

流量矩阵估计研究综述^{*})

蒋定德 胡光岷

(电子科技大学宽带光纤传输与通信网技术重点实验室 成都 610054)

摘要 随着 Internet 网络的快速发展,网络操作员迫切需要知道网络中数据的流动情况,以便更好地进行网络管理、网络监控、网络设计和网络规划等网络流量工程管理。流量矩阵作为网络流量工程的重要输入参数,已受到国内外研究人员的广泛研究,现已成为 Internet 的一个重要研究方向。本文介绍流量矩阵研究的现状,并从性能上分析和比较各种研究方法,最后讨论流量矩阵研究的技术难题,并指出新的发展方向。

关键词 流量矩阵,网络层析成像,SNMP,统计反演

Overview of the Traffic Matrix Estimation Research

JIANG Ding-De HU Guang-Min

(Key Laboratory of Broadband Optical Fiber Transmission and Communication Networks, UESTC, Chengdu 610054)

Abstract With the fast development of Internet network, network operators urgently want to know how the data in their network flow in order better to make network management, network monitoring, network designing and network planning and so on. Traffic matrix, as an important input of network traffic engineering, is widely researched by the worldwide researchers and becomes currently an important research area of Internet. This paper introduces the current research situations about traffic matrix, and analyses and compares the research methods about traffic matrix. Finally, we discuss the technologic difficulty of traffic matrix research, and point out the new development about traffic matrix.

Keywords Traffic matrix, Network tomography, SNMP, Statistical inference

1 引言

随着 Internet 网络的快速发展,网络的规模越来越复杂,控制和管理网络的难度随之增大。为了更好地进行网络管理、网络监控、网络设计和网络规划等网络流量工程,网络操作员迫切需要掌握有关网络数据的流动情况。流量矩阵作为网络流量工程的重要输入参数,已受到国内外研究人员的广泛研究,现已成为 Internet 的一个重要研究方向。流量矩阵(Traffic Matrix, TM)表示了网络中任意 OD(Origin-Destination)对(或流,或节点)之间的流量,描述了网络流量在各个 OD 对间的分布情况。OD 节点可以是链路(Link-to-Link)、路由器(Router-to-Router),也可以是 POP(Point-of-Presence)^[9~11,13,14,19]。针对不同的 OD 节点,流量矩阵可以是基于链路、路由器或 POP 的不同流量矩阵,从而可以提供不同的流量矩阵应用,以便为人们进行与网络流量相关的管理、监控工作提供有力的参考依据。

网络流量矩阵的获得^[16],按测量的协作方式可分为主动测量和被动测量,按测量的情况可分为直接测量和间接测量。在现有的复杂异构网络环境中,功能相近或相似的网络设备往往由不同的网络设备商提供。由于不同厂商的实现技术不一样,彼此之间很难相互协作。特别是网络中的核心路由器,即使它们之间有相互协作能力,也会因为引入直接测量而增加设备的负担,从而影响整个网络的性能。因而,直接测量尽管是一种很简单的方式,但是在具体实施时却很难实现,甚至是不可行的。为了获得网络的流量情况,研究人员将目光转移到了间接测量的方式上。间接测量是目前获得网络流量矩

阵的主要方式,它回避了直接测量所遇到的种种困难,采取迂回的方式来获得网络的流量矩阵,从而为网络流量工程分析人员提供有力的帮助。因而,流量矩阵在网络上并不容易直接获得,针对现有网络设备很少对网络流量矩阵的测量提供协作方式,网络流量的获取以被动测量和间接测量为主。从源节点出发的网络流量通过路由策略被转发到目的地,各个 OD 流在它所经过的链路上汇聚,而汇聚情况取决于网络拓扑结构和路由转发策略。尽管流量矩阵不容易直接获得,但是各个链路流量是很容易通过测量得到的。所以,流量矩阵、路由策略、链路流量之间存在某种关系,这种关系可以由一个线性等式来描述:

$$y = Ax \quad (1)$$

其中, y 是一个列向量,表示链路流量; x 也是一个列向量,表示流量矩阵; A 表示路由矩阵, A 可表示为 $A = \{a_{ij}\}$, a_{ij} 为路由矩阵 A 的元素。如果 OD 流 j 通过链路 i ,则 $a_{ij} = 1$,否则 $a_{ij} = 0$ 。一般地,(1)式中的 y 和 A 较容易获得; y 可以通过 SNMP(Simple Network Management Protocol)测量得到, A 可以通过路由策略和网络拓扑获得。可见,流量矩阵的求解是一个线性反问题求解过程。但是,由于实际网络中链路测量数远小于 OD 流数,这使得路由矩阵 A 远不是满秩的,故而所面对的问题就是欠定的、病态系统的反问题求解,即流量矩阵的估计问题。流量矩阵估计是一个复杂的问题,网络层析成像是解决这类问题的一种好方法^[1~14]。

