

基于合并分层聚类的网络拓扑推断算法

张润生, 李艳斌, 李啸天

(中国电子科技集团公司第五十四研究所, 河北石家庄 050081)

摘 要: 针对 HTE(Hierarchical Topology Estimation)算法计算复杂度较高的问题及其在节点相关性估计方差较大条件下性能下降的问题, 提出基于合并分层聚类的网络拓扑推断算法. 该算法采用自底向上的合并分层聚类, 每次聚类仅使用与最大相关节点对有关的数据, 相对 HTE 算法降低了运算复杂度; 建立了改进的有限混合模型, 增加了参数推断的有效数据, 提高了算法的参数估计精度. 仿真结果表明相对 HTE 算法, 本文方法可以更快地推断出网络拓扑, 且在节点相关性估计方差较大条件下, 有更高的拓扑推断精度.

关键词: 拓扑推断; 分层聚类; 有限混合模型; 期望最大化

中图分类号: TP393 **文献标识码:** A **文章编号:** 0372-2112 (2013) 12-2346-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.12.005

Agglomerative Hierarchical Clustering Based Algorithm for Network Topology Inference

ZHANG Run-sheng, LI Yan-bin, LI Xiao-tian

(The 54th Research Institute of CETC, Shijiazhuang, Hebei 050081, China)

Abstract: Considering the high complexity of HTE(Hierarchical Topology Estimation)and its performance degradation under the condition of large correlation estimation variance, a method based on agglomerative hierarchical clustering is proposed. The method employs bottom-up agglomerative hierarchical clustering, which only uses the data related to the node pair with the largest correlation, so it has lower computation complexity than HTE. A modified finite mixture model is established, increasing the amount of effective data, which improves the accuracy of parameter estimation. The simulation demonstrates that the proposed method infers the topology more rapidly, with higher accuracy when the correlation estimation variance is large.

Key words: topology inference; hierarchical clustering; finite mixture model; expectation maximization

1 引言

获取网络拓扑对于网络管理、网络优化以及网络故障诊断等, 都有十分重要的意义. 传统的网络拓扑获取技术都基于网络协议, 通过主动向网络发送 Traceroute 等探测包或被动侦听与拓扑相关的网络信息来发现网络拓扑^[1], 得到了不错的效果^[1~3]. 然而随着网络设备的安全设置日趋复杂, Traceroute 探测包往往会被视为 DDos 攻击, 而不予响应^[4]; 由于路由信息包复杂的加密技术, 被动侦听也难以实现. 因此, 传统拓扑发现技术的局限性日益凸显.

网络层析成像技术是一种新的网络测量技术, 其通过统计的方法推断网络性能和拓扑结构^[4~6]. 基于网络层析成像的拓扑推断算法能够通过端到端测量来获取

网络端节点的相关性, 进而利用该相关性来推断网络的拓扑结构, 其无需网络内部节点的合作, 较传统的拓扑发现技术有其优越性^[7].

最早网络层析成像拓扑推断技术基于多播测量, 文献[8]通过测量网络端到端丢包率来推断树状拓扑, 文献[9]给出了一种综合利用丢包率和链路利用率的自适应拓扑推断算法, 二者都是先推断出二叉树, 再通过设置适当门限修剪二叉树来获得真实拓扑, 其门限的选择在实际中可操作性较差, 且在测量方差较大时, 树的修剪会出现较大偏差. 文献[10]利用汉明距离合并树状拓扑中的兄弟节点, 较以往算法有一定的稳健性, 但同样存在门限的选择问题.

由于单播在实际网络中得到更广泛支持, 大量文献对基于单播的拓扑推断技术展开了研究. 在探测包设计

方面,文献[11]分析了基于单播的背靠背包、三明治包以及丢包率方法的性能,并给出了三种方法的不同适应条件.文献[12~14]设计了更加实用的单播探测包.在拓扑推断算法方面,文献[15]充分利用观测数据的统计特性,给出了基于马尔可夫蒙特卡罗的 MLT(Maximum Likelihood Tree)拓扑推断方法和自底向上合并的 ALT(Agglomerative Likelihood Tree)拓扑推断方法,MLT 是一种全局搜索方法,其运算量巨大,ALT 是采用分层合并的二叉树方法,需要选择门限修剪二叉树.文献[11]将节点相关性数据建模为有限混合模型,提出基于自顶向下叶子节点分层聚类的拓扑推断算法(HTE),该算法无需树的修剪,性能较 ALT 有很大提升,但其有较大的运算量.文献[16]研究了在已知拓扑结构中加入新节点的问题,提出了一种序贯动态拓扑推断算法,可减少探测包的数目.文献[17]借鉴文献[16]的思想提出一种基于叶子节点序贯插入的拓扑推断算法,其运算量较 MLT 有所减少.文献[18]将基于层析成像的网络拓扑推断技术应用于 P2P 流媒体系统优化 P2P 的节点选择,实现了高效率的数据转发,对层析成像拓扑推断算法的实际应用做出了贡献.

