

基于 k 阶马尔可夫链的单播网络丢包层析成像

费高雷* 胡光岷

(电子科技大学光纤传感与通信教育部重点实验室 成都 611731)

摘要: 该文针对时域相关的网络链路丢包估计问题,提出一种基于 k 阶马尔可夫链的单播网络丢包层析成像方法。该方法首先引入 k 阶马尔可夫链描述网络链路丢包过程,然后用最大伪似然方法估计 k 阶马尔可夫链链路丢包模型的状态转移概率。当 k 足够大时,该文方法可以根据单播端到端测量数据,准确地估计出网络链路上每个数据包丢失的概率。ns-2 仿真验证了该文方法的有效性。

关键词: 网络层析成像; 链路丢包估计; 时域相关; k 阶马尔可夫链

中图分类号: TP393.02

文献标识码: A

文章编号: 1009-5896(2011)09-2278-05

DOI: 10.3724/SP.J.1146.2010.00814

Unicast Network Loss Tomography Based on k -th Order Markov Chain

Fei Gao-lei Hu Guang-min

(Key Laboratory of Optical Fiber Sensing & Communication, Ministry of Education,
University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: This paper addresses the issue of temporal dependence network link loss inference, presents a k -th order Markov chain based unicast network loss tomography method. The method introduces firstly k -th order Markov Chain (k -MC) to describe the link packet loss process, and then uses pseudo maximum likelihood method to estimate the state transition probabilities of k -th order Markov chain. If k is large enough, then the method presented in this paper is capable of obtaining an accurate loss probability estimate of each packet based on unicast end-to-end measurements. ns-2 simulation validated the effectiveness of the method.

Key words: Network tomography; Link loss inference; Temporal dependence; k -th order Markov Chain (k -MC)

1 引言

互联网的高速发展使得网络规模越来越大,结构越来越复杂。为了更好地设计、控制和管理网络,必须实时地感知网络内部性能参数(如:链路丢包、链路时延和拓扑结构等)。网络层析成像^[1]可以在没有中间节点协作的条件下,通过主动发送端到端探测包或被动收集有用的信息来估计网络内部性能参数,是近年来备受关注的网络测量新技术之一。

网络丢包层析成像(又称为网络链路丢包估计)是网络层析成像的主要研究内容之一。现有多数网络链路丢包估计方法^[2,3]把链路丢包过程看成是 Bernoulli 过程,认为经过同一链路不同数据包的丢包行为是相互独立的,且如果假设丢包率不变,不同时刻发生丢包的可能性是一样的。但是,文献[4,5]

指出网络中同一链路上不同数据包的丢包行为具有相关性,当一个包被丢弃时,该数据包随后的包将以更大的概率被丢弃,即链路丢包具有时域相关性,但简单的 Bernoulli 过程不能准确反映链路丢包的时域相关性。

针对时域相关的网络链路丢包估计问题,文献[4]去除常规方法认为经过同一条链路的的不同探测包相互独立的假设,用 Gilbert 模型(两个状态的马尔可夫过程)对网络链路丢包进行建模,并用贝叶斯方法估计模型的状态转移概率。但是 Gilbert 模型只考虑了相邻两个包的相关性,对链路丢包时域相关性的描述往往不够准确^[6]。文献[5]提出了一种基于多播端到端测量的网络链路丢包时域特征参数估计方法,可以估计连续两个包被丢弃的概率、平均每次丢包的个数等,这些时域特征参数能较好地反应链路丢包的时域相关性,但他们的方法是基于多播的,因此在实际应用中存在限制。

