



专题：智能通信技术

互联网智能路由架构及算法

桂飞, 程阳, 李丹, 洪思虹
(清华大学, 北京 100084)

摘要: 突发流量在网络中非常普遍, 会严重损害用户体验。突发流量往往能在短时间(如毫秒级别)内充满链路, 导致网络拥塞和频繁分组丢失, 端到端时延增加。传统路由算法要么是流量无关(如 OSPF (open shortest path first, 开放式最短路径优先))的, 无法对实时流量的变化做出调整; 要么是集中式控制的(如线性规划), 面临求解时延过大而无法有效应对突发流量的问题。提出了一种新的智能路由算法解决突发流量的问题。一方面, 提出的算法能利用机器学习强大的建模能力, 通过对网络历史数据的挖掘来学习“隐式”的路由决策依据。另一方面, 提出的算法能借助机器学习的快速推理能力降低决策时延, 提高系统对突发流量的响应速度。实验结果表明, 在真实流量数据集下, 相比较其他路由算法, 提出的智能路由算法能降低 13%~70% 的瓶颈链路利用率。

关键词: 互联网路由算法; 突发流量; 机器学习; 深度强化学习

中图分类号: TN915

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020285

Internet intelligent routing architecture and algorithm

GUI Fei, CHENG Yang, LI Dan, HONG Sihong
Tsinghua University, Beijing 100084, China

Abstract: Traffic bursts are common in networks, which have a significant impact on quality of user experience. In the case of traffic bursts, huge volumes of packets can overwhelm the physical links in a short time duration(i.e., milliseconds), resulting in congestion and frequent packet loss. However, traditional routing schemes are either traffic oblivious such as OSPF, which can't adapt to real-time traffic changes, or centralized control such as linear programming, which can't efficiently react to traffic bursts due to slow computation. To address this problem in a practical and efficient approach, a novel intelligent routing algorithm based on machine learning (ML) was proposed. On the one hand, the proposed algorithm can leverage the promising modelling ability of machine learning to learn the implicit clue of routing decision. On the other hand, the proposed algorithm enjoys the ultralow processing latency benefited from the fast inference of ML, thus speeding up the reaction to traffic bursts. Experiments on two open-source datasets demonstrate that the proposed scheme can reduce utilization of bottleneck link by 13%~70%, compared with the baselines.

Key words: internet routing algorithm, traffic burst, machine learning, deep reinforcement learning

收稿日期: 2020-09-10; 修回日期: 2020-10-10

基金项目: 国家重点研发计划项目 (No.2018YFB1800500); 国家自然科学基金资助项目 (No.61772305); 广东省重点研发计划项目 (No.2018B010113001)

Foundation Items: The National Key Research and Development Programs of China (No.2018YFB1800500), The National Natural Science Foundation of China (No.61772305), Guangdong Provincial Key Research and Development Programs (No. 2018B010113001)

1 引言

互联网已经成为人类社会发展必不可少的推动力量。在万物互联的趋势下,网络覆盖范围越来越广,新型应用层出不穷。为适应网络用户和应用规模的不断增加,网络规模(节点数和链路带宽)也需要不断增加。也就是说,互联网服务提供商(internet service provider, ISP)必须不断频繁地扩容来支撑应用所需的网络性能(高带宽和低时延)。流量工程俨然成为域内网络用来优化路由提高链路利用率的一种必不可少的手段。该领域的重要性也直接催生了一系列做基于流量工程来优化路由的研究工作^[1-8]。