本文提出了基于合并分层聚类的拓扑推断算法(AHT, Agglomerative Hierarchical clustering based Topology inference),该算法首先对部分节点相关性数据建立修正的有限混合模型,然后通过对端节点自底向上的合并分层聚类实现拓扑推断,相对于 HTE 算法其有更高的时间效率和更好的拓扑推断性能.

2 网络拓扑推断模型

本文将待推断的网络拓扑建模为有向逻辑树^[14] T ,令 $T = (V, E)$, V 为树图中的顶点集合,对应于网络中的物理设备(主机、路由器、交换机等), V 由根节点 s 、叶子节点集合 D (其中 N_{leaf} 为叶子节点的数目)以及内部节点集合 I 构成; E 为边集合,对应于网络中的链路(连接节点的通信链路).令树根节点 s 为源节点,树的叶子节点集合 D 为接收节点.令 $U = s \cup D$ 为端节点,易得 U 中所有节点的度都为 1(假设每个端节点仅与一个路由器相连).该逻辑树^[16]中除根节点之外的所有非叶子节点均至少有两个孩子节点,除根节点之外的所有节点 $v \in I \cup D$ 均有唯一的父节点 $f(v)$;令 $(f(v), v), f(v), v \in V$ 表示 v 与其父节点之间的链路;令 (s, v) 为根节点 s 与节点 v 之间的链路;令 $a(i, j), i \neq j, i, j \in D$ 为节点对 $\{i, j\}$ 最深(距根节点最远)的公共父节点;令 $P(i, j)$ 为 $\{(s, i), (s, j)\}$ 的共享链路,即 $P(i, j) = (s, a(i, j))$.

定义叶子节点的相关性为 $\gamma_{ij} = N(P(i, j))$, $N(P(i, j))$ 表示节点对 (i, j) 共享链路上的某种性能的

度量(排队时延方差、丢包率方差等),满足 $N(P(i, j)) \propto P(i, j)$,可见拓扑树中叶子节点对的共享链路越长,相关性越大.叶子节点相关性满足以下条件^[11]:

(1)单调性:如果 $P(i, j)$ 是 $P(k, l)$ 的子链路,其中 $i, j, k, l \in D$ 且 $i \neq j, k \neq l$,则有 $\gamma_{ij} < \gamma_{kl}$.

(2)一致性:如果 $P(i, j)$ 与 $P(k, l)$ 为相同链路,即 $a(i, j) = a(k, l)$,其中 $i, j, k, l \in D$ 且 $i \neq j, k \neq l$,则 $\gamma_{ij} = \gamma_{kl}$.

在单播拓扑推断算法中用节点相关性测度采样 $\hat{\gamma}_{ij}$ ($\hat{\gamma}_{ij} \propto \text{length}(P(i, j))$, $\text{length}(\cdot)$ 表示共享路径的长度)作为节点相关性测度 γ_{ij} 的估计值,获取 $\hat{\gamma}_{ij}$ 的常用方法有背靠背包时延协方差方法、丢包率协方差方法和三明治包方法^[11].只要得到树状拓扑中叶子节点的相关性测度集合 $\{\hat{\gamma}_{ij}, i, j \in D\}$,就可以利用节点之间的相关性测度,通过分层聚类算法来推断树状拓扑结构.

3 HTE 算法

HTE 算法的基本思想为对叶子节点的分层聚类^[19],其逐级将叶子节点划分为可分子类和不可分子类^[11],每个可分子类对应树状拓扑中的一个内部节点,这样分层聚类完毕即可推断出所有内部节点,进而得到树状网络拓扑.对于图 1 中的树状拓扑,图 2 给出了其分层聚类结果,左边为叶子节点的分层聚类,右边为叶子节点相关性的聚类结果.可以通过聚类获得最小的节点相关性集合(对应于图 2 中右侧最上边的椭圆)将叶子节点划分为 $\{1, 2\}$ 和 $\{3, 4, 5, 6, 7\}$,推断出节点 11,以此类推集合 $\{3, 4, 5, 6, 7\}$ 又可划分为 $\{3\}, \{7\}$,




图1 树状拓扑示意图




图2 对应图1的分层聚类过程

{4,5,6},可推断出节点 9,{4,5,6}又可划分为三个不可分子类{4},{5},{6},可推断出节点 8,同理可推断出节点 10 的存在.

聚类的关键是得到每一层的类间相关性集合,文献[11]指出每个叶子节点类(基类或子类)中数值最小的相关性集合为类间相关性集合,然而由于测量误差的存在,此最小的相关性集合难以直观得到,HTE 算法将叶子节点的相关性测度集合建模为有限混合模型,取有限混合模型中均值最小的分量为每一层的类间相关性集合.

