了其它管理目的而采集的粗粒度的数据可以重复利用起来, 这无论是对于网络管理研究人员还是网络管理运行部门都是非常重要的。另一方面, 通过模型的学习和训练, 我们有可能建立起网络行为的/正常0模式和/异常0模式, 并基于这些模式对运行的网络进行实时监视, 并对可能出现的性能恶化或者潜在故障提前进行报警, 将可能实现真正意义上的主动式网络管理。

6 结束语

网络测量分析是网络行为研究的重要途径之一, 网络测量的对象包括从不同侧面反映网络行为特性的各种属性, 如丢包率、网络延迟、网络流量等。由于 Internet 流量的动态性和高突发性, 其流量过程建模异常困难, 而且对于大规模复杂网络, 要实施大规模细粒度测量也非常困难, 因此基于网络流量的测量分析研究进展缓慢。本文对我们提出的非平稳型流量队列(NIT)模型用于实际网络的流量测量研究进行了初步的探讨。流量测量只是网络测量的一个方面, 流量行为也只是网络行为研究的一个方面, 将流量测量及行为研究与其它网络行为的研究(如路由行为、延迟行为、丢包行为等)结合起来, 将有望更全面地把握网络运行的行为, 这也是我们进一步研究的方向。

参考文献:

- [1] Matthews W, Cottrell L. PingER project: Active internet performance monitoring for the HENP community [J]. IEEE Communications Magaz

zine, 2000, 38(5): 130- 136.

- [2] IEPM. Internet End-to-end Performance Monitoring [EB/OL]. <http://www2iepm.slac.stanford.edu/>, 2003- 03.
- [3] McGregor T, Braun H W, Brown J. The NLANR network analysis infrastructure [J]. IEEE Communications Magazine, 2000, 38(5): 122- 128.
- [4] Adams A, Mahdavi J, Mathis M, et al. Creating a scalable architecture for internet measurement [A]. Proc. of INET. 98 [EB/OL]. <http://www.isoc.org/inet98/proceedings/>, 1998- 07.
- [5] Leland W E, Taqqu M S, Willinger W, et al. On the self-similar nature of ethernet traffic [J]. IEEE/ACM Transactions on Networking, 1994, 2(1): 1- 15.
- [6] Norros I. On the use of fractional brownian motion in the theory of correlated networks [J]. IEEE J. on Selected Areas in Communications, 1995, 13(6): 953- 962.
- [7] Paxson V, Floyd S. Widearea traffic: The failure of poisson modeling [J]. IEEE/ACM Transactions on Networking, 1995, 3(3): 226- 244.
- [8] Lucas MT, Wrege D E, Dempsey B J, et al. Statistical characterization of widearea IP traffic [A]. Maki K, Ni L M, Singhal M, et al. Proc. of 6th Int. l Conference on Computer Communications and Networks [C]. CA: IEEE Computer Society Press, 1997. 442- 447.
- [9] Feldmann A, Gilbert A C, Willinger W. Data networks as cascades: Investigating the multifractal nature of internet WAN traffic [A]. Proc. ACM SIGCOMM [C]. Newyork: ACM press, 1998. 42- 55.
- [10] Beran J, Sherman R, Taqqu M S, et al. Long range dependence in variable bit rate video traffic [J]. IEEE Trans. on Communications, 1995, 43(234): 1566- 1579.
- [11] Mandelbrot B B, Ness J W. Fractional brownian motions, fractional noises and applications [J]. SIAM Review, 1968, 10(4): 422- 437.
- [12] Crovella M E, Bestavros A. Self-similarity in world wide web traffic: Evidence and possible causes [J]. IEEE/ACM Transactions on Networking, 1997, 5(6): 835- 846.
- [13] Liu C, Wiel S V, Yang J. A nonstationary traffic train model for fine scale inference from coarse scale counts [J]. IEEE J. on Selected Areas in Communications, 2003, 21(6): 895- 907.
- [14] Willinger W, Taqqu M S, Sherman R, et al. Self-similarity through high variability: statistical analysis of ethernet LAN traffic at source level [J]. IEEE/ACM Transactions on Networking, 1997, 5(1): 71- 86.

作者简介:



杨家海 男, 1966 年 9 月出生于浙江云和, 副教授, 博士, 主要研究方向为计算机网络、网络管理和测量、协议工程学等领域。

吴建平 男, 1953 年 10 月出生于山西太原, 教授, 博导, 主要研究方向为计算机网络体系结构、网络管理、协议一致性测试和协议工程学等领域。