软件学报 ISSN 1000-9825, CODEN RUXUEW
Journal of Software,2017,28(Suppl.(2)):81−89

E-mail: jos@iscas.ac.cn
http://www.jos.org.cn
Tel: +86-10-62562563

一种适用突发流量的数据中心网络流调度策略*

张 帆, 胡成臣

(西安交通大学 计算机科学与技术系,陕西 西安 710049)

通讯作者: 张帆, E-mail: xiaoxx_2000@163.com

摘 要: 云数据中心网络的流调度问题是当下的一个研究热点.比较具有实用性的流调度是不假设流信息预先可知,但目前这类流调度方案在流量突发时的表现并不理想.提出了一种针对流量突发情况的流调度方案,通过将每流排队与多级反馈队列调度相结合,实现了一个基于流隔离的多级调度方案FISH,解决了流量突发情况下不同流的排队竞争问题.实验结果表明,该方案性能稳定,可以将小流完成时间降低8.6%以上.

关键词: 数据中心网络;流调度;基于流;多级反馈队列;流完成时间

中文引用格式: 张帆,胡成臣.一种适用突发流量的数据中心网络流调度策略.软件学报,2017,28(Suppl.(2)):81−89. http://www.jos.org.cn/1000-9825/17021.htm

英文引用格式: Zhang F, Hu CC. Flow scheduling policy for burst traffic in data center networks. Ruan Jian Xue Bao/Journal of Software, 2017,28(Suppl.(2)):81−89 (in Chinese). http://www.jos.org.cn/1000-9825/17021.htm

Flow Scheduling Policy for Burst Traffic in Data Center Networks

ZHANG Fan, HU Cheng-Chen

(Department of Computer Science and Technology, Xi’an Jiaotong University, Xi’an 710049, China)

Abstract: The flow scheduling on cloud data center network is a hotspot at present. More practical flow scheduling assume that the flow information is unknown in advance, but the performance of these scheduling scheme is not good enough. By combining the multi-level feedback queue with the per-flow scheduling, this paper designs a multiple level scheduling scheme FISH based on the flow isolation, which solves the queueing competition of different flows. Experimental results show that the proposed scheme has stable performance and reduces the completion time of small flows by up to 8.6%.

Key words: data center network; flow scheduling; per-flow; multi-level feedback queues; flow completion time

近几年,随着云计算的持续火热,许多新兴的应用业务,如网络购物、网络社交、网络直播等对搜索引擎、即时消息发送、视频传输等应用有了更高的要求.这些应用对网络延迟都有着严格的限定,数据中心网络作为实现这些应用的重要平台,高效地运行可以提高用户体验度,为服务商带来更多的收益.如何提高数据中心网络的传输性能成为了时下的研究热点.

流完成时间(flow completion time,简称 FCT)是衡量数据中心网络传输性能的重要指标之一,许多关于流量传输的研究[1−7]都是围绕减小流的延迟进行的.PDQ[3],pFabric[4]和 PASE[5]针对那些大小或最后期限已知的流,让流的调度更接近最短作业优先(shortest job first,简称 SJF)算法.然而实际中有大量应用的流的信息都是无法获取的,针对这些大小或最后期限未知的流提出了 PIAS[6].PIAS 模仿最短作业优先算法,并配合显示拥塞通知(explicit congestion notification,简称 ECN)算法,在整体上实现了小流优先发送,缩短了流的完成时间.然而,数据中心网络中的流量具有高动态性和高突发性,我们观察了 PIAS 在几种流量场景下的表现,发现 PIAS 的性能在

* 基金项目: 国家重点研发计划(2016YFB0800101, 2017YFB0801703); 国家自然科学基金(61672425, 61402357, 61702407)

Foundation Items: National Key Research and Development Program of China (2016YFB0800101, 2017YFB0801703); National Natural Science Foundation of China (61672425, 61402357, 61702407)

收稿时间: 2017-06-30; 采用时间: 2017-10-20

不同场景下的抖动较大.原因在于PIAS的结构设计使其性能不可避免地会受到突发流量的影响.我们希望有一种流调度方案可以在流量突发的情况下,保证所有流依旧可以快速地被调度,特别是让小流得到及时处理.

鉴于这样的情况,我们提出了(flow isolated scheduling hierarchy,简称 FISH),一种为大小未知的流设计的多队列优先级调度方案.FISH 实现了在复杂的数据中心网络流量环境下,保证小流可以得到更快的调度,很大限度地减小了流的 FCT.