设叶子节点对 i, j 的相关性集合采样为 $\hat{\Gamma}_{ij} = \{\hat{\gamma}_k^{(i,j)}, k = 1, \dots, N\}$ (可由时延协方差法、丢包率协方差法或三明治包法测得), N 为采样数(其中 $N = M * N_{\text{norm}}$),将其分成 M 组,每组 N_{norm} 个,对每组分别求平均,得到新的采样集合 $\Gamma_{ij} = \{\bar{\gamma}_n^{(i,j)}, n = 1, \dots, M\}$, $\bar{\gamma}_n^{(i,j)} = (\sum_{k=(n-1)*N_{\text{norm}}+1}^{n*N_{\text{norm}}} \hat{\gamma}_k^{(i,j)})/N_{\text{norm}}$,根据中心极限定理,只要 N_{norm} 足够大, $\bar{\gamma}_n^{(i,j)}$ 近似服从高斯分布,根据叶子节点相关性的一致性可得,如果 $a(i, j) = a(k, l)$,则 $\bar{\gamma}_n^{(i,j)}$ 与 $\bar{\gamma}_n^{(k,l)}$ 近似服从相同的概率分布[11].由于 $\bar{\gamma}_n^{(i,j)}$ 都与某个内部节点(即 $a(i, j)$)相关联,所以 $\{\Gamma_{ij}, i, j \in D\}$ 中元素必定可以根据其从属的内部节点划分为有限个集合,集合个数等于内部节点个数(如图 2 中右图所示).定义每个集合为一个分量,记分量个数为 k ,引入辅助变量 $\{Z_m^{(i,j)}, m = 1, \dots, k\}$,满足

$$Z_m^{(i,j)} = \begin{cases} 1, & \Gamma_{ij} \in m \\ 0, & \Gamma_{ij} \notin m \end{cases} \quad (1)$$

对 $\{\Gamma_{ij}, i, j \in D\}$ 建立有限混合模型,参数为 $\theta = \{k, \alpha_1, \dots, \alpha_k, \theta_1, \dots, \theta_k\}$

$$f_{\text{FM}}(\Gamma) = \prod_{i,j \in D} \prod_{m=1}^k (\alpha_m \phi(\Gamma_{ij}; \theta_m))^{Z_m^{(i,j)}} \quad (2)$$

即

$$f_{\text{FM}}(\Gamma, \theta) = \prod_{i,j \in D} \prod_{m=1}^k (\alpha_m \prod_{n=1}^M \phi(\bar{\gamma}_n^{(i,j)}; \theta_m))^{Z_m^{(i,j)}} \quad (3)$$

对数似然为

$$\ell(\Gamma, \theta) = \sum_{i,j \in D} \sum_{m=1}^k Z_m^{(i,j)} [\log \alpha_m + \sum_{n=1}^M \log \phi(\bar{\gamma}_n^{(i,j)}; \theta_m)] \quad (4)$$

其中 $\Gamma = \{\Gamma_{ij}, 1 < i < N_{\text{leaf}}, i < j \leq N_{\text{leaf}}\}$, $\phi(\Gamma_{ij}; \theta_m)$ 为 Γ_{ij} 属于第 m 个分量条件下的概率分布, ϕ 为参数为 θ_m 的高斯分布, α_m 为式(1)中分量 m 的概率, $\sum_{m=1}^k \alpha_m = 1, 0 \leq \alpha_m \leq 1$.

对式(4)引入模型阶数惩罚项,通过 EM (Expectation-Maximization) 算法就可估计出 $\{Z_m^{(i,j)}, m = 1, \dots, k\}$. 然后构造以每个子类中所有叶子节点为顶点的完全

图,该完全图边的权值集合为 $\{1 - Z^{(i,j)}\}$,通过 HCS 算法[11]即可对类内的叶子节点进行分类.如此迭代即可完成自顶向下的分层聚类,进而推断出树状拓扑.

文献[7]给出了 HTE 算法的步骤,但该步骤并未提及叶子节点的划分过程,这里给出 HTE 算法的具体步骤:

```

Input:  $D, V = \{0\} \cup D, \Gamma, I = \emptyset$ 
Finish  $\leftarrow$  false,  $N \leftarrow |D| + 1$ 
 $V \leftarrow V \cup \{N\}, E \leftarrow \{(0, N)\} \cup \{(N, k), k \in D\}$ 
 $I \leftarrow \{N\}, N \leftarrow N + 1, T = (V, E)$ 
While(  $\sim$  Finish) do
   $I' \leftarrow \emptyset, \text{Finish} \leftarrow \text{true}$ 
  For all  $i \in I$  do
    对于树图  $T$ ,令内部节点  $i$  的所有孩子节点对应的相关性集合为  $\Gamma_i$ ,对  $\Gamma_i$  建立有限混合模型,估计其最小分量对应的  $\{Z_1\}$ ,以  $\{1 - Z_1\}$  为边的权值,以  $i$  的所有孩子节点为顶点构造完全图  $H$ ,应用 HCS 算法对  $H$  中的顶点聚类,  $K \leftarrow \text{HCS}(H)$ ,
    If(  $|K| > 1$ ) do
      For all  $A \in K$  do
        If(  $|A| > 1$ ) do
           $V \leftarrow V \cup \{N\}, E \leftarrow (E \setminus \{(i, j), j \in A\}) \cup \{(i, N)\} \cup \{(N, j), j \in A\}$ 
          If(  $|A| > 2$ ) do
             $I' \leftarrow I' \cup \{N\}, \text{Finish} \leftarrow \text{false}$ 
          End if
        End if
      End for
    End if
  End for
   $I \leftarrow I'$ 
End while
Output  $T = (V, E)$ 

```

其中 $\{0\}$ 表示根节点, D 为叶子节点集合, E 为边集合, I 为内部节点集合, V 为拓扑图中顶点集合, Γ 为叶子节点相关性集合, K 表示 HCS 算法得到的叶子节点聚类集合, (N, k) 为节点 N 到节点 k 的边, \setminus 表示删除, \leftarrow 表示右边赋值给左边.