本文介绍流量矩阵估计和分析的现状,并简要分析各种方法的性能,最后讨论流量矩阵研究的技术难题,并指出新的发展方向。

^{*}) 本文得到国家自然科学基金(No. 60572092)资助。蒋定德 博士生,研究方向为现代信号处理、计算机网络。

2 流量矩阵研究现状

在流量矩阵估计的发展历程中,对(1)式所描述的反问题求解,人们提出了许多研究方法,主要有如下三类。

2.1 统计反演方法

在1996年,Vardi^[2]首先提出使用网络层析成像来解决(1)式所描述的反问题,但是他把OD流建模为简单的泊松分布(Poisson)。随后Tebaldi等人^[3]使用贝叶斯方法来求解流量矩阵。在2000年,Cao等人在Vardi的基础上,将OD流建模为高斯分布(Gaussian),并运用EM算法^[4,25]和IPFP方法^[27]来求解流量矩阵。以上这一类方法是以统计数学^[17]和矩阵理论^[18]为基础,运用层析成像反演方法来求解网络流量矩阵,把它称为统计反演方法,其主要特点是:1)引入与OD流二阶矩相关的限制条件来求解欠定问题;2)对OD流使用简单模型,如泊松分布(Poisson)、高斯分布(Gaussian),在这些模型中,不包含OD流的时间和空间相关性;3)这些方法对OD流的先验值很敏感^[13,14]。

2.2 附加链路测量信息反演方法

Zhang^[9~11]、Nucci^[20]、Soule^[21]等人使用链路测量信息来作为流量矩阵反演的附加信息,从而有利于更精确地获得流量矩阵的估计值。这一类方法称为附加链路测量信息反演方法,其特点是:1)利用SNMP数据中的附加信息;2)用这个附加的测量数据来校正OD流模型;3)校正模型被用于估计过程中。Gunnar等人^[22]把这种方法和第一类方法进行了比较分析。这一类研究方法大致可以分为两类:层析成像重力模型方法(TomoGravity Method)^[9~11]和路由改变方法(Route Change Method)^[20,21]。

层析成像重力模型方法把层析成像和重力模型^[24]结合起来,从而达到较好的估计结果。重力模型捕获了OD流的流量特征,在文[9~11]中假设输入输出节点是独立的,并使用来自访问链路(access links)和对等链路(peering links)的SNMP数据来校正重力模型,这些校正数据与估计中来自骨干网路由器间的SNMP数据是不同的。在文[11,12]中,作者采用信息理论知识来反演流量矩阵。

层析成像重力模型方法通过用重力模型方法建立流量矩阵的初始值来进行流量矩阵的估计。重力模型可表示为^[9,13]

$$x(i, j) = x(i, *) \frac{x(*, j)}{\sum_j x(*, j)} \quad (2)$$

其中 $x(i, *)$ 表示流入节点 i 的总流量(如果节点 i 为路由器,则为所有与该路由器相连的访问链路和对等链路上的流入流量); $x(*, j)$ 表示流出节点 j 的总流量(如果节点 j 为路由器,则为所有与该路由器相连的访问链路或对等链路上离开网络的流出流量)。(2)式表明节点 i 发送到节点 j 的总流量与在节点 j 离开网络的流量成正比,与离开整个网络的总流量成反比,在文[9]中作者把这称为简单重力模型。这个模型实质上假设源节点和目的节点之间完全独立。然而,在IP骨干网上,有两种策略打破了这种假设:1)由于hot potato路由策略,从用户传送到对等点的流量将发送到最近的离开点;2)没有通过网络从一个对等网络传到另一个对等网络的流量^[13]。

因而,在文[9]中作者定义广义重力模型来捕获这些策略特征。这可以解释为源和目的节点之间是条件独立的,这被用在识别链路类型的附加信息上。广义重力模型可表示为^[9,13]

$$x'(i, j) = \begin{cases} 0, & i \in P, j \in P \\ \frac{x(i, *)}{\sum_{i \in Q} x(i, *)} x(*, j), & i \in Q, j \in P \\ x(i, *) \frac{x(*, j)}{\sum_{j \in Q} x(*, j)}, & i \in P, j \in Q \\ \rho \frac{x(i, *)}{\sum_{i \in Q} x(i, *)} x(*, j), & i \in Q, j \in Q \end{cases} \quad (3)$$

其中 Q 表示访问链路集合, P 表示对等链路集合, ρ 是一个标准化常量^[9]。

层析成像重力模型方法使用的是一个空间模型,它描述了OD流间的关系。重力模型实质上捕获了一个节点到每个节点的流量比,到一个源节点的流量仅仅是发送到该指定节点总流量的一部分。因此,尽管重力模型假设节点间是独立的或条件独立的,但是它并没有假设OD流间的独立性,所有从同一个源流出的OD流是相互依赖的,因为要求从同一个源流出的流量比之和为1,即描述了OD流在空间上的相关性。

路由改变方法^[20,21]的主要思想就是改变链路权值,从而达到改变路由的目的,使OD流在不同的路径上流动。通过这样足够多次地改变路由,从而增加路由矩阵的秩,使路由矩阵尽可能达到满秩或近似为满秩。然后根据每一次路由改变后新的路由矩阵来收集路由器件间SNMP数据,路由改变方法使用所有收集的数据来校正附加噪声的OD流模型。这是一个动态模型,它捕获OD流随时间的变化情况。这种方法同时在两个方面解决系统的病态特性:一方面增加路由矩阵的秩;另一方面使用改善的OD流模型(如式(4)所示)。这个模型没有捕获OD流在空间上的关系,只是OD流的时间模型^[7]。

