

DOI:10.3969/j.issn.1673-4785.201111008

网络出版地址:<http://www.cnki.net/kcms/detail/23.1538.TP.20120309.1559.005.html>

双层隐马尔可夫链的突发流合成

谢逸¹, 唐成华², 黄向农³

(1. 中山大学信息科学与技术学院, 广东广州 510006; 2. 桂林电子科技大学, 计算机科学与工程学院, 广西桂林 541004; 3. 中山大学网络与信息技术中心, 广东广州 510275)

摘要: 网络流模型被广泛用于构建网络与网络服务的测试环境, 其准确性直接影响各种业务的性能评估结果及在实际网络环境中的鲁棒性。随着电子商务及新型网络应用的普及, 突发流现象已经成为现代互联网的主要特征之一。针对平稳网络流而设计的传统网络流模型已经难以有效地描述现代网络中突发流的时间结构性及统计属性, 从而不能准确反映现代网络流的行为特征。为此, 提出一种新的结构化双层隐马尔可夫模型用于模拟实际网络环境下的突发流, 并设计了有效的模型参数推断算法及突发流合成方法。该模型通过结构化的2层隐马尔可夫过程描述突发流并实现仿真合成, 使合成流可以重现实际突发流的时间结构性、统计特性及自相似性。实验表明, 该模型可以有效合成突发流。

关键词: 隐马尔可夫模型; 合成; 突发流; 网络

中图分类号: TP30 文献标志码: A 文章编号: 1673-4785(2012)02-0108-07

A doubly hidden Markov model for synthesizing bursty workloads

XIE Yi¹, TANG Chenghua², HUANG Xiangnong³

(1. School of Information Science and Technology, Sun Yat-Sen University, Guangzhou 510006, China; 2. School of Computer Science and Engineering, Guilin University of Electronic Technology, Guilin 541004, China; 3. Network and Information Technology Center, Sun Yat-Sen University, Guangzhou 510275, China)

Abstract: Network traffic models have been widely used to build the test environment for networks and network services. Their accuracy directly impacts the performance evaluation results of various services and their robustness in the actual network environment. With the popularity of e-commerce and new network applications, the burst traffic phenomenon has become one of the main features of the modern internet. Traditional traffic models designed for stationary network traffic have difficulty in effectively describing the temporal structure and statistical properties of burst traffic of modern networks, which causes them not to be able to accurately reflect the actual network environment. In this paper, a new structural doubly hidden Markov model was proposed to characterize the practical burst traffic in a real network environment. Efficient algorithms for inference of model parameters and synthesis of the burst workload were also introduced. Based on the hierarchical structure, the proposed model can reproduce the similar temporal structure, statistical properties, and self-similarity of the real burst traffic. The proposed model includes two hidden Markov processes. The parent Markov state process was used to describe the large-scale trends or phases of burst traffic. The child Markov process was used to describe the small-scale fluctuations that happen during a given phase of the arrival process. Experiments were implemented to validate the proposed model.

Keywords: hidden Markov model; synthesize; burst workload; network

网络流模型一直是互联网研究中的一个重要

领域。一个有效的流模型是实现性能测试、容量规划及攻击防御的基础。没有正确的网络流模型, 将难以准确预测网络性能指标的变化, 从而无法使网络及其业务实现自适应调整。因此, 网络流模型对互联网及各种业务的研究与设计都具有重要的意义。

收稿日期: 2011-11-14. 网络出版日期: 2012-03-09.

基金项目: 国家自然科学基金资助项目(60970146); 教育部博士点专项基金资助项目(20090171120001); 中央高校基本科研业务费专项资金资助项目(11lgpy38).

通信作者: 谢逸. E-mail: xieyi5@mail.sysu.edu.cn.