4 AHT 算法

4.1 算法描述

HTE 算法每一次应用有限混合模型分层聚类都使用该子类中的所有相关性数据,存在较大的冗余.我们提出了自底向上的分层合并拓扑推断算法(AHT).文献

[15]中的 ALT 也是一种自底向上的拓扑推断算法,但其每次仅寻找最相关的两个叶子节点进行合并,得到的是二叉树,需要进行修剪才能得到目标拓扑,而该修剪过程会带来较大误差,这里我们应用有限混合模型,来寻找所有与最大相关节点对具有相同父节点的叶子节点,然后与最大节点对合并,以避免修剪过程.

首先,寻找相关性最大的叶子节点对 $\langle i, j \rangle$, 即

$$\langle i, j \rangle = \arg \max_{i, j \in D} (\bar{\Gamma}_{ij}), \bar{\Gamma}_{ij} = \sum_{n=1}^M \bar{\gamma}_n^{(i, j)} \quad (5)$$

定理 1 若 $\langle i, j \rangle$ 为最大相关节点对, 则 $\gamma_{il} = \gamma_{jl}$, $\forall l \in D, l \neq i, l \neq j$.

证明: 假设 $\gamma_{il} < \gamma_{jl}$, 则 $P(i, l) < P(j, l)$, 那么 i, j, l 三点的位置关系应为图 3 所示, 由叶子节点相关性的单调性可得, $P(i, j) < P(j, l)$, 即 $\gamma_{ij} < \gamma_{jl}$, 与 $\langle i, j \rangle$ 为最大相关节点对矛盾, 同理 $\gamma_{il} > \gamma_{jl}$ 亦不成立, $\gamma_{il} = \gamma_{jl}, l \in D, l \neq i, l \neq j$, 证毕.




图3 i, j, l 的位置关系

由文献[11]中 A4 可得, 若 $\gamma_{il} = \gamma_{jl}, l \in D, l \neq i, l \neq j$, 则 $\Gamma_{il} = \{\bar{\gamma}_n^{(i, l)}, n = 1, \dots, M\}$ 与 $\Gamma_{jl} = \{\bar{\gamma}_n^{(j, l)}, n = 1, \dots, M\}$ 近似服从相同的高斯分布, 故可将 Γ_{il} 与 Γ_{jl} 合成一组数据, 记为 $\Gamma_{(ij)l} = (\Gamma_{il}, \Gamma_{jl})$. 与 HTE 算法类似, 对 $\{\Gamma_{(ij)l} = (\Gamma_{il}, \Gamma_{jl}), l \in D, l \neq i, l \neq j\}$ 建立有限混合模型, 如式(6)所示. 由于 $\langle i, j \rangle$ 为最大相关节点对, 则 Γ_{ij} 必属于该有限混合模型的最大分量集合, 那么我们通过寻找同属于该集合的 $\Gamma_{(ij)l}$, 可得到与 $\langle i, j \rangle$ 具有相同父亲节点所有节点 $\{l^*\}$. 例如在图 1 中, 假设 $(4, 5)$ 为最大节点对, 那么通过有限混合模型可得 $\Gamma_{(4,5)6}$ 与 $\Gamma_{4,5}$ 同属于最大分量集合, 则叶子节点 4, 5, 6 具有相同的父亲节点.

$$f_{EM}(\Gamma) = \left\{ \prod_{l \in D} \prod_{m=1}^k (\alpha_m \phi(\Gamma_{(ij)l}; \theta_m))^{Z_m^{(i, l)}} \cdot \prod_{m=1}^k (\alpha_m \phi(\Gamma_{ij}; \theta_m))^{Z_m^{(i, j)}} \right\} \quad (6)$$

其中 $Z_m^{(ij, l)}$ 定义为

$$Z_m^{(ij, l)} = \begin{cases} 1, & \Gamma_{(ij)l} \in m \\ 0, & \Gamma_{(ij)l} \notin m \end{cases} \quad (7)$$