在路由改变方法^[19,20]中,作者在假设每日流量图形为周期静态、波动过程为具有协方差矩阵 Q 的零均值静态过程的前提下,将OD流模型表示为

$$x(i, j, t) = \sum_h \theta_h(i, j) b_h(t) + w(i, j, t) \quad (4)$$

其中第一项是傅里叶扩展,第二项是静态波动。 $b_h(t)$ 表示第 h 个基函数, $\theta_h(i, j)$ 对应于源节点为 i 、目的节点为 j 的OD对的系数。为了把路由变化和OD流时间模型联系起来,作者扩展系统 $y = Ax$,其中路由矩阵现在是时间的函数,并被修改为包括许多合并不同路由映射的块矩阵。此时,一阶统计估计是对每日流量图形的估计,即在等式(4)中的 θ_h ,二阶统计估计则为对波动过程协方差 Q 的估计。

2.3 测量反演结合方法

随着近年来流量监测技术的发展,流量矩阵研究人员发现,如果充分利用流量监测中的测量数据,将大大降低流量矩阵估计的误差,从而产生了第三类研究方法,即测量反演结合方法,其特点是:1)通过直接测量而不是通过假设捕获OD流的时间和空间相关性;2)通过这些直接测量获得的数据来校正模型;3)校正后的模型反过来被用于流量矩阵的估计。有四类这样的方法:Fanout方法^[23];PCA方法(Principal Component Analysis method)^[26];Kalman滤波方法(Kalman Filtering method)^[15];PamTram(Partial Measurement of Traffic Matrices)方法^[28]。

2.3.1 Fanout 方法

Fanout方法^[23]是一种纯数据派生的方法,它只依赖于对OD流的直接测量来获得流量矩阵,没有使用路由矩阵,没有进行反演计算,只需要简单的线性计算即可。一个节点的Fanout被定义为向量,它表示了每个节点转发到网络中每个

输出节点的流量部分,其中节点可以是一个 PoP、一个路由器,或一条链路。令

$$f(i, j, t) = \frac{x(i, j, t)}{\sum_j x(i, j, t)} \quad (5)$$

表示 t 时刻在节点 i 流入网络,在节点 j 流出网络的流量占 t 时刻在节点 i 流入网络总流量的比值,则一个节点的 BaseFanout 可以定义为 t 时刻的向量: $f(i, *, t) = \{f(i, j, t) \mid \forall j\}$ 。在文[22, 23]中,作者各自独立地发现:节点 Fanout 表现出很强的以每日为周期的图形,并且以一天为周期来说,是很容易预测的。节点 Fanout 的这种稳定性意味着:节点 i 在某一时刻的 Fanout 可以用来预测在随后几天中同一时刻的流量矩阵的第 i 行。

在初始化时, Fanout 方法让流量监视器在 24 小时内一直开着,利用来自流量监视器的数据,可以计算每一个节点的 BaseFanout。假设流量监视器每 10 分钟测一次 OD 流,则在 24 小时周期内有 144 个测量间隔。在给定一天中每 10 分钟窗口内 Fanout 的情况下,使用第一天在一个特别时刻 t 的 Fanout 来预测其他天在同一时刻 t 的流量矩阵,则流量矩阵的估计值可以表示为^[23]

$$\hat{x}(i, j, t) = \hat{f}(i, j, t)x(i, *, t) \quad (6)$$

其中 $x(i, *, t)$ 表示流入节点 i 的总流量。 $x(i, *, t)$ 可以通过在节点 i 求所有访问输入链路和对等输入链路上的 SNMP 链路测量值之和而获得,因而可以仅仅通过 Fanout 值乘以 SNMP 链路测量值来获得流量矩阵的估计值。

流量矩阵是一个动态变化的实体, Fanout 在时间上将会发生变化,因此这种方法应该包括一种启发式算法来侦测 Fanout 在时间上的变化。一旦侦测到 Fanout 发生变化,以前的 Fanout 就不能用于新的 OD 流估计,就需要重新校正流量模型,获得新的 Fanout,以保证准确进行新的流量矩阵的估计。这就需要在下一个 24 小时内进行网络流量的直接测量。这种启发式算法过程如下:

1) 每个节点在下一个 24 小时内随机选择一个 10 分钟的间隔,并只对此间隔重新计算其 Fanout。

2) 计算在新测出的 Fanout 向量和对应于以前的在同一 10 分钟间隔内的 Fanout 向量之间的变化。节点 i 在 t 时刻 Fanout 的变化量定义为: $\Delta(i, *, t) = \|\hat{f}(i, *, t) - f(i, *, t)\|$ 。

3) 如果 $\Delta(i, j, t) > \delta f_{i, j, t}$, 则表示该节点 i 的 Fanout 已发生了变化,需要对任意一个随机选择的时间间隔,在随后的 24 小时内重新测量该节点 i 的 BaseFanout 向量 $f(i, *)$ 。否则,返回到步骤 1), 整个过程重新迭代。

Fanout 方法的一个优点是降低了通信开销,因为基于节点 Fanout 扇出稳定性的观察结果,通常是每隔几天只发送一次节点 Fanout 到 NOC(Network Operations Center),而不是每 10 分钟发送一次,而且 OD 流监测器不需要一直开着,只在需要的时候才打开。另外,检查 Fanout 发生变化只在每一个节点的基础上进行,如果在一个节点发现 Fanout 发生变化,则只在该节点重新开始流量收集,不需要大范围的流量数据收集。采取 Fanout 方法,只有流量矩阵发生动态变化的部分才需要重新校正。Fanout 方法通过节点 Fanout 来对 OD 流建模,如式(5)所示,这种模型与重力模型一样,是一个空间模型,因为共同源节点的 Fanout 是相关的,它要求源节点的 Fanout 和必须为 1。类似地,有着共同目的节点的 OD 流也存在相关性。然而由等式(6)可知,这种模型也是一种时间模