建立有效网络流模型的前提是了解网络流的属性特征。已有的研究^[1-2]已经指出,大部分网络流具有自相似性、长相关性及突发性。其中,突发流是指数据传输中的非平衡模式,即网络流在某些时候呈现出非常高的数据传输率,而在另外一些时间则非常低。例如现代商务网站常常组织“抢购”或“秒杀”活动作为其销售策略。在这些活动期间,网络流量会因为用户数的激增而出现暴发性增长,从而导致突发流的出现。实际网络中的突发流不具有规律性,例如出现时间、持续时间、突发强度等。突发流的形成受多种随机因素影响,例如热点新闻的发布、金融市场的运作、大型活动的现场播放等都会引起突发流。如果网络基础设施或网络服务在设计阶段没有考虑到这种突发性现象,将有可能导致它们无法有效应对实际网络场景中的突发流。在过去的20年中,很多模型被用于描述突发网络流。已有的研究工作主要从两方面刻画突发流:结构方法与随机过程方法。早期网络流的研究^[1,3]主要考虑结构属性,例如自相似性与长相关性。在这之后,大量的数学方法被用于描述网络流的自相似性与长相关性,例如经典的On/Off模型^[4]、M/G/ ∞ 模型^[1]、小波模型^[5]、分形布朗运动模型^[6]等。结构化方法主要存在两方面的问题:1)它们无法描述时间域信息(例如时间结构性),因此这类模型无法正确重构实际突发流的时间特性;2)几乎所有描述自相似性的模型都仅通过一个共同的参数Hurst来描述网络流的突发性。而实际的网络流往往具有宽尺度的变化范围,使用单一参数的结构化方法不足以刻画复杂的、多尺度的突发流^[7]。例如,理论上的尺度范围存在于 $(0, \infty)$ 中。然而,实际表现出来的多尺度性往往只有有限的范围,而且无法精确表示。另外,现有的自相似模型往往假设所有的矩序(moment order)的尺度指数都相同,而实际的网络流中,不同阶的尺度指数由不同的参数所控制。因此,单一的Hurst参数实际上无法精确描述多尺度的自相似性。

典型的随机过程方法主要基于马尔可夫族模型。在文献[4]中,基于马尔可夫模型的“On/Off”模型用于模拟语音信号。在文献[8]中,采用树结构隐马尔可夫链到达模型(Markovian arrival process, MAP)被用于描述网络流。文献[9]使用马尔可夫调制泊松过程(Markov modulated Poisson process, MMPP)描述网络流的突发性。文献[10]使用马尔可夫调制流源模型(Markov-modulated fluid sources, MMFS)描述网络流。文献[11]使用自回归马尔可夫模型(autoregressive Markov model, ARMM)描述网

络流。这些方法主要有三方面的问题:1)已有的随机过程流模型采用平板结构,因此难以描述具有不规则、宽变化特性的突发流;2)由于模型参数在估计阶段受整个流过程的影响,它们难以刻画“突发”或“非突发”阶段的局部细节的变化过程;3)这类模型难以重构突发流的时间结构性特征,例如相邻2个突发过程的时间间隔、突发过程的持续时间等。因此,当实际网络流的突发性非常显著时,或网络量的波动范围变得非常大时,这一类模型的性能将逐渐下降,从而导致仿真流不具有实际突发流的各种特性。增加模型的参数,例如增加量化间隔,或增加Markov模型的状态数,可以在一定程度上提高模型描述细节过程的能力,但会导致两方面的问题:1)参数的增加必然导致模型的计算复杂度增加,特别是参数个数与复杂度具有非线性关系的模型;2)对某些模型,参数的增加不但不会提高性能,还可能导致“过描述”^[12]问题的出现。

为此,提出一种新的方法用于合成突发网络流,该方法基于多层隐马尔可夫模型(hierarchical hidden Markov model, HHMM)。HHMM^[13]已经成功应用于不同的领域,例如文本识别、策略识别、活动识别、视频分析、图像分类和信息抽取等。与经典的隐马尔可夫模型(hidden Markov model, HMM)^[14]相比,这些HHMM模型最主要的特点是,通过增加一个隐马尔可夫链描述慢变化的高层活动,从而捕获自然序列的长期相关性。这一特征使HHMM适合描述非平稳的突发网络流。然而从目前收集到的文献看,HHMM的这一优点还没有被应用到网络流建模上。本文的主要创新点包括:1)通过改进模型的结构,而不是通过增加模型参数来提高突发流的模拟性能。2)首次采用基于HHMM的结构化隐马尔可夫模型实现突发流建模。基于该模型的合成流可以有效重现实际突发流的时间结构特性、统计特性及自相似性。3)有效的模型参数推断算法与突发流合成算法,使该模型的结构优于传统平板型结构的模型,但计算复杂度没有显著增加。

1 建模依据与算法

1.1 模型定义

假设所观测到的时间过程是到达率过程(arrival rate process, ARP)。如图1所示,从大尺度看,可以根据到达率的量级把ARP划分为不同的流量阶段(traffic phase, TP),例如低流量阶段、过渡阶段和高流量阶段。因此,ARP大尺度变化过程实际上是由不同的流量阶段交替变化所组成,即ARP的粗轮廓可以通