流量特征会很大程度上影响路由算法的设计。对于许多网络,尽管从宏观角度观测,它们的流量需求在大部分时间都保持在较低且平稳的水平,但当以毫秒粒度进行观测会发现,流量呈现很强的动态性,突发流量非常普遍。突发流量^[9-11]能在短时间内塞满链路,随之而来的拥塞和分组丢失会造成网络抖动、时延突增和吞吐下降。造成突发流量有很多原因。首先,应用的行为会造成突发流量。比如, IPTV 这类视频应用^[10]的数据经过视频压缩算法后会形成体积不均匀的 I 帧和 P 帧(I 帧的体积远大于 P 帧)。当以恒定帧率发送数据时, I 帧数据的发送就会形成了一个小的突发流量。其次, TCP 栈的运行机制也会有助于突发流量的形成。比如, TCP^[11]普遍采用基于窗口的拥塞控制机制和自律动(self-clocking)机制可能会让发送端以远超过流的平均吞吐的速度发送数据。同时, TCP 栈^[12]为了提升性能而采取的批处理操作也会造成短期的突发流量。

突发流量普遍存在且对网络性能危害巨大,路由算法理应重点对其进行优化。然而,当前的路由实践却普遍只是采用“基于拓扑的静态路由”加上“基于规划的流量工程”的方法。静态路由方法缺点明显,由于路由选择不考虑流量状态,

往往需要预留足够的网络带宽以应对突发流量,造成当前网络的最高链路利用率很低。据统计,广域网的链路利用率普遍低于 50%,甚至大部分低于 30%。一旦网络的链路利用率增加,运营商只能进一步扩容来应对流量突发风险。这样会带来网络建设成本和运维成本的大幅增加。目前网络流量工程^[2-3]的主要思路是通过收集流量矩阵信息,采用线性规划等方法进行集中求解,然后把运算结果下发到路由器上,对网络流量进行选路优化。其存在的主要问题是:一方面,收集全网的流量矩阵信息成本较高、会带来较大时延;另一方面,基于线性规划的算法复杂度也往往较高,在网络规模较大时产生额外时延(秒级别)。因此,当前的流量工程方法难以对动态性强的网络流量(突发流量持续时间普遍为毫秒级别)进行实时响应。当前,随着网络设备可编程化和白盒化趋势,一些新兴网络测量技术(如 sketch、INT 等)^[13-16]使得网络状态的获取变得快速且精准,但路由控制算法仍是网络性能出现瓶颈的关键原因。

近年来,以机器学习为代表的人工智能技术的发展,带来了重新思考互联网路由控制的机会。一方面,基于机器学习技术,通过对互联网路由历史数据的挖掘来学习“隐式”的路由决策依据,以优化智能路由控制。并且,由参考文献[17-19]可知,网络流量虽然在较长时间尺度上呈现随机性,但是在更小的时间粒度(毫秒粒度)上是可预测的。这意味着在毫秒时间粒度上,网络流量存在着某种规律,它或许能被机器学习算法捕捉来优化路由决策的准确性。另一方面,机器学习具备快速推理能力,能大大降低决策时延,这为突发流量的快速响应提供了机会。本文将介绍如何基于机器学习的准确建模能力和快速推理能力来设计新型智能路由算法。

2 相关工作

基于流量工程的路由算法: ECMP^[4]在最短路



优先算法的基础上,提出将流量等分到多条等价最短路径上,以使网络负载更加均衡。HeurOSPF^[5]提出根据历史流量来集中式地计算路由配置(链路权重),并将其下发至各个路由器节点,随后各节点基于获得的链路权重运行分布式最短路径算法。SWAN^[2]和 Smore^[3]通过计算线性规划的方式在多条备选路径上进行分流,以此来达到降低网络堵塞的目的。尽管 SWAN 提出每 5 min 重新计算一次路由以适应流量的动态变化,但此方法存在两点局限:首先,它需要全局收集网络状态,时间开销较大;其次,线性规划算法的时间复杂度很高,不适合用来解决突发流量的问题。Oblivious routing^[6]认为路由只跟网络拓扑的性质相关,而跟流量无关。它提出利用线性规划工具对该问题进行求解,尽管可以在最坏情况下获得一个的性能下界,但是还远达不到最优性能。