本文提出一种基于 k 阶马尔可夫链的单播网络丢包层析成像方法。首先,针对网络链路丢包的时域相关性,用 k 阶马尔可夫链(k -th order Markov

2010-08-05 收到, 2011-07-08 改回

国家自然科学基金(60872033)和新世纪优秀人才支持计划(NECT-07-0148)资助课题

*通信作者: 费高雷 fgl@uestc.edu.cn

Chain, k -MC) ($k > 0$) 对网络链路丢包进行建模。 k -MC 链路丢包模型的状态转移概率表示在已知某一数据包前面 k 个数据包丢失或成功传输的条件下, 该数据包丢失或成功传输的概率。当 k 足够大时, k -MC 链路丢包模型能准确地反应链路丢包的时域相关性^[6]。其次, 本文根据单播端到端测量数据, 采用最大伪似然的方法估计 k -MC 链路丢包模型的状态转移概率, 其基本思想是利用单播端到端测量每次针对两个目的节点进行的特点, 把网络拓扑拆分为一系列只有两个叶节点的子树, 然后分别最大化这些子树的似然函数估计网络链路 k -MC 丢包模型的状态转移概率。

2 估计模型

2.1 网络模型

与大多数文献^[2-5]类似, 本文考虑一个给定源节点和一组接收节点对应的逻辑树模型 $T = (V, E)$ 。节点集 V 由根节点 0 , 叶节点 D 和内部节点 I 组成。除根节点外的任一节点 v , 都有唯一的父节点 $f(v)$ 。为了简单起见, 把链路 $(f(v), v)$ 记为 $e(v)$ 。所有链路的数目用 $|E|$ 表示。根节点 0 到叶节点 a 的路径用 $P(0, a)$ 表示。本文仿照图论, 用 $T_{a,b}$ 表示以 0 为根节点, a, b 为叶节点的子树; 用 $T_s = \{T_{a,b} : a, b \in D\}$ 表示所有这些子树的集合。

2.2 链路丢包模型

网络层析成像一般通过主动的发送探测包来了解网络实际流量的行为(如: 丢包^[2-5,7], 时延^[8-10]和拓扑结构^[11,12]等), 因此本文关注探测包的丢包行为。用随机过程 $x_v = \{x_v(l)\}$ 表示探测包在链路 $e(v)$ 上的丢失情况, 其中 l 表示探测包的标号。若第 l 个探测包在 $e(v)$ 上被丢弃, $x_v(l)$ 取值为 0 , 否则取值为 1 。本文对链路丢包作以下两个基本假设: (1) 对于任意 $v, w \in V$, 如果 $v \neq w$, 那么 $x_v(l)$ 和 $x_w(l)$ 是相互独立的; (2) x_v 平稳且各态历经。

选用合理的模型对丢包过程进行建模对网络链路丢包估计具有十分重要的意义。本文用 k -MC 对链路丢包进行建模, 该模型认为某一探测包被丢弃的概率与该探测包之前的 k 个探测包有关, 而当两探测包间的间隔大于 $k+1$ 时相互独立。相比于常用的 Bernoulli 和 Gilbert 模型, k -MC 模型考虑了探测包间的时域相关性, 因此能更好地描述链路丢包过程。另一方面, 文献[6]在实际网络中论证了 k -MC 在大多数情况下都能准确地描述网络链路丢包过程。

用二进制向量 $\mathbf{x}^k(l) = [x(l), x(l+1), \dots, x(l+k-1)]$ 表示从第 l 个包开始连续 k 个包的丢失情况, 那

么 k -MC 链路丢包模型的状态转移概率可以表示为

$$P[x(l) | \mathbf{x}^k(l-k)] \quad (1)$$

k -MC 链路丢包模型的状态转移概率表示在已知某一数据包前面 k 个数据包丢失或成功传输的条件下, 该数据包丢失或成功传输的概率。对于式(1), 根据条件概率的定义可得

$$P[x(l) | \mathbf{x}^k(l-k)] = \frac{P[\mathbf{x}^{k+1}(l-k)]}{P[\mathbf{x}^k(l-k)]} \quad (2)$$