过流量阶段过程(traffic phase process, TPP)来描述。而 TPP 本身也是一个时间过程。与一般基于 Markov 模型的时间序列建模类似,假设流量阶段过程 TPP 满足马尔可夫假设的无后效性。因此 TPP 可以用一个马尔可夫链来描述。该马尔可夫链称为父马尔可夫过程,包含 $|Q^p|$ 个状态,每一个状态对应一种典型的流量阶段 TP。在给定的流量阶段 i 内(或父状态 i 下),局部的小尺度网络流波动由另一个嵌套的子马尔可夫链描述。该嵌套的子马尔可夫链包含 $|Q_i^c|$ 个有效状态及一个吸收态 Θ_i^c ,每一个子状态对应一种典型的局部流量分布。因此,双重马尔可夫模型可以描述网络流的大尺度及小尺度变化过程。

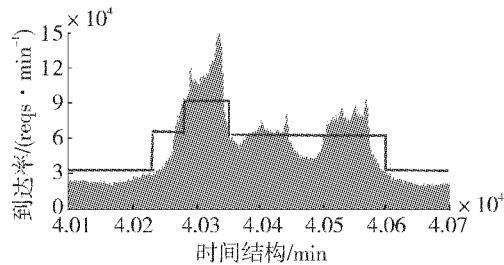


图 1 大尺度网络流量阶段

Fig. 1 Large-scale typical phase of arrival rate process

该模型的随机性及状态的隐藏性在于:1) 流量阶段 TP 无法被准确测量,例如流量阶段的开始时间、持续时间等;2) 在给定的流量阶段内,小尺度的局部波动仍然具有随机性;3) 一个观测到的到达率(或 ARP 片段)有可能来自于不同的流量阶段、或来自于同一个父状态下不同的子状态。因此,在这个双层马尔可夫模型中,父马尔可夫链和子马尔可夫链都具有不确定性与隐藏性,它们无法被精确测量,只能通过可观测的 ARP 进行估计。可见双层马尔可夫模型可以看成一个简化的 HHMM:1) 父状态链不可观测,但控制子状态过程;2) 子状态过程不可观测,但控制模型的输出过程。模型的参数(即父/子状态过程的初始概率、状态转移概率及子状态的输出概率)代表网络流的内部形成机制。为了使用 HHMM 构建上述双层隐马尔可夫模型,做了以下假设:

- 1) 父状态的跳转将使当前子状态过程结束,并触发一个新的子状态过程开始;
- 2) 每个子状态集中的吸收态不输出观测值,但吸收态出现时,当前子状态过程将结束并返回父状态过程;
- 3) 模型的输出仅由子状态链控制,且相同子状态下的输出相互独立;
- 4) 不同父状态下的子状态集合可以具有不同的子状态数。

表 1 列出了本文所使用的一些符号及定义。为了便于介绍下文的算法,使用 i, j 表示 Q^p 中的元素,即父状态集合中的马尔可夫状态;用 m, n 表示 Q_i^c 中的元素,其中 $i \in Q^p$, q_t^p 与 q_t^c 分别表示父状态过程与子状态过程在 t 时刻的状态。于是可以使用图 2 所示的双层隐马尔可夫状态图来表示突发流的到达过程。

表 1 模型符号定义

Table 1 Notation of symbols

符号	定义
O	$O = \{o_1, o_2, \dots, o_T\}$, 长度为 T 的到达率序列。
o_t	t 时刻的到达率。
$x_{a:b}$	$x_{a:b} = \{x_a, x_{a+1}, \dots, x_b\}$, 时间跨度为 a 到 b 的时间序列。
Q^p	$Q^p = \{1, 2, \dots, Q^p \}$, 父马尔可夫状态集合。
Q_i^c	$Q_i^c = \{1, 2, \dots, Q_i^c , \Theta_i^c\}$, 父马尔可夫状态 i 的子马尔可夫状态集合, 其中 Θ_i^c 表示吸收态。
π_i^p	$\pi_i^p = P[q_i^p = i]$, 父马尔可夫链初始状态概率。
a_{ij}^p	$a_{ij}^p = P[q_t^p = j q_{t-1}^p = i]$, 父马尔可夫链状态转移概率。
π_m^{cli}	$\pi_m^{cli} = P[q_t^c = m q_i^p = i, q_{t-1}^p \neq i]$, 父马尔可夫状态 i 下, 子状态链的初始概率。
a_{mm}^{cli}	$a_{mm}^{cli} = P[q_t^c = m q_{t-1}^c = m, q_{t-1:t}^p = i]$, 父马尔可夫状态 i 下, 子状态链的转移概率。
b_{mk}^{cli}	$b_{mk}^{cli} = P[O_t = k q_i^c = m, q_t^p = i]$, 父马尔可夫状态 i 下, 子状态链的输出概率。
λ	$\lambda = \{\pi_i^p, a_{ij}^p, \pi_m^{cli}, a_{mm}^{cli}, b_{mk}^{cli}\}$, 模型的参数集合。