基于机器学习的路由算法:当前,学术界在如何利用机器学习算法来优化路由算法方面已做了初步尝试。参考文献[20]讨论了如何利用监督学习方法根据历史的流量需求矩阵预测接下来的流量需求矩阵,并在预测的流量需求矩阵上利用线性规划求解得到最优路由策略。该方法要求集中收集流量矩阵信息和集中式求解,时间开销较大。Q-routing 路由^[21]利用 Q-learning 算法,以最小化端到端时延为目标,自动学习到最优下一跳。在路由设备中,该方法使用在线策略的方式,要求根据实时的网络时延信息学习和更新 Q 表,并选择具有最大效益的下一跳出口转发数据分组,但是路由环路等问题没有得到解决。Delay-Optimal TE^[22]在此基础上,提出了一种基于多智能体强化学习的智能路由方法,以提升模型的收敛速度。但这种方法有可能存在路由环路的问题。DRLTE^[23]考虑如何利用强化学习来优化流量分割。其考虑在给定备选路径(通过最短路径算法得到)的情况下,利用深度强化学习算法根据网络的利用率和延迟信息,学习出这些路径上的最

优流量分割策略,并在此基础上选择路径转发数据分组,以提升网络效率。该方法在一定程度上证明了强化学习的有效性,但是其使用集中式的路由决策模型,存在可扩展能力不足的问题。

3 机器学习算法为互联网路由带来的新机会

3.1 机器学习算法的优势

随着网络规模和复杂度的不断增加,试图对网络进行确定性建模已变得非常困难。同时,根据参考文献[17-19]可以得知,网络流量虽然在较长时间尺度上呈现随机性,但是在更小的时间粒度(毫秒粒度)上是可预测的。这意味着在毫秒时间粒度上,网络流量存在着某种规律。以 RNN 等为代表的深度学习算法,能极大提升对时序数据的曲线拟合能力,并在自然语言处理等领域^[24]得到成功运用。应用到路由场景中,可以大大地提高对流量矩阵、链路负载的预测能力从而提升路由的动态响应能力。其次,以强化学习为代表的机器学习算法能在复杂不确定的环境中通过与环境不断交互试错的方式学习如何取得优化目标,并在游戏和棋类^[25]等领域取得极大成功。将其应用到路由场景中,可以加强对流量动态场景下的路由规划能力。最后,机器学习模型虽然训练过程较慢,但是一旦训练完成,模型的推理速度极快,应用到路由场景中,可以提高对突发流量的响应速度。

3.2 机器学习算法的选择

机器学习算法主要分为监督学习、非监督学习和强化学习 3 类算法。首先,监督学习和非监督学习算法一般适用于分类、识别或者预测等任务,这类任务具有一次性决策、只关注即时奖励的特点。然而,路由本质上是一种序列决策任务,也就是说当前的路由动作会直接影响下一时刻的状态输入和动作。因此,路由任务需要更注重未来的累计奖励,而非即时奖励。自然地,路由控制任务可被视为一个强化学习的马尔可夫决策过程。

其次, 监督学习算法需要用海量带标注的样本进行训练后才能获得较好性能。然而, 在路由场景下, 带标注的样本较难在短时间内被大量获取, 因为每个样本需要进行一次完整的线性规划计算才能获得。强化学习提供了另一种思路, 它不需要带标注的样本, 而是能通过不断和环境交互的方式, 试错迭代, 通过环境的反馈信号来训练更新模型。

基于以上分析, 强化学习算法更适合应用在路由场景。然而, 单纯的强化学习算法仍然具有局限性。比如, 在大规模系统中, 决策空间和状态空间较大, 强化学习算法往往会面临维度灾难 (curse of dimensionality) 问题。此时, 深度学习技术便能发挥作用。深度学习模型具有多层神经网络结构, 它能通过高维特征空间变换到低维特征空间的表示学习方式缓解维度灾难问题。因此, 本文将以深度强化学习算法 (结合强化学习和深度学习技术) 为基础设计智能路由算法。