模型参数为 $\theta = \{k, \alpha_1, \dots, \alpha_k, \theta_1, \dots, \theta_k\}$ 的对数似然函数为

$$\begin{aligned} \ell(\Gamma, \theta) = & \sum_{l \in D} \sum_{m=1}^k Z_m^{(ij, l)} \left[\log \alpha_m + \sum_{n=1}^M \log \phi(\bar{\gamma}_n^{(i, l)}; \theta_m) \right. \\ & \left. + \sum_{n=1}^M \log \phi(\bar{\gamma}_n^{(j, ?l)}; \theta_m) \right] \\ & + \sum_{m=1}^k Z_m^{(i, j)} \left[\log \alpha_m + \sum_{n=1}^M \log \phi(\bar{\gamma}_n^{(i, j)}; \theta_m) \right] \end{aligned}$$

同样对式(7)加入模型阶数惩罚, 运用 EM 算法可估计出 $\{Z_m^{(ij, l)}, m = 1, \dots, k\}$ 与 $\{Z_m^{(i, j)}, m = 1, \dots, k\}$, 这里我们设定只要满足 $Z_m^{(ij, l)} > 0.5$, 就认为 $\Gamma_{(ij)l}$ 属于分量集合 m . 设第 k 个分量为有限混合模型中均值最大的分量集合, 由于 $\langle i, j \rangle$ 为最大相关节点对, 则 Γ_{ij} 属于分量集合 k , 即 $Z_k^{(i, j)} > 0.5, Z_n^{(i, j)} \leq 0.5, n \neq k$, 由式(8)得 $\Gamma_{(ij)l^*}$ 也属于分量集合 k , 也即 $\gamma_{il^*} = \gamma_{jl^*} = \gamma_{ij}$, 则 l^* 必与节点对 $\langle i, j \rangle$ 有相同的父节点, 令 $Q = \{l^*\} \cup \{i, j\}$ 为 $a(i, j)$ 的所有叶子节点构成的集合, 满足 $a(i, j) = a(s, t), \forall s, t \in Q, \langle s, t \rangle \neq \langle i, j \rangle$.

$$l^* = \arg(\Gamma_k^{(ij, l)} > 0.5), l \in D, l \neq i, l \neq j \quad (8)$$

然后将 Q 中所有节点合并成新的叶子节点 h , 并计算 h 与 $\{g \in \bar{Q}, \bar{Q} = D \setminus Q\}$ 相关性采样集合 $\Gamma_{hg}, \Gamma_{hg} = \{(1/W) \sum_{s \in Q} \bar{\gamma}_n^{(s, g)}, n = 1, \dots, M\}$, W 为 Q 中叶子节点个数. 这样构造一个新的拓扑树, 然后继续寻找相关性最大的叶子节点对, 如此迭代, 直至所有叶子节点合并成一个节点为止.

以图 1 为例简述该过程, 假设找到 $(4, 5)$ 为最大相关节点对, 取 $\{\Gamma_{(45)l}, \Gamma_{4,5}\}$ 为 $\{(\Gamma_{4,1}, \Gamma_{5,1}), (\Gamma_{4,2}, \Gamma_{5,2}), (\Gamma_{4,3}, \Gamma_{5,3}), (\Gamma_{4,6}, \Gamma_{5,6}), (\Gamma_{4,7}, \Gamma_{5,7}), \Gamma_{4,5}\}$, 建立有限混合模型对 $\{(\Gamma_{(45)l}, \Gamma_{4,5}), l \in D, l \neq 4, 5\}$ 聚类, 得到满足式(8)的 l^* 为节点 6, 然后将节点 4, 5, 6 合并, 记为节点 8, 并求取节点 8 与其余叶子节点的相关性, 得到新的叶子节点集合, 接着继续寻找新的叶子节点集合中的最大相关节点对, 如此迭代, 直至合并得到节点 0 为止. 该过程的结果可用图 2 表示.

AHT 算法的步骤归纳如下:

Input: $D, V = \{0\} \cup D, \Gamma, E = \emptyset$

$D' \leftarrow D, N \leftarrow |D'| + 1$

While $(|D'| > 1)$ do

Find $\langle i, j \rangle = \arg \max_{i, j \in D} (\bar{\Gamma}_{ij})$

在 Γ 中取 $\{\Gamma_{(ij)l}\}$ 建立有限混合模型, 估计与 i, j 属于同一父节点的叶子节点集合 Q

加入新节点 N , 计算 N 与 $D' \setminus Q$ 中节点的相关性 $\Gamma' = \{\Gamma_{hg}, g \in \bar{Q}\}$,

$\Gamma \leftarrow (\Gamma \setminus \{\Gamma_{ij}, \Gamma_{ik}, \Gamma_{jk}, k \in D'\}) \cup \Gamma'$

$D' \leftarrow (D' \setminus Q) \cup \{N\}, E \leftarrow E \cup \{(N, k), k \in Q\}, V \leftarrow V \cup \{N\}$

$N \leftarrow N + 1$

End while

$E \leftarrow E \cup \{(0, N)\}$

Output: $T = (V, E)$

其中 $\{0\}$ 表示根节点, D 为叶子节点集合, E 为边集合, V 为拓扑图中顶点集合, Γ 为叶子节点相关性集合, (N, k) 为节点 N 到节点 k 的边, \setminus 表示删除.