型,因为估计值依赖于 Fanout 的历史值,所以 Fanout 模型对 OD 流建立起了时间空间相关性^[13]。

2.3.2 PCA 方法

PCA 方法以主成分分析方法和矩阵理论分析^[18]为基础,通过研究 OD 流集合的主要成分,即特征流向量,由其特征流向量来表示 OD 流集合,从而将流量矩阵估计问题转化为求其特征流向量的问题。通常特征流向量的维数比 OD 流集合的维数要小得多,这样通过降维的方法,降低了问题的难度,易于求解 OD 流的估计问题。在文[13, 26]中,作者使用 PCA 方法来研究 OD 流估计问题。PCA 方法的基本思想就是:不是估计所有的 N 个 OD 流,而是仅仅估计 k 个最重要的特征流。因为 $k \ll N$, 所以从链路流量估计特征流的问题就变成了非病态系统的问题。PCA 方法的整个算法流程表示如下:

1) 由初始流量矩阵 X_0 , 求分解式 $X_0 = USV^T$, 获得交换矩阵 V 和 S (或 V' 和 S')。其中 X_0 表示为 $T \times N$ 的多元 OD 流时间序列, U 是 $T \times N$ 本征流时间序列矩阵, V 是 $N \times N$ 主要部分作为其列的矩阵, S 是 $N \times N$ 的奇异值对角矩阵。

2) 判断是否校正 PCA 模型, 是则进行步骤 1), 更新 PCA 模型 V 和 S (或 V' 和 S') 矩阵, 否则转入步骤 3)。

3) 将流量矩阵 X 表示为 $T \times N$ 的多元 OD 流时间序列, 则用 PCA 方法可以把流量矩阵 X 表示为^[13, 26]

$$X = USV^T$$

4) 选择顶部 k 个主要部分来降低维数。把 t 时刻所有的流量近似为

$$x_t \approx V'S'u'_t, t=1, 2, \dots, T$$

其中 u'_t 是 t 时刻 k 个最重要特征流的值组成的向量。

5) 由链路测量值 y_t 估计顶部 k 个特征流 u'_t , 且有 $y_t \approx AV'S'u'_t, t=1, 2, \dots, T$ (8)

由于 u'_t 的维数是很小的, 因此等式(8)是良性估计问题。要求解 u'_t , 使用 $AV'S'$ 的伪逆来获得估计值 $\hat{u}'_t$ 。

6) 利用等式(7)计算流量矩阵的估计值 $\hat{x}_t$ 。把 $\hat{x}_t$ 中为负项项设为零, 并依靠 IPF (iterative proportional fitting) 算法^[27]来求得估计值, 它满足限制条件 $y = Ax$ 。

流量矩阵在时间上可能发生变化, 从而交换矩阵 V 和 S (或 V' 和 S') 也将发生变化, 因此为了保证流量矩阵估计的正确性, PCA 方法需要有一个校正过程。重校正步骤分为两个部分^[13]: 决定什么时候触发整个流量矩阵的重测量; 更新 PCA 模型 V 和 S (或 V' 和 S') 矩阵。校正过程表示如下:

1) 由流量矩阵估计值得到链路估计值 $\hat{y}_t = A\hat{x}_t$ 。其中 $\hat{x}_t$ 是在 t 时刻流量矩阵的估计值。

2) 求最大相对误差:

$$\epsilon_t = \max_i \left| \frac{y_t - A\hat{x}_t}{y_t} \right|$$

其中 y_t 是 t 时刻所有链路上的测量值, ϵ_t 是在所有链路上的最大相对误差。

3) 在 24 小时内检查 ϵ_t , 只有当在连续时间段 h 内 $\epsilon_t > \delta$ (δ 是一个误差门限参数), 且 $h/24 > k$ (h 为小时数) 时才进行新的 OD 流测量过程。如果 δ 和 k 较小, 则校正过程将频繁触发; 如果 δ 和 k 较大, 则校正过程将发生得少一些。在文[26]中把它们分别设为 $\delta = 0.9$ 和 $k = 0.5$, 即如果相对误差大于 90% 且持续半天, 则触发校正过程。

4) 如果校正过程被触发, 则在下一个 24 小时内对整个流量矩阵重新进行测量, 获得流量矩阵测量值 X_0 , 并利用矩阵分解获得新的 V 和 S (或 V' 和 S')。

PCA 模型表示了整个 OD 流在长时间上的相关性,如式(7)所示。同时,PCA 模型也表示了 OD 流在空间上的相关性,在 PCA 模型中,每个 OD 流被分解为特征流的加权和,这些特征流就是要估计的未知量。估计过程分别考虑每个时间点来决定特征流的值,表示 OD 流间相关性的权值由 V 和 S (或 V' 和 S') 来指定^[26],并利用 24 小时对流的直接测量来校正。因此,PCA 模型体现了 OD 流的时间和空间相关性,并且估计过程只是一个简单的伪逆求解过程。