3.3 技术挑战

利用深度强化学习的准确建模和快速推理能力设计智能路由算法, 主要面临以下几个挑战。

首先, 如何避免动态的流量需求输入对模型收敛的影响。流量需求随时间的动态变化会使智能体无法区分不同动作得到的奖励的差异是由动作好坏造成的, 还是由于流量需求大小不同造成的, 这会导致模型无法正常收敛。本文设计了一种新的奖励函数解决流量需求的动态变化对奖励的干扰问题, 该奖励函数能区分流量需求大小的差异对于奖励的干扰, 使得模型能对好的动作进行奖励和对坏的动作进行惩罚。

其次, 如何保障路由的可扩展性。集中式控制可使路由以全局视角对流量控制进行优化, 但其缺点是需要全局收集实时网络状态, 而全局状态收集的时间开销很大。另一方面, 当网络规模较大时, 集中式控制带来的过高决策时延不可接受。因此, 有必要将路由控制协议设计成分布式

决策的过程。分布式决策要求每个路由器只基于自身的本地信息进行路由决策, 但如何保证分布式决策能取得全局优化仍然是个挑战。

路由器进行分布式路由决策本质上是一种多智能体决策问题, 该问题的解决方法在游戏领域已经取得了很多进展。参考文献[26-27]研究在多角色策略游戏中, 每个角色如何能基于局部信息进行决策, 最终取得全局的游戏目标 (即在对局中胜出)。受此启发, 本文将相关的多智能体强化学习算法应用到分布式路由控制协议的设计中, 来解决分布式决策取得全局优化的挑战。

4 智能路由架构和算法设计

4.1 智能路由算法的设计原则

首先, 本文提出的智能路由算法以最小化瓶颈链路利用率为优化目标。瓶颈链路利用率是该领域普遍使用的性能优化指标, 它能够有效衡量路由算法能否有效降低网络拥塞和提高网络资源利用率。

其次, 本文提出的智能路由算法需要准确捕捉路由的动态变化和突发流量的变化趋势。准确感知流量的动态变化是路由算法做出正确决策的前提。

最后, 本文提出的智能路由算法需要具有高可扩展性。高可扩展性保证了在网络规模变大时, 路由算法依然能及时对突发流量进行响应。

4.2 智能路由算法架构

本文基于深度强化学习的准确建模能力和快速推理能力来设计智能路由算法。智能路由体系架构如图 1 所示, 整个算法架构分为离线训练系统和在线推理系统两部分。因为机器学习的训练过程慢, 但是推理速度很快, 因此本文提出应将训练过程和推理过程分离以保证推理速度。其中, 训练过程发生在线下训练中心。训练中心首先会采集真实历史流量, 然后通过流量重放的方式对网络的历史运行情况进行模拟再现。各个强化学




图1 智能路由体系架构

习模型便可以在此模拟网络中进行交互迭代式训练。待训练结束后，训练中心会将训练好的各个模型逐一下发到对应的各边缘路由器上。进入在线推理阶段后，每个边缘路由器的智能模型将根据本地网络信息执行分布式推理过程。

路由器被分为边缘路由器和中间路由器两类。边缘路由器作为应用端流量入口，应该承担流量的分割工作。因此，智能节点示意图如图2所示，可以将边缘路由器作为智能节点，在其上部署机器学习智能模型，执行周期性的路由决策推理任务。边缘路由器上主要由状态采集模块、推理引擎和转发引擎3部分组成。首先，状态采集模块负责周期性地采集本地网络状态，然后将其发送给推理引擎。然后，推理引擎基于输入信息进行推理决策，输出在节点之间的备选路径上的流量分割比。转发引擎会基于流量分割比执行流量分流的过程。因为在路由器对备选路径进行调整的开销很大，而只在备选路径上做流量分割的调整的开销很小（固定备选路径）。因此，在训练过程开始前，通过 K 条最短路径（ K shortest path, KSP）、无关路由等算法得到备选路径。