其中 $P[\mathbf{x}^k(l-k)]$ 和 $P[\mathbf{x}^{k+1}(l-k)]$ 表示连续多个探测包丢失或成功传输状态的联合概率。定义 k 阶联合状态概率 (k -th order Joint State Probability, k -JSP) 为连续 k 个探测包丢失或成功传输状态的联合概率。由式(2)可知, k -MC 链路丢包模型的状态转移概率可以通过计算 k 和 $k+1$ 阶联合状态概率得到。

$\mathbf{x}_j^k(l)$ 中元素的取值为 0 或 1 , 那么 $\mathbf{x}_j^k(l)$ 有 $K = 2^k$ 种不同的取值方式。用 \mathbf{s}_i 表示 $\mathbf{x}_j^k(l)$ 的第 i 种取值方式, 其中 i 的值通过把二进制的 $\mathbf{x}_j^k(l)$ 转化为十进制获得。用 $\theta_{j,i}$ 表示 $\mathbf{x}_j^k(l)$ 取值为第 i 个状态的概率, 即有 $\theta_{j,i} = P[\mathbf{x}_j^k(l) = \mathbf{s}_i]$ 。本文需要估计的是所有链路联合状态概率的概率质量函数 (Probability Mass Function, PMF) $\boldsymbol{\theta} = [\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_{|E|}]$, 其中 $\boldsymbol{\theta}_j = [\theta_{j,0}, \theta_{j,1}, \dots, \theta_{j,K-1}]^T$, $1 \leq j \leq |E|$ 。在下文中, 把链路联合状态概率的概率质量函数简称为链路 PMF。

3 最大伪似然估计

3.1 伪似然函数

针对链路丢包估计的单播探测包方式有背靠背包^[2](back-to-back)或包组^[3](packet strip)两种。这两种方式的共同点是根节点每次向两个叶节点发送探测包, 这实际上是把网络分成一系列只有两个叶节点的逻辑子树分别进行测量。本文针对这一特点采用最大伪似然方法进行估计。该方法在网络层析成像中的应用最早出现在链路时延估计和源到目的 (OD) 流估计^[13], 其基本思想是把全局问题拆分成一系列的子问题, 并忽略子问题之间的相关性, 分别对子问题的似然函数进行最大化以获得需要估计的参数。如图 1(a)所示, 若 0 节点向节点 1 , 节点 2 发送探测包, 那么对应的子树如图 1(b)所示。为方便描述, 子树的 3 条逻辑链路分别用 c , u 和 v 表示(如图 1(b)所示)。

与链路丢包状态的表示类似, 用向量 $\mathbf{y}_a^k(l) = [y_a(l), y_a(l+1), \dots, y_a(l+k-1)]$ 表示在子树 $T_{a,b}$ 的叶节点 a 上观测到的从第 l 个探测包开始连续 k 个探测包的丢包情况, 那么在 $T_{a,b}$ 两个叶节点上获得的一系列观测值的集合可以用 $Y_{a,b}^k = \{\mathbf{y}_a^k(l), \mathbf{y}_b^k(l)\}_{l=1}^{N-k+1}$ 表示, 其中 N 是探测包数; 所有子树叶节点观测数据

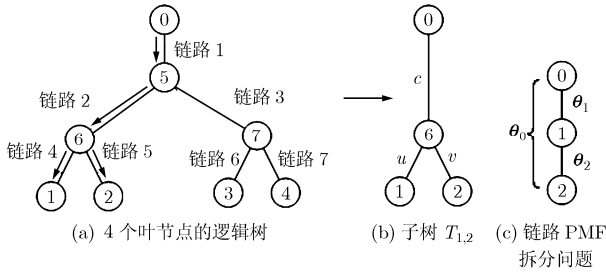


图1 树拆分

的集合用 $Y^k = \{Y_{a,b}^k : a, b \in D\}$ 表示。如果某一探测包在路径上的所有链路都成功传输，那么该路径的叶节点就能够接收到该探测包，否则就无法接收到。因此，叶节点 a 上观测到的丢包情况和路径 $P(0, a)$ 上链路的丢包情况有以下关系：

$$\mathbf{y}_a^k(l) = \mathbf{x}_{j_1}^k(l) \& \mathbf{x}_{j_2}^k(l) \& \cdots \& \mathbf{x}_{j_M}^k(l) \quad (3)$$