2.3.3 Kalman 滤波方法

Kalman 滤波是信号自适应滤波中的一种重要处理方法,是一种强有力的方法,不仅用于估计而且也用于预测。在流量矩阵估计中,使用 Kalman 滤波方法^[15]的主要思想是:以矩阵理论分析^[18]为基础,利用动态线性系统理论的状态空间模型来表示系统的变化,把 OD 流看作网络流量系统的基本状态。由于 OD 流在时间上是变化的,因此状态空间在时间上也是变化的。令 y_t 表示时刻 t 的观测向量, $Y_t = \{y_t\}$ 表示所有到 t 时刻的观测值集合。向量 $x_t = \{x(i, j, t) \mid \forall i, \forall j\}$ 表示时刻 t 时 OD 流的整个集合,也表示时刻 t 时系统的状态。则状态空间可以表示为如下模型:

$$x_{t+1} = Cx_t + w_t$$

其中 C 是状态传输矩阵, w_t 是流量系统的噪声。 C 的对角线元素表示了流量变化中的时间相关性; C 的非对角线元素表示了 OD 流间的空间相关性。噪声过程 w_t 表示了 OD 流中的波动变化。可见该模型表示流量矩阵的时间和空间的相关性^[13]。

链路测量值 y_t 与流量矩阵 x_t 的关系可以表示为

$$y_t = Ax_t + m_t$$

其中 m_t 项代表附加的测量噪声。

令 $\hat{x}_{t|t-1}$ 表示基于所有到 $t-1$ 时刻的信息对 t 时刻 x_t 的预测, $\hat{x}_{t|t}$ 表示 t 时刻 x_t 的估计值,则在给定观测集合 $(y_1, \dots, y_{t+1})$ 的条件下,确定 $\hat{x}_{t+1|t+1}$ (简称为 $\hat{x}_{t+1}$)。 t 时刻的估计误差由 $\hat{x}_{t|t} - x_t$ 给出。误差方差由下式给出:

$$E[\|x_{t+1} - \hat{x}_{t+1}\|^2] = E[(x_{t+1} - \hat{x}_{t+1})^T (x_{t+1} - \hat{x}_{t+1})]$$

令 $P_{t|t} = E[(\hat{x}_{t|t} - x_t)(\hat{x}_{t|t} - x_t)^T]$ 表示 t 时刻误差的协方差矩阵。假设状态噪声 W 和测量噪声 M 都是零均值白噪声过程,而且是不相关的,协方差阵分别为 Q 和 R 。系统状态的初始条件由 $x_{0|0} = E[x_0]$ 和 $P_{0|0}$ 表示,则 Kalman 滤波算法可以表示如下^[13,15]:

1) 由直接测量获得的初始流量矩阵 X_0 和初始条件 $x_{0|0} = E[x_0]$ 和 $P_{0|0}$, 并利用 EM 算法获得矩阵 C, Q, R ^[25]。

2) 判断是否需要校正过程,如需要则重新进行 OD 流测量,转入 1), 否则转入 3)。

3) 预测过程。由 t 时刻信息预测 $t+1$ 时刻的状态和方差:

$$\begin{cases} \hat{x}_{t+1|t} = C\hat{x}_{t|t} \\ P_{t+1|t} = CP_{t|t}C^T + Q \end{cases}$$

4) 估计过程。结合预测状态和观测值 Y_{t+1} 来更新状态和方差:

$$\begin{cases} \hat{x}_{t+1|t+1} = \hat{x}_{t+1|t} + G_{t+1}[y_{t+1} - A\hat{x}_{t+1|t}] \\ P_{t+1|t+1} = (I_d - G_{t+1}A)P_{t+1|t}(I_d - G_{t+1}A)^T + G_{t+1}RG_{t+1}^T \end{cases}$$

其中 I_d 为单位阵, G_{t+1} 称为 Kalman 增益矩阵 (gain matrix)。由上式可知, Kalman 滤波方法具有自我校正特性,因而它具有自适应性。

由于流量矩阵在时间上是变化的,因而 Kalman 滤波方

法也需要校正过程,以保证基本状态空间模型适应流量矩阵的变化。其校正过程如下^[13,15]:

(1) 计算误差: $i_{t+1} = y_{t+1} - A\hat{x}_{t+1|t}$ 。

(2) 在每 10 分钟的时间间隔内,计算 i_t 并检查它是否超过门限(把误差方差的两倍用作门限值,如 $2 \times \text{Adiag}(P_{t|t})$)。24 小时内,在每条链路上都这样做,在 24 小时结束时,检查这些误差的百分之几超过了这个门限。如果误差的 10% 以上超过门限,则在整个网络上进行 24 小时的流量测量。在 24 小时结束时,使用所测的流量矩阵校正 C, Q, R 。

由上面分析可知, Kalman 滤波方法不仅建立了 OD 流的空间时间模型,而且具有自我校正特性。因而, Kalman 滤波方法充分利用了 OD 流的时间空间相关性,能够对 OD 流产生准确的估计值,并具有自适应性。

2.3.4 PamTram 方法

这种方法与以前所有的方法都不同,它仅仅利用单条或几条 OD 流的测量值来估计流量矩阵。其基本思想是:在每次估计间隔内只选择少量能提供信息的 OD 流来进行测量,为了避免优化选择的沉重计算,使用来自博弈论的直觉来开发随机选择规则,目的是为了降低错误和适应流量的变化。在文^[28]中,作者证明,为了显著降低误差,在每个测量期间仅仅测量一条 OD 流是足够的,因而在测量开销方面,该方法成为一种轻量级的方法;在最小均方误差意义上, IPF (Iterative Proportional Fitting) 算法近似于流量矩阵估计,这使该方法在计算开销方面是一种轻量级的方法。