4.3 强化学习算法建模

本节介绍强化学习智能体（包括动作、状态和奖励3部分）的建模过程。




图2 智能节点示意图

(1) 策略和动作

策略定义了智能体在当前状态下的行为方式，即智能体在当前网络状态下如何进行流量分割（对应到路由场景下），通常策略可以用神经网络表示（它表示智能体通过训练后学到的状态到动作的映射）。动作则是智能体在各个状态下采取的行为。比如，智能体 a 根据当前的状态，进行决策并输出通向路由器 b 的流量在3条备选路径

上的分割比 (20%、30%、50%), 那么此分割比即可以定义成智能体的动作。同时, 因为每个智能体 (各个路由器) 在网络中所处的位置和面临的网络环境不同, 每个智能体具有完全不同的策略 (模型), 且全都基于自身的本地状态进行独立决策。

(2) 状态

状态一般作为智能体进行决策的直接依据。本文将每个智能体的状态定义为智能路由器的前 T 个时间周期内的所有本地链路的利用率的集合 (以矩阵形式表示): $s^t = [u_1^t, \dots, u_K^t]$, 其中 t 表示第 t 个时刻周期, K 表示本地链路的数目。一方面, 时间窗口的输入形式可以解决当发生流量突发时路由控制任务的非马尔可夫性问题。另一方面, 时间窗口的输入形式让模型能实时捕捉流量的动态变化趋势。最后, 状态输入仅包含本地链路信息可以最大限度地减小状态获取的时间开销, 提高路由决策的响应速度。

(3) 奖励函数

奖励函数表示强化学习算法的优化目标。智能体会通过奖励信号判断当前执行的策略的好坏, 进而对模型参数进行更新。奖励函数定义为全网的最大链路利用率与当前时间周期内的总的流量需求大小的比值的负值, 如式 (1) 所示:

$$r = -(\arg \max_{\substack{1 \leq i \leq N, \\ 1 \leq k \leq P, \\ 1 \leq j \leq L_{i,k}}} (u_{i,k,j})) / d_t \quad (1)$$

其中, $L_{i,k}$ 表示第 i 个节点对的第 k 条备选路径上的链路总数, $u_{i,k,j}$ 表示第 i 个节点对的第 k 条备选路径上的第 j 条链路的链路利用率, d 表示当前时间周期内所有节点对之间的流量需求大小的总和。在奖励函数中引入总的流量需求大小作为分母可以理解成当前动作在每单位流量需求下能取得奖励值。通过这种方式, 奖励函数能有效分离当前动作对网络性能的实际贡献, 进而被用来更新模型参数。

4.4 多智能体训练算法

为保证可扩展性, 本文研究基于多智能体强化学习算法的智能路由模型设计, 来解决分布式决策 (每个智能体仅根据本地局部信息进行分布式地独立决策) 达到全局优化的目标。受游戏领域的多智能体强化学习^[26-27]的启发, 本文在每个智能体模型独立推理的基础上, 在线下训练阶段额外引入一个全局评判者的角色, 由它指导所有独立的智能体模型朝全局优化的目标迭代更新。具体地, 本文借助成熟的多智能体强化学习算法 (多智能体 DDPG 算法^[26]) 解决此问题。多智能体强化学习的建模如图 3 所示, 在该算法中, 各路由器上的智能模型 (智能体) 建模成 Actor。在此基础上, 额外引入一个全局的价值评估 Critic (仅存在于训练过程)。在训练过程中, 这个价值评估 Critic 能站在全局的角度对每个 Actor (智能体) 的动作对于全局目标的贡献进行打分, 然后每个智能体可以根据各自的打分值针对性地更新自己的策略。最后, 所有智能体模型能通过这种训练方式达到全局优化的目标。