4.2 算法分析

由文献[11]得,有限混合模型第 m 个分量的 FIM (Fisher Information Matrix) 为 $I_m(\theta_m) = \sum_{i,j \in D, i < j} I_m^{(i,j)}(\theta_m)$, 其中 $I_m^{(i,j)}(\theta_m)$ 是第 m 个分量 ($\theta_m = (\mu_m, \sigma_m^2)$) 与 Γ_{ij} 有关的 FIM 信息

$$I_m^{(i,j)}(\theta_m) = \begin{bmatrix} \frac{\alpha_m N_{i,j}}{\sigma_m^2} & 0 \\ 0 & \frac{2\alpha_m N_{i,j}}{\sigma_m^2} \end{bmatrix}$$

令

$$T(\theta_m) = \begin{bmatrix} \frac{\alpha_m}{\sigma_m^2} & 0 \\ 0 & \frac{2\alpha_m}{\sigma_m^2} \end{bmatrix}$$

得 $I_m(\theta_m) = \sum_{i,j \in D, i < j} N_{ij} T(\theta_m)$, 又有 $|\Gamma_{ij}| = |\Gamma_{kl}| = N_{ij} = M$, $|\cdot|$ 表示 \cdot 中的元素个数, 其中 $i, j, k, l \in D$ 且 $i \neq j, k \neq l$. 则 $I_m(\theta_m) = M \sum_{i,j \in D, i < j} T(\theta_m)$.

由于 HTE 算法采用最大似然估计, 故 $\hat{\theta}_m$ 服从正态分布, 即 $\hat{\theta}_m \sim N(\theta_m, I_{\text{HTE}}^{-1}(\theta_m))$, 其中 $I_{\text{HTE}}^{-1}(\theta_m)$ 为 HTE 算法关于 $\hat{\theta}_m$ 的渐进方差

$$I_{\text{HTE}}^{-1}(\theta_m) \approx \left(\sum_{i,j \in D, i < j} T(\theta_m) \right)^{-1} / M \quad (9)$$

可见 M 越大, $\hat{\theta}_m$ 的渐进方差越小, 估计越准确. 在 AHT 算法中, 我们构造 $\Gamma_{(ij)l} = (\Gamma_{il}, \Gamma_{jl})$, $|\Gamma_{(ij)l}| = 2|\Gamma_{ij}| = 2M$, $l \in D, l \neq i, l \neq j$. 得到 AHT 算法 $\hat{\theta}_m$ 最大似然估计的渐进方差近似为

$$I_{\text{AHT}}^{-1}(\theta_m) \approx \left(\sum_{i,j \in D, i < j} T(\theta_m) \right)^{-1} / 2M < I_{\text{HTE}}^{-1}(\theta_m) \quad (10)$$

可见在 M 较大时, AHT 算法聚类参数的渐进方差小于 HTE 算法, 故其聚类准确度高于 HTE 算法, 具有更高的拓扑推断精度.

5 仿真实验与结果分析

实验 1

本实验比较不同方差因子条件下 ALT、HTE、AHT 三种算法的拓扑推断性能.

仿真设置: 本文采用与文献[11]中相同的拓扑结构, 如图 4 所示. 对于每一对叶子节点 (i, j) , 用 Matlab 生成满足单调性和一致性条件的 $N = 200$ 个节点相似度采样数据. 这些采样数据为节点对共享链路上的所有子链路的测度数据之和. 每条子链路的测度数据服从均值为 γ_l , 方差为 σ_l 的高斯分布. 其中 $\gamma_l \sim \text{uniform}(1, 5)$, $\sigma_l = \alpha(1/\sqrt{2})$, α 为方差因子, $M = 10$, $N_{\text{nom}} = N/M = 20$. 本实验检验 ALT、HTE、AHT 三种算法在方差因

子 α 从 1 到 7 的拓扑推断性能. 鉴于文献[7, 11~14]都使用树编辑距离评价拓扑推断性能, 故本文使用推断拓扑与原拓扑的树编辑距离评价算法性能. 树编辑距离^[11, 20]定义为从一个树图映射到另外一个树图所需的编辑操作之和, 表征两个树图的相似程度, 树编辑距离越小, 表示两个树图的相似程度越大, 即推断树状拓扑与原树状拓扑的树编辑距离越小, 拓扑推断的效果越好.




图4 仿真使用的逻辑拓扑

图 5 为三种算法随着方差因子增大的树编辑距离性能, 每个方差因子下独立进行 1000 次蒙特卡罗实验. 由图中结果可得, AHT 算法和 HTE 算法的树编辑距离性能均优于 ALT 算法; 在方差因子较小时, HTE 算法有着最好的性能, 而随着方差因子增加 AHT 算法显示出其优势, 在方差因子较大时, AHT 算法的性能明显优于其它两种算法. HTE 和 AHT 都是基于有限混合模型的算法, 在方差因子较小时, 由于 HTE 算法应用了基于图论的 HCS 分类方法, 具有更高的稳健性, 因此在方差因子较小时其推断性能会优于 AHT 算法, 而在方差因子较大时这种稳健性不再起决定性作用. 由第 4 节可知, AHT 算法建立了改进的有限混合模型, 相当于增加了采样数据, 混合模型参数的最大似然估计方差相应减小, 因此在方差因子较大时, 其有更高的拓扑推断精度.