网络流量复杂多变,同一个队列中不同大小的流在排队时相互影响,而流的信息无法准确获取,如何在这种情况下保证各种流量被有效地调度呢?FISH 引入了 per-flow 调度,因为 per-flow 调度可以对每个流进行单独的控制[8],使其得到 QoS 保证[9].对于大小未知的流,受 PIAS 启发,我们利用一个多级反馈队列(multi-level feedback queues,简称 MLFQ)对这些流进行调度.MFLQ 根据一个大小未知的流已经发送的字节数,将其分配到多个优先级队列中(大流和小流开始都在高优先级队列中,大流随后降到低优先级队列中).为了利用 per-flow 调度与 MFLQ 调度两者的优点,我们对 MFLQ 进行了多维扩展,将交换机中的每一个优先级队列扩展为多个 per-flow 队列,实现了一个多维的 MLFQ.其中,每一维的多级反馈队列只为一个流服务,从而实现了流之间的隔离,同时也实现了 SJF 算法.

我们使用 NS-2 模拟器[10]在真实的网络负载下对 FISH 进行了评估.由于 PIAS 在现有的信息无关的流调度方案中表现得非常出色,所以把 FISH 与 PIAS 进行了对比.实验结果表明,在普通的流量环境下,FISH 的性能与 PIAS 相当.但在网络流量突发情况下,FISH 比 PIAS 的性能更加优异.

本文第 1 节介绍相关工作.第 2 节通过实验描述现有调度方案存在的问题.第 3 节详细介绍 FISH 方案的设计原理和具体实现.第 4 节通过 NS-2 模拟评估 FISH 在不同场景下的性能,并分析实验结果.第 5 节总结全文.

1 相关工作

现有大量关于数据中心网络流调度研究,与 FISH 有关的工作有 pFabric[4]、DCTCP[1]、PIAS[6]、DQS[11].pFabric 是一种流信息可知的方案,它认为数据中心的传输应该让流调度与速率控制解耦[4];pFabric 一方面给数据包标记优先级序号,并且使用交换机中的优先级队列对流进行调度,另一方面进行简单的速率控制,通过这两种机制使流的 FCT 接近最优.因为掌握了流的各种信息,所以对信息可知的流调度方案一般都希望接近最短剩余处理时间调度算法.DCTCP[1]是数据中心网络专门设计的,它使用 ECN 估计源拥塞的程度,并仅对源端的发送速率进行控制,保证交换机高吞吐量的同时以非常低的缓冲占有率运行,为小流提供了低延迟.由于很多流的信息无法确切感知,PIAS[6]是一种解决传输这类流的解决方案,它利用 MFLQ 队列来模糊地识别一条大小信息未知的流,并且让小流和大流的前面一小部分优先发送,让大流的后面一大部分稍后发送,再配合使用 DCTCP,进一步缩短了流的传输时间.

随着互联网的迅速发展,各种各样的业务在互联网中不断出现,如何为各种应用保证其业务质量成为网络运营商非常关注的问题.在有限的网络资源下,传统的尽力而为的服务已经不能满足这些网络应用在时延、抖动、吞吐量和可靠性等方面的需求.为此,IETF 提出了集成业务(integrated services,简称 IntServ)的概念.网络中的业务被划分为不同的业务流,IntServ 是一种端到端的基于流的 QoS 技术,它可以为不同业务流提供可靠的 QoS[8].Per-flow 调度可以采用不同的调度方法来调度属于不同流的数据包,隔离不同的流,为不同的流提供相应的 QoS.按照传统的方式,由于在路由器上有以百万计的队列需要保持执行,所以 per-flow 调度技术实现的成本太高.在这种情况下,一种动态的队列共享机制 DQS 被提了出来,它通过让每个流动态地共享少量的物理队列,用较低的成本达到与纯 per-flow 调度技术一样的效果[11].FISH 将 per-flow 排队机制首次应用到 MLFQ 调度上,它综合了前两者的优点.一方面,它利用 MLFQ 对信息无法被感知的流的调度优势整体上实现了 SJF 算法;另一方面,它隔离同一优先级中不同大小的流之间的影响,在高可变的网络流量环境下仍然可以缩短流的完成时间.

2 问题描述

本节通过两个例子讨论在网络流量突发时 PIAS 因无法及时调度小流而导致的小流 FCT 增加的问题,并讨

论了在 PIAS 的基础上实现 per-flow 调度算法的可能性.

我们使用 NS-2 测试了 PIAS 在两种场景下的表现.实验拓扑如图 1(a)所示,一台交换机连接了两个服务器,服务器的网卡最大传输速率是 10Gbps.服务器 1 向另一台服务器 2 发送数据流.实验场景如图 1(b)所示,第 1 种场景是先发送小流再发送大流,其中有 8 条小流(每条流的大小为 50KB)和 3 条大流(每条流的大小为 1 000KB)先后进入队列中;第 2 种场景中流发送的顺序是相反的.我们测试了流的平均到达间隔时间(Δt)和到达顺序对 PIAS 的影响.实验结果如图 2 所示,在相同的流到达间隔下,场景 2 与场景 1 相比,在小流传输方面,系统性能最大下降了 19%.在很短的时间内,不同大小的流都涌入到同一个队列中,此时这些流还没有及时出队.如果场景 2 在队列中出现,那么由于在同一个队列中的数据包只遵循 FIFO 调度,小流前面的大流会阻碍小流及时地发送,增加了小流的排队等待时间,从而导致性能下降.