5 实验与分析

为了验证本文提出的智能路由算法的性能, 本文利用 TensorFlow 平台和 NS3 仿真平台实现提出的路由算法, 并在真实开源流量数据集下对本文算法和多种当前路由算法从多个维度进行了对比。

5.1 实验设置

首先, 本文使用的服务器硬件配置包括 2 个英伟达 P100 显卡, 2 个 16 核 E5-2630-V3 处理器 (2.4 GHz) 和 64 GB DDR4 内存 (2 133 MHz)。在软件层面, 所有实验在 Ubuntu-16.04 中进行。同时, 本文采用 TensorFlow 1.4 (支持 GPU 的版本) 来构建深度强化学习, 同时采用 NS3-v3.30 网络仿真器来构建网络环境。

其次, 本文采用 5 种典型路由算法作为对比实验, 它们分别是最短路优先算法 (shortest path first, SPF)、 K 条最短路径 (K -shortest-path, KSP)




图3 多智能体强化学习的建模

等价多路径（equal-cost multi-path, ECMP）^[4]，深度强化学习—流量工程（deep reinforcement learning traffic engineering, DRL-TE）^[23]和无关路由（oblivious routing）^[3]。

最后，本文采用当前开源的网络数据集 Abilene^[28]和 GEANT^[29]作为实验数据。其中，Abilene 的拓扑由 11 个节点和 28 条边组成，所有流量需求数据的采样频率为每 5 min 一次；GEANT 的拓扑由 23 个节点和 74 条边组成，所有流量需求数据的采样频率为每 15 min 一次。本文选择连续一周的数据作为数据集，其中前 80% 的数据作为训练阶段的流量重放数据，后 20% 的数据作为测试阶段的重放数据。

5.2 实验结果与分析

本文主要采用两种指标作为性能评价。第一种是最大链路利用率比（maximum link utilization ratio, MLU ratio），它能衡量当前方法所得到的全网最大链路利用率与最优情况的比值。该比值越小（且越接近 1）表明算法性能越好。第二种是 MLU ratio 的累积分布函数（cumulative distribution function, CDF），它能衡量算法性能的整体分布情况。

首先，在 Abilene 数据集下的 MLU ratio 性能对比如图 4 所示。在 Abilene 数据集下，本文算法能取得平均 1.31 的 MLU ratio 性能，而 DRL-TE、SP、KSP、ECMP 和 OR 分别取得 1.51、1.82、4.2、

2.31 和 2.52 的 MLU ratio 的性能。本文算法取得远高于其他方法的性能。同时，从图 5 可以看出，在 Abilene 数据集下，相比较其他算法，本文算法有 75% 的 MLU ratio 小于 1.3，这体现了本文算法性能较优且较稳定。




图4 在 Abilene 数据集下的 MLU ratio 性能对比




图5 在 Abilene 数据集下的 MLU ratio CDF 曲线性能对比

然后, 图 6 和图 7 给出了在 GEANT 数据集下本文算法和其他方法的性能对比。在 GEANT 数据集下的 MLU ratio 性能对比如图 6 所示, 在 GEANT 数据集下, 本文算法能取得平均 1.33 的 MLU ratio 性能, 而 DRL-TE、SP、KSP、ECMP 和 OR 仅能各取得 1.45、2.1、1.5、1.7 和 3.1。同时, 在 GEANT 数据集下的 MLU ratio CDF 曲线性能对比如图 7 所示, 本文算法的 70% 的 MLU ratio 都小于 1.3, 这足以体现本文算法能取得比其他方法更优且更稳定的性能。