图5 三种算法的推断性能比较

实验 2

本实验比较不同叶子节点数条件下 HTE 和 AHT 两种算法的拓扑推断时间性能.

仿真设置:遍历叶子节点数从 4 到 9 的所有树状拓扑,使用 Matlab 产生满足单调性和一致性条件的相应相似度采样数据,相似度采样数为 200,每个拓扑仿真 50 次,记录仿真时间求均值。

图 6 给出了 HTE 算法和 AHT 算法在不同叶子节点数条件下的平均运行时间,可见 AHT 算法的时间效率明显高于 HTE 算法。由于 AHT 算法每次聚类的有限混合模型仅使用与最大相关节点对有关的节点相关性数据,因此减小了运算量,其时间效率较 HTE 算法有明显提高。由图 6 可以看出,在节点数较少时,AHT 算法的优势不太明显,而随着节点数增加,AHT 算法的运行时间呈近似线性增长,HTE 算法的运行时间呈近似指数增长,因此网络叶子节点数较多时,AHT 算法优势更为明显。




图6 两种算法的运行时间比较

实验 3

本实验通过网络仿真软件 Opnet 产生网络采样数据,应用 ALT、AHT、HTE 算法推断网络拓扑。

仿真设置:网络拓扑如图 7 所示,节点 0 为源主机节点,其他叶子节点为目的主机节点,节点 16、17、18、19、20 为路由器节点,端节点与路由器之间的使用速率为 T1(1.544Mbit/s)的 PPP 链路,路由器之间的链路采用速率为 E1(2.6048Mbit/s)的 ATM 链路。模拟网络中配置五种业务:Database (medium load)、FTP (medium load)、Email (medium load)、Http (heavy browsing)、Print (text file),为使业务在网络中近似均匀分布,在每个路由器接入一个服务器,支持所有业务。应用三明治包^[8]方法进行叶子节点相关性采样,其中大包和小包分别为 100byte、10byte。在不同条件下分别独立仿真 1000 次。

图 8 给出了 ALT、HTE、AHT 三种算法在不同探测包数条件下的平均树编辑距离,可见,随着节点对探测包个数的增加三种算法的性能均有所提高,ALT 算法随探测包数目增加,性能改善比较明显。比较三种算法,AHT 算法的平均树编辑距离小于 HTE 算法和 ALT 算法,具有最好的拓扑推断性能。




图7 Opnet仿真拓扑图

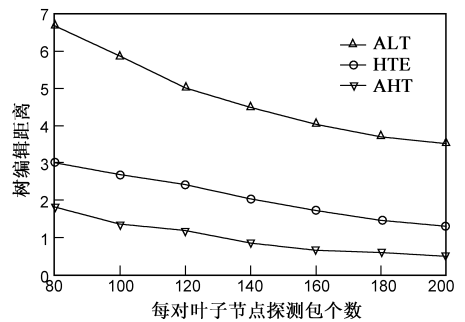


图8 三种算法在不同探测包个数下的性能

6 结论


本文通过分析 HTE 算法的不足,提出了自底向上合并的分层聚类拓扑推断算法,该算法建立了改进的有限混合模型,增加了参数推断的有效数据,提高了算法的参数估计精度,同时采用自底向上的分层聚类,每次聚类仅使用与最大相关节点对有关的数据,相对 HTE 算法降低了运算复杂度。目前有关层析成像拓扑推断算法的文献都仅针对小型网络进行了仿真实验,对于较大规模网络的应用尚未见报道,因此,层析成像拓扑推断算法在较大规模网络的应用是值得进一步研究的方向。

参考文献

- [1] Donnet D, Friedman T. Internet topology discovery: a survey [J]. IEEE Communications Surveys and Tutorials, 2007, 9(4): 2-15.
- [2] 姜誉,方滨兴,胡铭曾. 大型 ISP 网络拓扑多点测量及其特征分析实例[J]. 软件学报, 2005, 16(5): 846-856.
Jiang Yu, Fang Bin-xing, Hu Ming-zeng. An example of analyzing the characteristics of a large scale ISP topology measured from multiple vantage points[J]. Journal of Software, 2005, 16(5): 846-856. (in Chinese)