其中 $\&$ 是按位与运算(例如： $\mathbf{x}_i = [1, 0, 1, 0]$ ， $\mathbf{x}_j = [1, 1, 0, 1]$ ，那么 $\mathbf{x}_i \& \mathbf{x}_j = [1, 0, 0, 0]$)； $\{j_1, j_2, \dots, j_M\}$ 表示路径 $P(0, a)$ 上所有链路的集合； M 是该路径上的链路数。另一方面，如果已知路径 $P(0, a)$ 和该路径上某一条链路 j 的丢包情况，那么两者之间应满足

$$\mathbf{x}_j^k(l) \& \mathbf{y}_a^k(l) = \mathbf{y}_a^k(l) \quad (4)$$

对于子树 $T_{a,b}$ ，若已知两个叶节点丢包情况的一组观测值 $\{\mathbf{y}_a^k(l), \mathbf{y}_b^k(l)\}$ ，用 $S_c(l)$ 表示共享链路上可能状态的集合，即对于 $\forall s_i \in S_c(l)$ ，有 $s_i \& \mathbf{y}_a^k(l) = \mathbf{y}_a^k(l)$ 和 $s_i \& \mathbf{y}_b^k(l) = \mathbf{y}_b^k(l)$ ；用 $S_u(l, c) = \{s_i : s_i \& s_c = \mathbf{y}_a^k(l)\}$ 和 $S_v(l, c) = \{s_i : s_i \& s_c = \mathbf{y}_b^k(l)\}$ 分别表示已知共享链路的状态 s_c 的条件下链路 u 和 v 上可能状态的集合。那么，子树 $T_{a,b}$ 的似然函数可以写成以下形式：

$$F_{a,b}(Y_{a,b}^k | \boldsymbol{\theta}) = \prod_{l=1}^{N-k+1} \left[\sum_{s_c \in S_c(l)} P(s_c) \left(\sum_{s_u \in S_u(l,c)} P(s_u) \right) \cdot \left(\sum_{s_v \in S_v(l,c)} P(s_v) \right) \right] \quad (5)$$

全局伪似然函数是所有子树似然函数的积，那么树 T 的全局伪似然函数表示为

$$F_T(Y^k | \boldsymbol{\theta}) = \prod_{T_{a,b} \in T_s} F_{a,b}(Y_{a,b}^k | \boldsymbol{\theta}) \quad (6)$$

对式(6)左右两边取对数可得对数伪似然函数：

$$L_T(Y^k | \boldsymbol{\theta}) = \lg F_T(Y^k | \boldsymbol{\theta}) = \sum_{T_{a,b} \in T_s} \lg F_{a,b}(Y_{a,b}^k | \boldsymbol{\theta}) \quad (7)$$

由于对数运算不改变似然函数的单调性，因此最大化对数伪似然函数可以得到链路 PMF 的最大伪似然估计。但是由于问题的复杂性，直接对式(7)进行最大化求解非常困难。一种替代的方法是使用期望最大化(EM)算法。对于任意子树 $T_{a,b}$ ，用 EM 算法估计相应链路 PMF 的具体步骤如下：

(1)输入： $T_{a,b}$ 两个叶节点上获得的一系列的观测值 $Y_{a,b}^k = \{\mathbf{y}_a^k(l), \mathbf{y}_b^k(l)\}_{l=1}^{N-k+1}$ ，子树 3 条链路 PMF 的初始值 $\boldsymbol{\theta}^{(0)} = [\boldsymbol{\theta}_c^{(0)}, \boldsymbol{\theta}_u^{(0)}, \boldsymbol{\theta}_v^{(0)}]$ 。