图 6 在 GEANT 数据集下的 MLU ratio 性能对比




图 7 在 GEANT 数据集下的 MLU ratio CDF 曲线性能对比

综上所述, 在两种不同的数据集下, 相比较其他算法, 本文算法都能显著降低网络拥塞, 提高网络资源利用率。

6 结束语

本文针对当前网络中普遍存在的突发流量问

题, 提出一种新的智能路由算法。一方面, 它能利用机器学习强大的建模能力, 对网络状态变化趋势进行准确建模, 从而学习网络状态到路由的映射关系。另一方面, 它能借助机器学习的快速推理速度显著降低决策时延, 提高系统对突发流量的响应速度。实验结果表明, 在真实流量数据集下, 相比较其他路由算法, 本文提出的智能路由算法能降低 13%~70% 的瓶颈链路利用率。


参考文献:

- [1] BOGLE J, BHATIA N, GHOBADI M, et al. TEAVAR: striking the right utilization-availability balance in WAN traffic engineering[C]//Proceedings of the ACM Special Interest Group on Data Communication. New York: ACM Press, 2019: 29-43.
- [2] HONG C Y, KANDULA S, MAHAJAN R, et al. Achieving high utilization with software-driven wan[C]//Proceedings of 2013 ACM SIGCOMM Computer Communication Review. New York: ACM Press, 2013.
- [3] KUMAR P, YUAN Y, YU C, et al. Semi-oblivious traffic engineering: the road not taken[C]//Proceedings of 15th USENIX Symposium on Networked Systems Design and Implementation (NSDI 18). [S.l.: s.n.], 2018.
- [4] IETF. Analysis of an equal-cost multi-path algorithm: RFC 2992 [S]. 2000.
- [5] FORTZ B, THORUP M. Internet traffic engineering by optimizing OSPF weights[C]//Proceedings of IEEE INFOCOM'2000. Piscataway: IEEE Press, 2000.
- [6] APPLGATE D, COHEN E. Making routing robust to changing traffic demands: algorithms and evaluation[J]. IEEE/ACM Transactions on Networking (TON), 2006, 14(6): 1193-1206.
- [7] HAO W, XIE H Y, QIU L L, et al. COPE: traffic engineering in dynamic networks[C]//Proceedings of 2006 Conference on Applications, Technologies, Architectures, and Protocols for Computer Communications. [S.l.: s.n.], 2006.
- [8] ZHANG Y C, TIAN Y, WANG W D, et al. Federated routing scheme for largescale domain network[C]//Proceedings of IEEE International Conference on Computer Communications poster (Infocom'2020). Piscataway: IEEE Press, 2020.
- [9] FONTUGNE R, ABRY P, FUKUDA K, et al. Scaling in internet traffic: a 14 year and 3 day longitudinal study[J]. ACM Transaction on Networking, 2017.
- [10] XenaNetworks. Microburst[R]. 2019.
- [11] JIANG H, DOVROLIS C. Why is the internet traffic bursty in short time scales?[C]//Proceedings of Sigmetric. New York: ACM Press, 2005.
- [12] KAPOOR R, SNOEREN A C, VOELKER G M, et al. Bullet