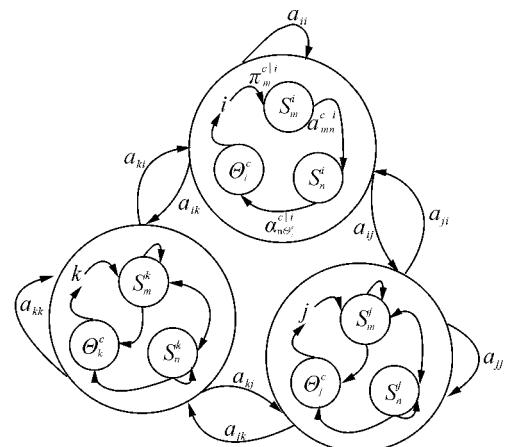


图 2 突发网络流的状态

Fig. 2 A state diagram for describing the burst traffic

父马尔可夫过程最初以概率 π_i^p 进入状态 i 。状

态 i 以概率 $\pi_i^{cl_i}$ 生成其子状态 m . 然后, 在父状态 i 下的子状态根据概率 $b_{mo_i}^{cl_i}$ 输出当前的到达率 o_t , 完成输出以后, 子状态 m 按照转移概率分布 $a_{mn}^{cl_i}$ 跳转到下一个子状态 n , 然后重复模型的输出与子状态的跳转. 当子状态过程出现吸收状态 Θ_i^c 时, 模型将停止当前的子状态过程并返回父马尔可夫状态 i , 由父状态过程的状态转移概率 a_{ij}^p 决定下一个父状态的取值. 通过这种方式, 网络流可以被分割为连续的流量阶段过程并由父马尔可夫状态过程描述, 每一个阶段(父状态)代表不同的流量等级. 而每一个特定流量阶段中的小尺度网络流波动则由相应的子状态过程的转移概率及输出概率来刻画. 因此, 双层隐马尔可夫链非常适合描述网络流, 特别是非平稳的突发流过程.

1.2 模型参数推断及突发流合成

与经典的 HMM 类似, 双层隐马尔可夫模型主要用于解决以下 3 类问题: 1) 给定一个模型 λ , 计算观测序列相对于该模型的概率; 2) 给定一个模型 λ 及观测序列 $o_{1:T}$, 估计最可能的双层隐马尔可夫状态序列; 3) 通过观测序列 $o_{1:T}$ 估计模型的参数, 即调整模型的参数使 1) 和 2) 的概率最大. 针对所提出的双层隐马尔可夫模型, 介绍一种前后向算法解决上述 3 个问题.

基于提出的第 3 个假设条件, 即模型的输出仅由子状态链控制, 且相同子状态下的输出相互独立, 有

$$P[o_{a:b} \mid q_t^c = m, q_t^p = i] = \prod_{t=a}^b P[o_t \mid q_t^c = m, q_t^p = i].$$

定义模型的前向变量:

$$\alpha_t(i, m) = P[o_{1:t}, q_t^p = i, q_t^c = m].$$

考虑 $t-1$ 时刻, 模型的父状态只能是 $q_{t-1}^p = i$ 或 $q_{t-1}^p \neq i$, 可以得到前向变量的递推过程:

$$\begin{aligned} \alpha_t(i, m) &= \sum_n a_{t-1}(i, n) a_{ii}^p a_{nm}^{cl_i} b_{mo_i}^{cl_i} + \\ &\quad \sum_{j \neq i, n} a_{t-1}(j, n) a_{ji}^p \pi_m^{cl_i} b_{mo_i}^{cl_i}. \end{aligned}$$

对于给定的状态 (i, m) 及时间 $t > 1$, 前向变量的初始值为

$$\alpha_1(i, m) = \pi_i^p \pi_m^{cl_i} b_{mo_1}^{cl_i}.$$

定义后向变量:

$$\beta_t(i, m) = P[o_{t+1:T} \mid q_t^p = i, q_t^c = m].$$

考虑 $t+1$ 时刻, 模型的父状态只能是 $q_{t+1}^p = i$ 或 $q_{t+1}^p \neq i$, 可以得到后向变量的递推过程:

$$\begin{aligned} \beta_t(i, m) &= \sum_n a_{ii}^p a_{mn}^{cl_i} b_{no_{t+1}}^{cl_i} \beta_{t+1}(i, n) + \\ &\quad \sum_{j \neq i, n} a_{ij}^p a_{mn}^{cl_j} b_{no_{t+1}}^{cl_j} \beta_{t+1}(j, n). \end{aligned}$$