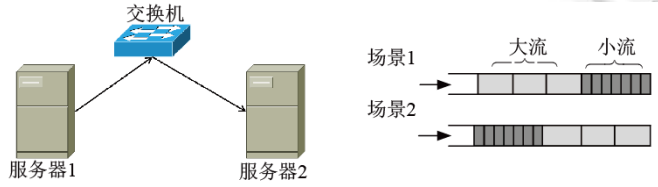

(a) 实验拓扑 (b) 两种场景

Fig.1 Test scenario for PIAS

图 1 PIAS 测试场景

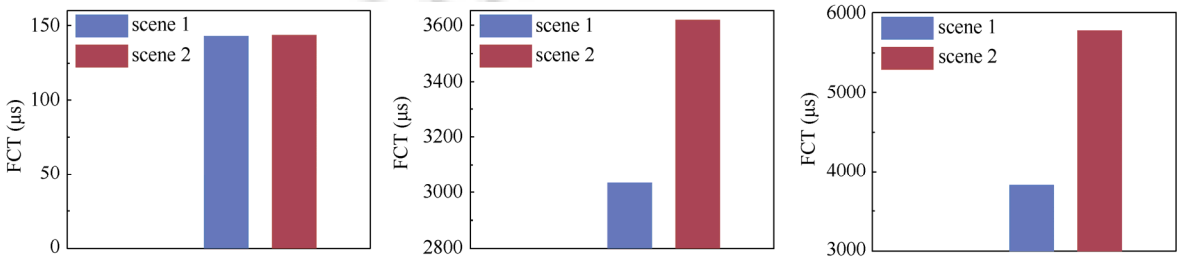

(a) Δt=1ms (b) Δt=0.1ms (c) Δt=0.05ms

Fig.2 FCT of small flow in different scenarios

图 2 不同场景下的小流平均完成时间

3 FISH 的设计

3.1 设计原理

本节介绍了 FISH 的设计.已有的关于未知大小的流的解决方案 PIAS 模拟了 SJF,但缺乏对复杂流量环境的适应性.FISH 不但能够实现 SJF 算法,而且能够适应复杂的流量环境.为了达到这样的目标,我们采用交换机中多个优先级队列实现一个多维的 MLFQ.对 MLFQ 进行了扩展,将每一个优先级队列扩展为多个队列,其中每个队列为一条单独的流服务,实现了一个多维的 MLFQ,如图 3 所示.对于进入到交换机中的每一条流,随着发送字节数的增加,短流在高优先级被优先发送完毕,长流从高优先级降到了低优先级,随后才被发送,从而实现了短流优于长流发送的目的.

Per-flow 调度是基于流的调度方式,它保证了每个流的服务质量,且已应用于高速路由的设计之中.为了实现流之间的隔离,我们将 per-flow 调度应用在 MLFQ 上,原来的方案中,MLFQ 的每一个优先级队中的流按照 FIFO 发送,在 FISH 方案中,同一个优先级中的流被分配到各自属于自己的队列中,这些队列按照轮循的方式发送.如图 3 所示,大流 f1 和小流 f2 进入交换机后,随着它发送的字节数的增加,f1 被划分为两部分 f1_1 和 f1_2, 两

部分先后分别进入到两个队列 Queue1_1 和 Queue2_1 中.f2 较短,只进入到队列 Queue1_2 中.Queue1_1 和 Queue1_2 的优先级最高,Queue2_1 优先级次之.f1_1 和 f2_1 轮流发送预先已设置好的长度,直到发送完毕.然后 f1_2 才被发送.

FISH 对传统 MLFQ 进行了多维扩展,使得同一优先级中的每个流可以被及时地服务,同时也实现了 SJF 算法,保证了小流优先于大流被调度.