- trains: a study of NIC burst behavior at microsecond time-scales[C]// Proceedings of 9 th ACM Conference on Emerging Networking Experiments & Technologies. New York: ACM Press, 2013.
- [13] HUANG Q, LEE P C, BAO Y G. SketchLearn: relieving user burdens in approximate measurement with automated statistical inference[C]//Proceedings of ACM SIGCOMM 2018. New York: ACM Press, 2018.
- [14] HUANG Q, SUN H F, LEE P C, et al. OmniMon: re-architecting network telemetry with resource efficiency and full accuracy[C]//Proceedings of ACM SIGCOMM 2020. New York: ACM Press, 2020.
- [15] CHEN X, HUANG Q, ZHANG D, et al. ApproSync: approximate state synchronization for programmable networks[C]// Proceedings of IEEE ICNP 2020. Piscataway: IEEE Press, 2020.
- [16] CHEN X, LIU H Y, HUANG Q, et al. SPEED: scalable and high-performance deployment for data plane programs[C]// Proceedings of IEEE ICNP 2020. Piscataway: IEEE Press, 2020.
- [17] SRIKANTH K, PADHYE J, BAHL V. Flyways to De-Congest data center networks[C]//Proceedings of Hotnet 2009. [S.l.: s.n.], 2009.
- [18] LIU X, SRIDHARAN A, MACHIRAJU S, et al. Experiences in a 3G network: interplay between the wireless channel and applications[C]//Proceedings of ACM International Conference on Mobile Computing & Networking. New York: ACM Press, 2008.
- [19] BENSON T, ANAND A, AKELLA A, et al. MicroTE: fine grained traffic engineering for data centers[C]//Proceedings the Seventh Conference on emerging Networking Experiments and Technologies 2011. [S.l.: s.n.], 2011.
- [20] VALADARSKY A, SCHAPIRA M, SHAHAF D, et al. Learning to route[C]//Proceedings of the 16th ACM Workshop on Hot Topics in Networks. New York: ACM Press, 2017.
- [21] BOYAN J A, LITTMAN M L. Packet routing in dynamically changing networks: A reinforcement learning approach[C]// Proceedings of the 6th International Conference on Neural Information Processing Systems 1993. New York: ACM Press, 1994.
- [22] PINYOANUNTAPONG P, LEE M, WANG P. Delay-optimal traffic engineering through multi-agent reinforcement learning[C]//Proceedings of IEEE INFOCOM 2019 Workshop on Network Intelligence (NI 2019) Machine Learning for Networking. Piscataway: IEEE Press, 2019.
- [23] XU Z Y, TANG J, MENG J S, et al. Experience-driven networking: a deep reinforcement learning based approach[C]// Proceedings of IEEE Conference on Computer Communications (IEEE INFOCOM 2018). Piscataway: IEEE Press, 2018.
- [24] 蔡鑫, 娄京生. 基于 LSTM 深度学习模型的中国电信官方微博用户情绪分析[J]. 电信科学, 2017, 33(12): 136-141.
- CAI X, LOU J S. Sentiment analysis of telecom official micro-blog users based on LSTM deep learning model[J]. Telecommunications Science, 2017, 33(12): 136-141.
- [25] GIBNEY E. Google AI algorithm masters ancient game of Go[J]. Nature News, 2016, 529(7587): 445.
- [26] LOWE R, WU Y, TAMAR A, et al. Multi-agent actor-critic for mixed cooperative-competitive environments[C]//Proceedings of Advances in Neural Information Processing Systems. [S.l.: s.n.], 2017.
- [27] FOERSTER J, FARQUHAR G, AFOURAS T, et al. Counterfactual multi-agent policy gradients[C]//Proceedings of AAAI 2018. [S.l.: s.n.], 2018.
- [28] ZHANG Y. 6 months of abilene traffic matrices[Z]. 2004.
- [29] UHLIG S, QUOTIN B, LEPROPRE J, et al. Providing publicintradomain traffic matrices to the research community[C]//Proceedings of ACM SIGCOMM Computer Communication Review. New York: ACM Press, 2006.

[作者简介]



桂飞 (1994-), 男, 清华大学博士生, 主要研究方向为智能网络。

程阳 (1992-), 男, 清华大学博士生, 主要研究方向为高性能网络系统的设计与优化、分布式机器学习系统。

李丹 (1981-), 男, 博士, 清华大学教授、博士生导师, 主要研究方向为数据中心网络、网络智能和可信互联网。入选教育部“青年长江学者”奖励计划, 获得国家优秀青年基金项目资助, 国家“973”项目首席科学家, 国家重点研发计划项目负责人。IEEE Transactions on Computers、IEEE Transactions on Wireless Communications 等国际学术期刊编委, ACM SIGCOMM、IEEE INFOCOM 等国际学术会议程序委员会委员。

洪思虹 (1997-), 女, 清华大学硕士生, 主要研究方向为网络智能传输算法以及网络智能路由算法。