对于给定的状态 (i, m) 及时间 $t < T$, 后向变量

的初始值为

$$\beta_T(i, m) = 1.$$

为了推断双层隐马尔可夫模型的参数, 定义一个辅助的联合概率密度函数 $\zeta_t(i, j, m, n)$ 并给出其递推公式:

$$\begin{aligned} \zeta_t(i, j, m, n) &= P[o_{1:T}, (q_t^p, q_t^c) = (i, m), (q_{t+1}^p, q_{t+1}^c) = (j, n)] = \\ &= \begin{cases} \alpha_t(i, m) a_{ij}^p \pi_n^{cl_j} b_{no_{t+1}}^{cl_j} \beta_{t+1}(j, n), & i \neq j; \\ \alpha_t(i, m) a_{ii}^p a_{mn}^{cl_i} b_{no_{t+1}}^{cl_i} \beta_{t+1}(i, n), & i = j. \end{cases} \end{aligned}$$

定义辅助联合概率密度函数 $\gamma_t(i, m)$ 及其递推公式为

$$\begin{aligned} \gamma_t(i, m) &= P[o_{1:T}, q_t^p = i, q_t^c = m \mid \lambda] = \\ &\quad \sum_{j, n} \zeta_t(i, j, m, n). \end{aligned}$$

基于上述的递推过程, 可以估计出模型的各个参数:

1) 父状态过程初始概率密度函数 π_i^p 的最大或然概率估计为

$$\hat{\pi}_i^p = \sum_{j, m, n} \zeta_t(i, j, m, n) / N_\pi^p.$$

式中: $N_\pi^p = \sum_{i, j, m, n} \zeta_t(i, j, m, n)$ 是归一化因子.

2) 父过程状态转移概率密度函数 a_{ij}^p 的最大或然概率估计为

$$\hat{a}_{ij}^p = \sum_{t=1}^{T-1} \sum_{m, n} \zeta_t(i, j, m, n) / N_a^p(i).$$

式中: $N_a^p(i) = \sum_{t=1}^{T-1} \sum_{j, m, n} \zeta_t(i, j, m, n)$ 是归一化因子.

3) 父状态 i 下的子状态过程的初始概率密度函数 $\pi_m^{cl_i}$ 的最大或然概率估计为

$$\hat{\pi}_m^{cl_i} = \sum_{t=1}^{T-1} \sum_{j \neq i, n} \zeta_t(j, i, n, m) / N_\pi^{cl_i}.$$

式中: $N_\pi^{cl_i} = \sum_{t=1}^{T-1} \sum_{j \neq i, m, n} \zeta_t(j, i, n, m)$ 是归一化因子.

4) 父状态 i 下的子状态过程的状态转移概率密度函数 $a_{mn}^{cl_i}$ 的最大或然概率估计为

$$\hat{a}_{mn}^{cl_i} = \sum_{t=1}^{T-1} \zeta_t(i, i, m, n) / N_a^{cl_i}(m).$$

式中: $N_a^{cl_i}(m) = \sum_{t=1}^{T-1} \sum_n \zeta_t(i, i, m, n)$ 是归一化因子.

5) 父状态 i 下的子状态过程的输出概率密度函数的最大或然概率估计为

$$\hat{b}_{mk}^{cl_i} = \sum_{t=1}^{T-1} \sum_{j, n} \zeta_t(i, j, m, n) \delta(o_t = v_k) / N_b^{cl_i}(m).$$

式中: $N_b^{cl_i}(m) = \sum_{t=1}^{T-1} \sum_{j, n} \zeta_t(i, j, m, n)$ 是归一化因子.

6) 双重隐状态链 (q_t^p, q_t^c) 的后验估计为

$$\begin{aligned} (\hat{q}_t^p, \hat{q}_t^c) &\equiv \arg \max_{i, m} P[o_{1:T}, q_t^p = i, q_t^c = m \mid \lambda] = \\ &\quad \arg \max_{i, m} \gamma_t(i, m). \end{aligned}$$

7) 观测序列 $o_{1:T}$ 相对于给定模型 λ 的或然概率为

$$L \equiv P[o_{1:T} \mid \lambda] = \sum_{i, m} P[o_{1:T}, q_T^p = i, q_T^c = m \mid \lambda] =$$

$$\sum_{i,m} \alpha_t(i, m).$$

从递推公式及参数估计方法可以看到,在本算法中,模型参数的估计可以和后向过程结合在一起。因此,所定义的辅助联合概率密度函数 $\zeta_t(i, j, m, n)$ 及 $\gamma_t(i, m)$ 和后向变量都不需要存储。