3 性能分析

3.1 对先验值的敏感性

第一类方法对先验值是很敏感的,好的先验值和差的先验值对估计结果将会产生很大的差别。如在文^[13,14]中,作者证明在差的先验值条件下,贝叶斯估计产生的平均误差将会比好的先验值差 50% 左右。在第一类方法中,贝叶斯估计比 EM 估计对先验值更敏感,其原因之一就是贝叶斯估计中 MCMC 算法的收敛性是随机的,而 EM 估计算法有确定的收敛性^[13,14]。

第二类方法因为使用了更好的 OD 流模型,因而产生较好的先验值,从而降低了对先验值的依赖程度,即降低了对先验值的敏感性。如 TomoGravity 方法,因为对 OD 流建模使用重力模型,因而能够为层析成像方法产生好的先验值,降低了整个方法对先验值的敏感性。而路由改变方法根本就不用先验值,直接用矩阵的伪逆运算来获得估计结果。特别是这两种方法都加入了校正过程,从而使得其对先验值的依赖程度更低。

第三类方法由于都用直接流测量来获得初始的流量矩阵,因而先验值是真实的流量,不是一个凭经验或其他方式产生的对真实值的近似值,从而保证了先验值的良性,降低了对先验值的依赖。

3.2 误差分析

第一类方法采用了简单的建模假设,认为 OD 流是服从独立同分布(泊松分布或正态分布),在时间和空间上不具有相关性。在近几年的研究中,研究人员发现,在实际的 IP 骨干网上,由于共享链路、路由策略以及其他因素的影响, OD 流间是具有相关性的。另一方面,估计过程中采用了统计假设的反迭代算法,这种算法使得其对先验值极为敏感,差的先验值有可能使结果收敛于局部最优而非全局最优,更有甚

者,有可能使结果不收敛。所有这些,都可能使估计结果有较大误差。在文[13]的分析中,我们可以看到,尽管在文[1]中Cao等人使用滑动窗口来降低误差,改善性能,但是其改善效果也不很明显。

TomoGravity 和路由改变方法采用 SNMP 测量数据来建模,使用重力模型或周期静态模型,对 OD 流建立起了时间或空间上的相关性,在估计过程中采用 MMSE 最优方法或矩阵伪逆运算。正因为对 OD 流的建模考虑其时间或空间的相关性,而且当 OD 流变化时包含了模型校正过程,以及引入了附加信息到整个算法过程中,所以,与第一代方法相比,这将大大降低估计误差,在文[13]中也证明了这一点。

Fanout, PCA 和 Kalman 方法采用直接测得的流量数据来建模,使用线性动态系统模型或本征流本征向量模型或节点 Fanout 模型,对 OD 流建立起了空间或时间空间相关性,估计过程采用 Kalman 滤波、矩阵伪逆运算或直接计算 OD 流估计值。与第二代方法相比,其引入的附加信息不是 SNMP 测量数据,而是真实的 OD 流数据,从而提高了估计值的精度。另外也包括了校正过程,即当 OD 流发生持续较长时间的变化时,将开始校正过程,重新确定模型参数,保证估计结果能够随着 OD 流的变化而变化。因为以上原因,它们的估计误差比第二代方法更低。如在文[13]中,作者证明 Fanout, PCA 和 Kalman 方法与 TomoGravity 方法相比,时间误差前者为 10%~15%,而后者为 25%左右;空间误差前者为 5%~15%,后者为 20%~33%。可见前者的改善效果是很明显的。

3.3 自适应性

在实际的流量测量中,研究人员发现 OD 流具有动态性,如某些流在一段时期内发生急速的变化,而其他的流在较长的时间内却变化缓慢。因为第一类方法误差较大,在此主要比较 Fanout, PCA 和 Kalman 方法与 TomoGravity 方法的自适应性,并主要比较流量经历迅速变化和缓慢变化两种情况^[13]:

第一种情况:流量经历迅速变化的情况(在一天的期间内):

- 1) 这四种方法都能处理这种变化;
- 2) PCA, Kalman 方法能很好地追踪出流量变化的细节部分;当变化很快时,它们也能很好地进行追踪;
- 3) 对于捕获流中不改变基本趋势的变化有很大的灵活性。

第二种情况:流量经历缓慢变化的情况(流跌了几个数量级,跌到一个较小但非零的水平):

1) TomoGravity 方法能最好地追踪这种变化。原因在于每一个时隙它完全重新开始模型校正。在这种情况下,重力模型的无记忆特性对此很好地发挥了作用。

2) Fanout 方法的自适应行为也表现得很好。

3) PCA, Kalman 有较大的误差。原因在于主要流中的巨大变化。尽管 PCA, Kalman 方法适应了这种变化,但是与 TomoGravity 方法相比,它没有更好地适应这种变化;在文[7]的情况下,作者提到,尽管这两种方法以非常及时的方式对第一次变化(OD 流中的下跌)作出反应,但是对恢复作出的反应是很慢的,原因在于它们对重校正的延迟,而这种延迟是我们有意设计来避免对短暂的变化作出反应。由于在这种情况下,短暂的变化时间有点长,因此这两种方法没有成功地避免对它作出反应。从而,在这两种方法没有足够快地适应这种变化的几个时间点处,将产生较大的误差。