(2)迭代：令 t 次迭代后，子树的链路 PMF 为 $\boldsymbol{\theta}^{(t)}$ 。

E 步(估计各链路上连续 k 个包出现状态 s_i 次数的期望值)：

$$\widehat{m}_{j,i}^{(t+1)} = \sum_{l=1}^{N-k+1} p^{(t)}(\mathbf{x}_j^k(l) = s_i | Y_{a,b}^k(l), \boldsymbol{\theta}^{(t)}), \quad j=c, u, v \quad (8)$$

其中 $p^{(t)}(\mathbf{x}_j^k(l) = s_i | Y_{a,b}^k(l), \boldsymbol{\theta}^{(t)})$ ， $j=c, u, v$ 通过上下行信息传递算法^[14]计算得到，其实质是假设一条链路状态已知的条件下，推断其余两条链路可能的状态，并计算相应的概率。

M 步(更新子树的链路 PMF)：

$$\boldsymbol{\theta}_{j,i}^{(t+1)} = \widehat{m}_{j,i}^{(t+1)} / \left(\sum_{i=0}^{K-1} \widehat{m}_{j,i}^{(t+1)} \right), \quad j=c, u, v \quad (9)$$

EM 算法通过上述两个步骤不断地更新子树的链路 PMF，使得子树似然函数的值不断逼近一个极大值。当迭代停止时，相应的 $\boldsymbol{\theta}^{(t+1)}$ 即为子树链路 PMF 的估计值。

3.2 链路 PMF 的拆分

EM 算法估计的是各子树逻辑链路的 PMF，而子树的逻辑链路可能由原树的多条链路组成，这使得原树的某些链路的 PMF 不能直接得到，因此需要作进一步估计。本文把这一过程称为链路 PMF 的拆分。链路 PMF 的拆分可以抽象为图 1(c)所示的问题： $(0,2)$ 和 $(0,1)$ 的 PMF 已知，分别用 $\boldsymbol{\theta}_0$ 和 $\boldsymbol{\theta}_1$ 表示； $(1,2)$ 的 PMF 需要估计，用 $\boldsymbol{\theta}_2$ 表示。根据式(3)可得式(10)：

$$\boldsymbol{\theta}_{0,i} = \sum_{r=0}^{K-1} \boldsymbol{\theta}_{2,r} \left(\sum_{t \in I(i,r)} \boldsymbol{\theta}_{1,t} \right), \quad 0 \leq i \leq K-1 \quad (10)$$

其中 $I(i, j)$ ， $j=0, 1, \dots, K-1$ ，表示 $(0,2)$ 和 $(1,2)$ 的状态分别在 s_i 和 s_j 的条件下， $(0,1)$ 上可能状态标号的集合。联立所有式(10)形式的式子可得以下线性方程组：

$$\boldsymbol{\theta}_0 = \mathbf{A} \boldsymbol{\theta}_2 \quad (11)$$

其中 \mathbf{A} 是 $K \times K$ 的方阵， $\mathbf{A}_{i,j} = \sum_{t \in I(i,j)} \boldsymbol{\theta}_{1,t}$ 。若 $i > j$ ，则 $I(i, j) = \emptyset$ ，那么相应的 $\mathbf{A}_{i,j} = 0$ 。因此， \mathbf{A} 是可逆的上三角矩阵，式(11)存在唯一解 $\boldsymbol{\theta}_2 = \mathbf{A}^{-1} \boldsymbol{\theta}_0$ 。

4 仿真

为了验证本文方法的有效性，本文用 ns-2 搭建仿真平台(如图 1(a)所示)。图中总共包含 8 个节点和 7 条链路。每条链路都采用 FIFO 的队列模型，

各链路参数设置如表 1。仿真的背景流量由 120 条 Pareto On-Off 模型的 UDP 流和 120 条 TCP 流组成。UDP 流的 On 期和 Off 期都是 200 ms, On 期的速率是 0.5 Mbps, TCP 流的速率是 0.2 Mbps。本文采用背靠背包形式的探测包^[4]对子树 $T_{1,2}$, $T_{2,3}$ 和 $T_{3,4}$ 进行测量。探测包是 0 节点产生的 CBR UDP 流, 大小为 50 Byte, 发送间隔为 20 ms。整个测量周期持续 2000 s。