对于给定的网络流模型 λ , 突发流的合成可以由算法 1 得到。

算法 1 突发流合成及隐状态过程推断。

输入:

双重隐马尔可夫模型参数。

输出:

到达率过程:

$$\hat{\theta} = \{\hat{o}_1, \hat{o}_2, \dots, \hat{o}_T\};$$

双重隐状态过程: $(\hat{q}_t^p, \hat{q}_t^c), t = 1, 2, \dots, T$.

- 1) 由 $\pi_i^p, i \in Q^p$ 获取父过程初始状态 \hat{u} .
- 2) 初始子状态: $\hat{v} = \emptyset$.
- 3) for $t = 1$ to T do
- 4) if $\hat{v} = \emptyset$ then
- 5) 由 $\pi_m^{e|\hat{u}}, m \in Q_u^c$ 得到子状态 \hat{v} .
- 6) else if $\hat{v} = \theta_u^c$ then
- 7) 由 $a_{ui}^p, i \in Q^p$ 得到下一个父状态 \hat{u} .
- 8) 设置新的初始子状态 $\hat{v} = \emptyset$.
- 9) goto 4).
- 10) endif.
- 11) 由 $b_{\hat{u}t}^{e|\hat{u}}$ 得到当前时刻的输出值 \hat{o}_t .
- 12) $\hat{q}_t^p = \hat{u}, \hat{q}_t^c = \hat{v}$.
- 13) 由 $a_{im}^{e|\hat{u}}, m \in Q_u^c$ 确定下一个子状态 \hat{v} .
- 14) endfor.

2 实验结果及分析

实验所使用的模型结构可以通过经验方法来确定: $|Q^p| = 3, |Q_i^c| = 3, i \in Q^p$. 其中 3 个父状态分别表示 3 种大尺度流量阶段: 流量谷、过渡、流量峰。各子状态集分别表示不同流量阶段下的到达率分布。根据实验比较看, 这种模型结构对所使用的数据集是有效的。当状态数过少时, 模型无法准确描述某些状态, 如果增加状态数, 则会导致计算量加大, 而且对 HMM 簇模型来说, 增加状态数不意味着模型性能的提升, 相反可能会导致出现“过描述”^[12] 现象。