可见,获得附加信息的速率决定了流量矩阵估计方法的自适应性。尽管这些方法都能自适应地处理这些动态变化,但是,像在文[13]中所说明的一样,与第三类方法相比, TomoGravity 方法每 10 分钟获得用于模型校正的附加信息,因而它是最具有自适应性的方法,但是却有较大的误差。第三类方法获得用于模型校正的附加信息一周不会多于一次或两次,因而它们没有 TomoGravity 方法那样具有最大的自适应性。然而,由于有丰富的流量数据,并且结合了流量数据实际的时间或时间空间相关性,因而第三类方法几乎能够完全消除估计偏差。而且 TomoGravity 的整个生命期内总是表现出误差,而第三类方法仅仅在自适应期间表现出较大的误差。

3.4 直接测量性能分析

由于有丰富的已知数据流用来建立 OD 流模型,因而第三类方法在空间和时间误差上低于第二类方法,但是直接测量数据流的开销是昂贵的。

TomoGravity 方法对应于没有使用直接数据流测量,其误差是我们的一个参考点。而流量矩阵完全使用直接测量数据时,其对应误差为 0,是我们在此考虑的另一个参考点,在文[13]中,作者进行了一系列的分析,得出如下三个有意义的结果:

1) 对于 10%~20% 的测量开销,误差降低到 TomoGravity 方法误差的一半。对空间和时间误差而言,降低小测量开销误差的这种最大好处是明显的;

2) 第三类方法以 10% 的测量开销就可以产生非常准确的估计;

3) 大约超过 20% 的开销以后,通过增加测量,很少有进一步的改善。

可见,使用部分流量测量对降低误差,提高估计精度是很明显的。

4 技术路线及发展方向

对于线性系统模型 $y = Ax$, 在实际应用中,由于大多数网络设备都不提供协作方式,直接进行流量测量是不可能的,而且 x 的维数要远远大于 y 的维数,因此要获得准确的流量矩阵 x ,目前有如下的一些技术问题。

1) 链路测量数据的可靠性:如何准确地获得链路流量向量 y ,将是准确获得流量矩阵估计值的一个限制。在实际链路测量中,我们使用 SNMP 来获得链路流量。大家都知道,SNMP 有其自身的缺陷和限制,它不能准确获得每一时刻的链路流量,而是在一个时间间隔内的平均值。

2) 拓扑结构的准确性:如文[16]中所述,在 IP 网络中,要准确获得 IP 网络拓扑结构是很困难的,从而要准确获得路由矩阵 A 是困难的。

3) OD 流模型的有效性:对 OD 流的建模是一个很困难的问题,怎样的模型才能准确地反映真实的 OD 流,仍是一个值得研究的问题。尤其是对 OD 流的直接测量是不可能的,因此不可能获得真实的 OD 流,故而评价流量矩阵的估计值和流量矩阵模型的有效性是很困难的。

4) 反演估计的可靠性:尽管现在对于反问题进行了多年的研究,有很多现存的求解方法,但是通过这些现存的方法来进行流量矩阵的估计,其结果是否能够准确地反映真实的 OD 流,以及是否有新的方法可以用来更好地解决这一反问题,仍在进一步研究中。

(下转第 13 页)

- 8 谢纪刚, 袁正定. 非平衡数据集 Fisher 线性判别模型. 北京交通大学学报, 2006, 30(5): 15~18
- 9 Weiss G. Mining with Rarity Problems and Solutions: A Unifying framework. SIGKDD Explorations, 2004, 6(1): 7~19
- 10 Marcus A. Learning when data sets are imbalanced and when costs are unequal and unknown. In: Proc. of the Workshop on Learning from Imbalanced Data Sets II, ICML, Washington DC, 2003
- 11 Miroslav K, Stan M. Addressing the curse of imbalanced training sets-one sided selection. In: Proc. of the 14th International Conference on Machine Learning, Morgan Kaufmann, 1997. 179~186
- 12 Mahesh V, Vipin K, Ramesh C. Evaluating boosting algorithms to classify rare classes: comparison and improvements. In: Proc. of the 1st IEEE International Conference on Data Mining, San Jose, CA, 2001. 257~264
- 13 Guo H Y, Herna L V. Learning from Imbalanced Data Sets with Boosting and Data Generation: The DataBoost-IM Approach. Sigkdd Explorations, 2003, 6: 30~39
- 14 Vapnik V. The nature of statistical learning theory. New York: Springer Verlag Press, 1995
- 15 郑恩辉, 李平, 宋执环. 不平衡数据知识挖掘: 类分布对支持向量机分类的影响. 信息与控制, 2005, 34(6): 703~708
- 16 肖健华, 吴今培. 样本数目不对称时的 SVM 模型. 计算机科学, 2003, 30(2): 165~167
- 17 Wu G, Edward Y C. Adaptive Feature-Space Conformal Transformation for Imbalanced-Data Learning. In: Proc. of the 20th international conference on machine learning, Washington DC, 2003. 816~823
- 18 Wu G, Edward Y C. KBA: Kernel boundary alignment considering imbalanced data distribution. The IEEE transactions on knowledge and data engineering, 2005, 17(6): 786~795
- 19 Claire C, Nicholas H. Improving minority class prediction using case-specific feature weights. In: Proc. of the 14th international conference on machine learning, Morgan, Kaufmann, 1997. 57~65
- 20 Chris D, Robert C H. C4. 5, class imbalance, and cost Sensitivity: Why under-sampling beats over-sampling. In: Proc. of the Workshop on Learning from Imbalanced Data Sets II, ICML, Washington DC, 2003

(上接第 9 页)

为了解决以上技术问题, 研究人员在多个方面探索解决流量矩阵估计问题的最佳方案. 测量反演结合策略, 是未来继续发展的一个方向. 由于随着网络的发展, 目前有许多流监测器对我们而言是可以直接使用的, 从而使得这一方法可行, 并成为未来的一个发展方向. 目前获得流量矩阵的已知方法大多仅仅依靠 SNMP 数据来进行, 这些方法对较小流量的处理是很困难的, 测量反演结合策略的下一代方法将能够更好地处理这一问题^[13].