表 1 各链路参数

参数\链路	1	2	3	4	5	6	7
带宽(Mbps)	20	10	10	5	5	5	5
延迟(ms)	10	10	10	5	5	5	5
队列长度	50	30	30	20	20	20	20

k -MC 链路丢包模型的阶数可通过计算链路丢包的自相关系数确定^[6]。但在网络层析成像中, 链路丢包的数据是无法直接获得的。然而, 路径丢包数据是路径上所有链路丢包共同作用的结果, 因此链路丢包的相关性能在各叶节点的观测数据上反映。本文通过计算各叶节点观测数据的自相关系数来确定链路丢包模型的阶数。对于图 1(a)网络, 根据文献^[6]的定义计算各叶节点观测数据的自相关系数, 结果表明: 当 $k > 3$ 时, 各路径丢包数据的自相关系数都接近于 0, 因此采用 3 阶马尔可夫链对该网络中的链路丢包进行建模。

为获得 3 阶马尔可夫链路丢包模型的状态转移概率, 本文估计各链路 3-JSP 和 4-JSP 的 PMF, 其中链路 1 的结果如图 2 所示(该链路是随机选择的, 其余链路的结果与该链路相似)。从图 2 中可以看到本文方法估计得到的链路 PMF 与真实的链路




图 2 链路 1 的 PMF

PMF 几乎重合在一起, 说明本文方法能获得准确的估计结果。

为比较 Bernoulli, Gilbert 和 k -MC 丢包模型的性能, 本文考虑已知连续的 3 个包被丢弃的条件下第 4 个包被丢弃的概率。这里为了方便表述, 用 $p_{k+1|k}$ 表示已知连续 k 个包被丢弃的条件下第 $k+1$ 包被丢弃的概率, 用 p_k 表示连续 k 个包被丢弃的概率, 特别地, 用 p_1 表示丢包率。Bernoulli 模型认为各个包是相互独立的, 所以 $p_{4|3} = p_1$; Gilbert 模型考虑相邻两个包的相关性, 因此有 $p_{4|3} = p_{2|1} = p_2 / p_1$; 而对于 k -MC 模型, 当 $k=2$ 时, $p_{4|3} = p_3 / p_2$; 当 $k=3$ 时, $p_{4|3} = p_4 / p_3$ 。图 3 和图 4 分别描述了 3 种模型下 $p_{4|3}$ 的估计值和这些估计值的相对误差。从图 4 中可以看出, 当使用 k -MC 模型时, 所有链路上的丢包估计结果都具有最小的相对误差, 因此 k -MC 模型优于一般的 Bernoulli 模型和 Gilbert 模型。另一方面, 3 阶马尔可夫链比 2 阶马尔可夫链获得了更准确的估计结果, 因此使用高阶马尔可夫链可获得对链路丢包过程更好的描述。

5 结论

本文针对网络链路丢包具有时域相关性的特点, 采用 k -MC 对链路丢包进行建模。当 k 足够大时, k -MC 链路丢包模型能够准确地描述链路丢包的时域相关性。为了获得链路丢包模型的参数, 本文将 k -MC 链路丢包模型的状态转移概率估计问题转化为 k 阶联合状态概率估计问题, 然后采用最大伪似然的方法进行估计。本文最后用 ns-2 仿真证明了本文方法能准确地估计出链路丢包的 k 阶联合状态概率, 且通过比较说明了 k -MC 模型优于 Bernoulli 模型和 Gilbert 模型。