- [3] 张国强, 张国清, 范晶. 中国大陆 AS 级拓扑的测量与分析[J]. 通信学报, 2007, 28(10): 92 – 101.
Zhang Guo-qiang, Zhang Guo-qing, Fan Jing. Measurement and evaluation of mainland China AS-level topology[J]. Journal on Communications, 2007, 28(10): 92 – 101. (in Chinese)
- [4] Duffield N, Presti F L. Network tomography from measured end-to-end delay covariance[J]. IEEE/ACM Transactions on Networking, 2004, 12(6): 978 – 992.
- [5] Coates M, Hero A, Nowak R, Yu B. Internet tomography[J]. IEEE Signal Process Magazine, 2002, 19(3): 47 – 65.
- [6] Krishnamurthy A, Singh A. Robust multi-source network tomography using selective probes[A]. Proceedings of the 31st Annual IEEE International Conference on Computer Communications (IEEE INFOCOM 2012) [C]. Piscataway, N J, USA: IEEE Press, 2012. 1629 – 1637.
- [7] 赵洪华, 陈鸣. 基于网络层析成像技术的拓扑推断[J]. 软件学报, 2010, 21(1): 133 – 146.
Zhao Hong-hua, Chen Ming. Topology inference based on network tomography[J]. Journal of Software, 2010, 21(1): 133 – 146. (in Chinese)
- [8] Duffield N, Horowitz J, Presti F L, Towsley D. Multicast topology inference from measured end-to-end loss[J]. IEEE Trans on Information Theory, 2002, 48(1): 26 – 45.
- [9] Duffield N, Horowitz J, Presti F L. Adaptive multicast topology inference[A]. Proceedings of the 20th Annual Joint Conference of the IEEE Computer and Communications Societies (IEEE INFOCOM 2001) [C]. Piscataway, N J, USA: IEEE Press, 2001. 1636 – 1645.
- [10] 李勇军, 蔡皖东, 田广利. 基于端到端报文丢失的网络拓扑推测算法研究[J]. 通信学报, 2007, 28(10): 85 – 91.
Li Yong-jun, Cai Wan-dong, Wang Wei, Tian Guang-li. Research on network topology identification algorithm based on end-to-end loss performance[J]. Journal on Communications, 2007, 28(10): 85 – 91. (in Chinese)
- [11] Shih M F, Hero A. Hierarchical inference of unicast network topologies based on end to end measurements[J]. IEEE Trans on Signal Processing, 2007, 55(5): 1708 – 1718.
- [12] 赵洪华, 丁科, 陈鸣. 采用单测量源的拓扑推断算法[J]. 电子科技大学学报, 2010, 39(2): 275 – 278.
Zhao Hong-hua, Ding Ke, Chen Ming. Topology inference algorithm by using one measuring node[J]. Journal of University of Electronic Science and Technology of China, 2010, 39(2): 275 – 278. (in Chinese)
- [13] 赵洪华, 陈鸣. 利用往返时延抖动的网络拓扑推断算法[J]. 西安交通大学学报, 2009, 43(6): 28 – 31.
Zhao Hong-hua, Chen Ming. A topology inference algorithm using round delay variation[J]. Journal of Xi'an Jiaotong University, 2009, 43(6): 28 – 31. (in Chinese)
- [14] 赵洪华, 胡谷雨, 倪桂强, 沙俊星. 基于四元分组测量的网络拓扑推断算法[J]. 北京邮电大学学报, 2012, 35(2): 126 – 130.
Zhao Hong-hua, Hu Gu-yu, Ni Gui-qiang, Sha Jun-xing. A network topology inference algorithm based on 4-tuple packets measurement[J]. Journal of Beijing University of Posts and Telecommunications, 2012, 35(2): 126 – 130. (in Chinese)
- [15] Castro R, Coates M, Nowak R. Likelihood based hierarchical clustering[J]. IEEE Trans on Signal Processing, 2004, 52(8): 2308 – 2321.
- [16] Jian Ni, Haiyong Xie, Sekhar Tatikonda, Yang Richard Yang. Efficient and dynamic routing topology inference from end-to-end measurements[J]. IEEE/ACM Transactions on Networking, 2010, 18(1): 123 – 135.
- [17] Fei G, Hu G. Improving maximum-likelihood-based topology inference by sequentially inserting leaf nodes[J]. IET Commun, 2011, 5(15): 2221 – 2230.
- [18] 雍兴辉, 黄永峰. P2P 流媒体系统中层次化网络拓扑推断技术的研究[J]. 电子学报, 2010, 38(1): 1 – 5.
Yong Xing-hui, Huang Yong-feng. Network topology hierarchy inference on P2P media streaming system[J]. Acta Electronica Sinica, 2010, 38(1): 1 – 5. (in Chinese)
- [19] Xian Zhang, Chris Phillips. A survey on selective routing topology inference through active probing[J]. IEEE Communications Surveys & Tutorials, 2012, 14(4): 1129 – 1141.
- [20] Zhang K, Shasha D Simple fast algorithms for the editing distance between trees and related problems[J]. SIAM J Comput, 1989, 18(6): 1245 – 1262.

作者简介



张润生 男, 1984 年生于河北保定, 现为中国电子科技集团公司第 54 研究所博士研究生. 主要研究方向为网络测量、网络拓扑推断.
E-mail: zhang_runsheng@163.com

李艳斌 男, 1966 年生于河北石家庄, 现为中国电子科技集团公司首席专家, 博士生导师. 主要研究方向为电子对抗总体技术.

李啸天 男, 1986 年生于河北石家庄, 现为中国电子科技集团公司第 54 研究所博士研究生. 主要研究方向为纠错码盲识别、网络测量.