充分考虑 OD 流的时间、空间或者是时间空间相关性, 建立合理的 OD 流模型, 更好利用测量附加信息, 提高估计精度, 降低误差, 是以后流量矩阵估计的进一步发展方向. 对 OD 流动态变化自适应性的提高, 也是以后我们需要解决的问题.

参考文献

- 1 Cao J, Davis D, Weil S V, et al. Time-varying Network Tomography. J of the American Statistical Association, 2000
- 2 Vardi Y. Network tomography: Estimating source-destination traffic intensities from link data. Amer J Stat Assoc, 1996, 91(433): 365~377
- 3 Tebaldi C, West M. Bayesian inference on network traffic using link count data. Journal of the American Statistical Association, 1998, 93(442): 557~576
- 4 Tsang Y, Coates M, Nowak R. Passive network tomography using EM algorithms. In: Proc. IEEE Int Conf. Acoust, Speech, and Signal Proc., May 2001
- 5 Coates M, Hero A, Nowak R, et al. Internet tomography. IEEE SignalProcess, 2002, 19(3): 47~65
- 6 Tsang Y, Coates M, Nowak R. Nonparametric internet tomography. In: Proc. IEEE Int Conf. Acoust. Speech, Signal Process, May 2002
- 7 Chen, Bindel K. Tomography-based Overlay Network Monitoring. ACM IMC, 2003
- 8 Duffield N. Simple Network Performance Tomography. ACM IMC, 2003
- 9 Zhang Y, Roughan M, Duffield N, et al. Fast Accurate Computation of Large-Scale IP Traffic Matrices from Link Loads. In: ACM Sigmetrics, San Diego, CA, 2003
- 10 Zhang Y, Roughan M, Lund C, et al. Estimating Point-to-Point and Point-to-Multipoint Traffic Matrices: An Information-Theoretic Approach. IEEE/ACM Transactions on Networking, 2004
- 11 Zhang Y, Roughan M, Lund C, et al. An Information Theoretic Approach to Traffic Matrix Estimation. In: ACM SIGCOMM, Karlsruhe, Germany, August 2003
- 12 Medina, et al. An Information-Theoretic Approach to Traffic Matrix Estimation. ACM SigComm, 2002
- 13 Soule A, Lakhina A, Taft N, et al. Traffic Matrices: Balancing Measurements, Inference and Modeling. ACM Sigmetrics 2005. Banff, June 2005
- 14 Medina A, Taft N, Salamati K, et al. Traffic Matrix Estimation: Existing Techniques and New Directions. In: ACM SIGCOMM, Pittsburgh, USA, Aug. 2002
- 15 Soule A, Salamati K, Nucci A, et al. Traffic Matrix Tracking using Kalman Filtering: [Research Report]. RP-LIP6-2004-07-10. LIP6, 2004
- 16 张宏莉, 方滨兴, 胡铭曾, 等. Internet 测量与分析综述. 软件学报, 14(1): 110~116
- 17 Kay S M 著. 统计信号处理基础: 估计与检测理论. 电子工业出版社, 2003
- 18 张贤达. 矩阵分析与应用. 清华大学出版社, 2004
- 19 Bhattacharyya S, Diot C, Jetcheva J, et al. Geographical and Temporal Characteristics of Inter-POP Flows: View from a Single POP. In: European Transactions on Telecommunications, February 2002
- 20 Nucci A, Cruz R, Taft N, et al. Design of IGP Link Weight Changes for Estimation of Traffic Matrices. In: IEEE Infocom, Hong Kong, March 2004
- 21 Soule A, Nucci A, Leonardi E, et al. How to Identify and Estimate the Largest Traffic Matrix Elements in a Dynamic Environment. In: ACM Sigmetrics, New York, June 2004
- 22 Gunnar A, Johansson M, Telkamp T. Traffic Matrix Estimation on a Large IP Backbone - A Comparison on Real Data. In: ACM Internet Measurement Conference, Taormina, Italy, October 2004
- 23 Papagiannaki K, Taft N, Lakhina A. A Distributed Approach to Measure Traffic Matrices. In: ACM Internet Measurement Conference, Taormina, Italy, October 2004
- 24 Erlander S, Stewart N F. The Gravity Model in Transportation Analysis - Theory and Applications. 1990
- 25 Vanderbei R J, Iannone J. An EM approach to OD matrix estimation: [Tech Rep]. SOR 94-04, Princeton University, Princeton, NJ, 1994
- 26 Lakhina A, Papagiannaki K, Crovella M, et al. Structural Analysis of Network Traffic Flows. In: ACM Sigmetrics, New York, June 2004
- 27 Rschendorf L. Convergence of the iterative proportional fitting procedure. Annals of Statistics, 1995. 1160~1174
- 28 Liang G, Taft N, Yu Bin. A Fast Lightweight Approach to Origin-Destination IP Traffic Estimation Using Partial Measurements. IEEE Transactions on Information theory, 2006, 52(6)