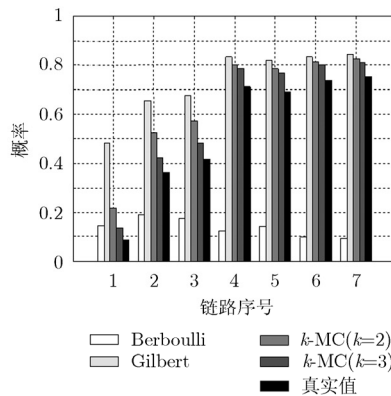


图 3 3 种模型估计所得的 $p_{4|3}$ 与实际值比较

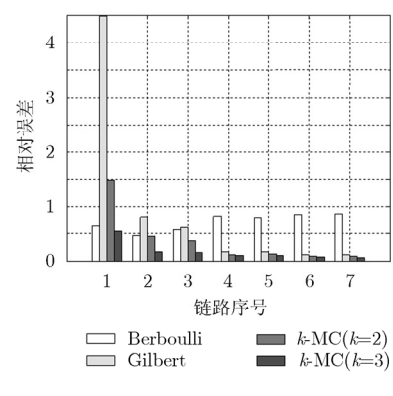


图 4 3 种模型估计所得的 $p_{4|3}$ 的相对误差

参 考 文 献

- [1] Coates M, Hero A, Nowak R, *et al.*. Internet tomography[J]. *IEEE Signal Process Magazine*, 2002, 19(3): 47-65.
- [2] Coates M and Nowak R. Network loss inference using unicast end-to-end measurement[C]. ITC Conference on IP Traffic Modelling and Management, Monterey, CA, USA, September 2000: 2384-2394.
- [3] Duffield N G, Presti F L, Paxson V, *et al.*. Network loss tomography using striped unicast probes[J]. *IEEE/ACM Transactions on Networking*, 2006, 14(4): 697-710.
- [4] Guo D and Wang X. Bayesian inference of network loss and delay characteristics with applications to TCP performance prediction[J]. *IEEE Transactions on Signal Processing*, 2003, 51(8): 2205-2218.
- [5] Arya V, Duffield N G, and Veitch D. Multicast inference of temporal loss characteristics[J]. *Performance Evaluation*, 2007, 64(9-12): 1169-1180.
- [6] Yajnik M, Sue M, Kurose J, *et al.*. Measurement and modelling of the temporal dependence in packet loss[C]. IEEE INFOCOM, New York, USA, March 1999: 345-352.
- [7] Su H, Li Y, Lin S, *et al.*. Inference of link loss rates by explicit estimation[J]. *IET Communications*, 2010, 4(5): 540-550.
- [8] Arya V, Duffield N G, and Veitch D. Temporal delay tomography[C]. IEEE INFOCOM, Phoenix, AZ, USA, April 2008: 276-280.
- [9] Antichi G, Pietro A D, Ficara D, *et al.*. End-to-end inference of link level queueing delay statistics[C]. IEEE GLOBECOM, Honolulu, Hawaii, USA, December 2009: 2930-2935.
- [10] Gu Y, Jiang G, Singh V, *et al.*. Optimal probing for unicast network delay tomography[C]. 2010 Proceedings IEEE INFOCOM, San Diego, CA, USA, March 2010: 1-9.
- [11] Eriksson B, Dasarathy G, Barford P, *et al.*. Toward the practical use of network tomography for internet topology discovery[C]. 2010 Proceedings IEEE INFOCOM, San Diego, CA, USA, March 2010: 1-9.
- [12] Ni J, Xie H, Tatikonda S, *et al.*. Efficient and dynamic routing topology inference from end-to-end measurements[J]. *IEEE/ACM Transactions on Networking*, 2010, 18(1): 123-135.
- [13] Liang G and Yu B. Maximum pseudo likelihood estimation in network tomography[J]. *IEEE Transactions on Signal Processing*, 2003, 51(8): 2043-2053.
- [14] Frey B. Graphical Models for Machine Learning and Digital Communication[M]. Cambridge, MA, USA, MIT Press, 1998: 27-35.

费高雷：男，1982年生，博士生，研究方向为计算机通信网、网络层析成像。

胡光岷：男，1966年生，教授，博士生导师，研究方向为计算机通信网、网络行为学与安全。