首先使用所采集的突发流训练模型参数, 然后利用训练得到的模型合成突发流。在实验中, 比较了本文所提出的双层隐马尔可夫模型与经典平板型隐马尔可夫模型的性能。

图 3 是 3 个突发流过程的时间结构。

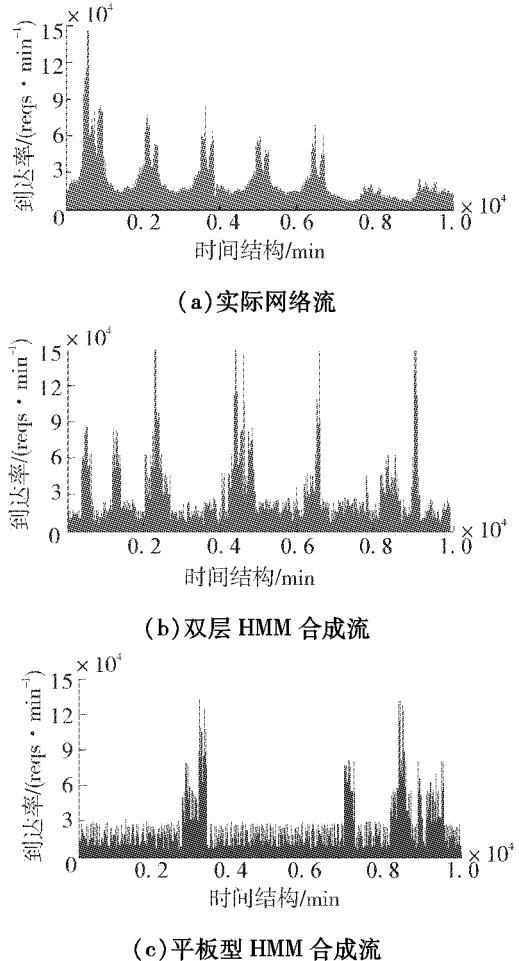


图 3 实际流与合成流的时间结构

Fig. 3 Time structure of real and simulated traffic

从三者的时间结构可以看出, 由双层 HMM 合成的突发流的时间结构更加接近实际的突发流过程, 例如流量强度、突发区域的数量、突发期的持续时间、相邻突发区域的时间间隔等。这主要得益于层次化的模型结构, 即父马尔可夫过程刻画突发过程与非突发过程的行为特性与统计特性, 这使合成流能够具有与实际流类似的大尺度属性。而局部的流量波动则由子层马尔可夫链描述, 因此合成流不会丢失细节信息。而且由于子状态过程分属不同的父状态, 即使不同的父状态具有巨大的流量差异, 它们的细节行为及局部统计属性仍然可以由不同的子状态进行描述。因此, 该模型可以有效描述大小尺度的时间结构性, 而经典的平板型 HMM 所合成的网络流过程则不具有实际突发流的这些时间结构属性。

图 4 是 3 个到达过程的统计分布。从这些结果可以看出: 1) 基于双层 HMM 的合成突发流的统计属性更加接近实际流, 而平板型 HMM 的合成流与实际流的统计属性具有一定的差异; 2) 平板型 HMM 的合成结果中, 数据点比本文的双层 HMM 稀疏。其主要原因是双层 HMM 利用其层次化结构优

势,在模型训练阶段既可以捕获实际流的大尺度统计属性,又可以刻画小尺度细节变化。因此,尽管本实验中2个模型的总状态数一样,但结构化的双层HMM的性能比经典的HMM好。

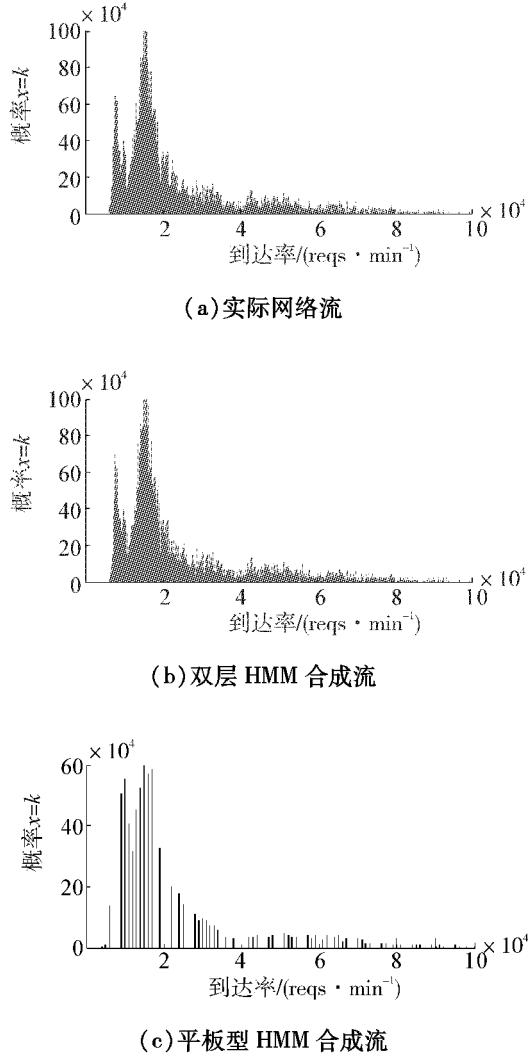


图4 实际流与合成流的统计属性

Fig.4 Statistical properties of real and simulated traffic

自相似性与相关系数是衡量合成网络流的常用指标。表2比较了双层HMM与平板型HMM在这两方面的性能。为了消除实验的随机性,2个用于比较的模型各自独立地生成3个合成流。从表2中可以看到,相对于平板型的HMM,基于双层HMM的3个合成流的Hurst参数都更加接近实际流的Hurst参数。而且,双层HMM的3个合成突发流与实际突发流的相关系数也比平板型HMM的高。

表2 自相似性Hurst参数及相关系数

Table 2 Hurst parameters and correlation coefficients

items	original	Doubly HMM	Flat-HMM
Hurst	0.830	0.835; 0.854; 0.823	0.678; 0.708; 0.739
相关系数	—	0.565; 0.534; 0.633	0.311; 0.269; 0.324

3 结论

提出一种新的双层隐马尔可夫模型用于描述并合成突发流。为实现模型参数推断而提出的前后向算法可以使参数估计和后向递推过程结合在一起,有效减少了存储要求并提高了运算速度。实验结果表明,相对于经典的平板型HMM,基于所提出的双层HMM的合成突发流具有以下的优点:

- 1) 与实际流相似的时间结构性;
- 2) 与实际流相似的统计分布;
- 3) 与实际流相似的自相似性及更高的相关性。

双层HMM的应用并不局限于网络流的到达过程。大部分实际的网络问题都具有层次化的结构,例如传输字节数、连接行为等。因此,所提出的双层HMM可以应用于其他复杂的、结构化的建模问题。

参考文献:

- [1] PAXSON V, FLOYD S. Wide area traffic: the failure of Poisson modeling [J]. IEEE/ACM Transactions on Networking (ToN), 1995, 3(3): 244.
- [2] LELAND W, TAQQU M, WILLINGER W, et al. On the self-similar nature of Ethernet traffic [J]. IEEE/ACM Transactions on Networking, 2002, 2(1): 1-15.
- [3] BERAN J, SHERMAN R, TAQQU M, et al. Long range dependence in variable bit rate video traffic [J]. IEEE Trans on Communication, 1995, 43: 1566-1579.
- [4] ZVIRONIENE A, NAVICKAS Z, RINDZEVICUS R. Bursty traffic simulation by ON-OFF model [J]. Electronics and Electrical Engineering, 2006, 70(6): 65-68.
- [5] RIEDI R, CROUSE M, RIBEIRO V, et al. A multifractal wavelet model with application to network traffic [J]. IEEE Transactions on Information Theory, 2002, 45 (3): 992-1018.
- [6] NORROS I. On the use of fractional Brownian motion in the theory of connectionless networks [J]. IEEE Journal on Selected Areas in Communications, 2002, 13(6): 953-962.
- [7] ABRY P, BARANIUK R, FLANDRIN P, et al. The multi-scale nature of network traffic: discovery, analysis, and modeling [J]. IEEE Signal Processing Magazine, 2002(19): 28-46.
- [8] NISHIMURA S, SHINNO M. Modeling burst traffic using a MAP with a tree structure [J]. Journal of the Operations Research, 2004, 47(3): 129-144.
- [9] ANDERSSON M, CAO J, KIHL M, et al. Performance modeling of an Apache web server with bursty arrival traffic [EB/OL]. [2011-06-18]. <http://lup.lub.lu.se/luur/download?>

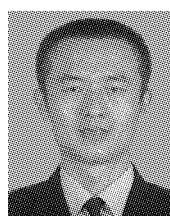
func = downloadFile&recordId = 532529&fileId = 625324.

- [10] KONTOVASSILIS K, MITROU N. Bursty traffic modeling and efficient analysis algorithms via fluid-flow models for ATM IBCN[J]. Annals of Operations Research, 1994, 49(1): 279-323.
- [11] LIU P, CHEUNG W, LI K. On the modeling of bursty traffic [C]//Proceedings on Computer, Communication, Control and Power Engineering. Beijing, China, 2002: 220-223.
- [12] JOHNSON M. Why doesn't EM find good HMM POS-taggers [C]//Proceedings of the 2007 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning (EMNLP-CoNLL). Prague, Czech Republic, 2007: 296-305.
- [13] FINE S, SINGER Y, TISHBY N. The hierarchical hidden Markov model: analysis and applications [J]. Machine Learning, 1998, 32(1): 41-62.
- [14] RABINER L. A tutorial on hidden Markov models and selected applications in speech recognition [J]. Proceedings of the IEEE, 1989, 77(2): 257-286.

作者简介:



谢逸,男,1973年生,讲师,博士,主要研究方向为计算机网络与通信.发表学术论文20余篇,其中多篇被SCI、EI检索.



唐成华,男,1974年生,副教授,博士,主要研究方向为智能信息处理、网络安全等,发表学术论文30余篇,被EI检索13篇.



黄向农,男,1958年生,工程师,主要研究方向为计算机网络应用技术.

第4届智能人机系统与控制论国际会议(IHMSC 2012)

The 4th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC 2012)

As a continuation of IHMSC 2009 to IHMSC 2011, which were held successfully in Hangzhou, Nanjing and Hangzhou respectively, the 4th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC 2012) will take place at Jiangxi Normal University in Nanchang, China, between 26-27 August, 2012. The aim of this conference is to provide a forum for exchanges of research results, ideas for and experience of application among researchers and practitioners involved with all aspects of human-machine systems and cybernetics.

Publication

The proceedings of IHMSC 2012 will be published by the IEEE Computer Society's Conference Publishing Service (CPS), and indexed by EI and ISTP. The proceedings of previous three IHMSC from 2009 to 2011 have been indexed by EI and ISTP, and included in the digital libraries (CSDL, IEEE Xplore, IEEE IEL).

Website: <http://ihmcs.zju.edu.cn/>