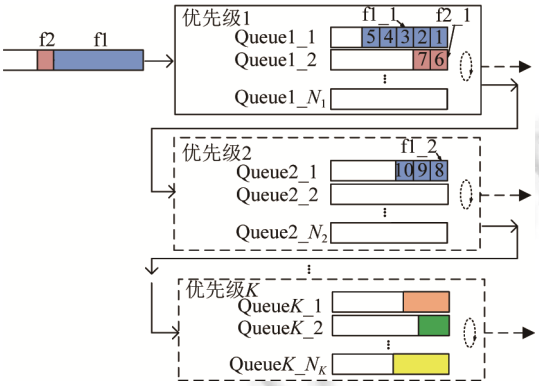

Fig.3 FISH scheduling graph

图 3 FISH 调度示意图

3.2 FISH 的具体实现

FISH 方案主要由交换机完成.我们把流的识别、分配以及调度全部放在交换机上加以实现.如图 4 所示,当数据包进入交换机后,交换机通过对数据包的五元组(源 IP 地址、目的 IP 地址、协议号、源端口、目的端口)的识别来判断该数据包所属的流.对进入交换机的每一条流,计数器会记录这条流有已经进入到交换机中数据包的数目.当一条流的计数器达到某个阈值时,该流的数据包的 DSCP 值会被修改为相应的优先级,然后数据包被分配到相应的优先级下的队列中.

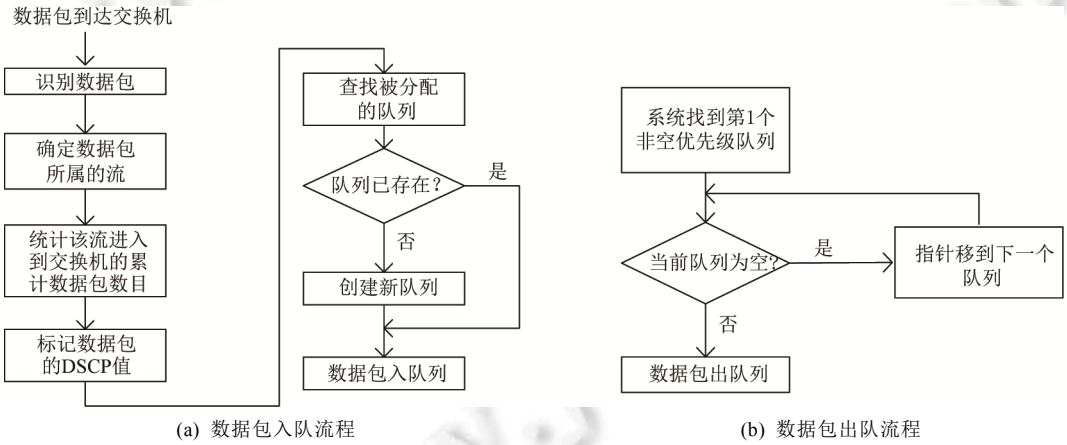

(a) 数据包入队流程 (b) 数据包出队流程

Fig.4 FISH data packet processing

图 4 FISH 数据包处理流程

为了实现 FISH,我们在交换机上将 per-flow 调度与优先级队列调度相结合,实现了一个全新的设计. Per-Flow 调度在交换机的具体实现上可以分为队列的静态划分和动态划分.静态划分简单、直观,但却无法完全满足许多应用的性能需求.动态划分根据流的大小和数量为其分配队列,它对缓存的利用更加充分和灵活,而且可以满足不同应用对性能的潜在需求.

为了在交换机上实现了 per-flow 调度,我们借鉴了动态队列共享(dynamic queue sharing,简称 DQS)机制[11],为具有相同优先级的每个流创建属于自己的队列.当一条新流进入交换机的缓存后,系统会自动地为该流创建队列.当一个队列长时间为空时,队列就会被清除.队列的数量由该流的长度决定.如果流很长,那么该流会从高优先级队列中逐渐降到低优先级队列,所以系统会为它创建多个队列;如果流很短,那么系统很可能只为它创建一个队列.

以图 3 中的流 f1 和 f2 为例,大流 f1 进入交换机后,随着它发送的字节数的增加,系统先后为它创建了两个队列 Queue1_1 和 Queue2_1.同理,由于流 f2 比较短,系统为它创建了一个队列 Queue1_2.队列 Queue1_1 和 Queue1_2 在最高优先级中,所以队列 Queue1_1 和 Queue1_2 轮循发送它们中的数据包,假设每个队列每次只有一个数据包出队,根据本方案中的队列调度算法,数据包发送顺序为 P1→P6→P2→P7→P3→P4→P5.当最高优先级队列中的数据包发送完毕后,开始发送第 2 个优先级队列中的数据.队列 Queue2_1 的优先级次之,所以只能依次发送该队列中的流 f2 的数据包 P8→P9→P10.当一个队列长时间为空时,队列就会被清除.

以下给出了队列调度算法.

算法 1. Queue scheduling.

```
while All_queue_length>0
    do for prio=1 to Prio_queue_num
            do while Prio_queue_length(prio)>0        //判断同一优先级队列是否为空
                    do if queue[queid]_length()>0
                            then queue_deque()        //数据包出队
                                 queid←queid+1        //指针移动到下一个队列
                            else queid←queid+1
return NULL
```

默认情况下,系统优先调度高优先级队列中的数据包.但当高优先级队列中不断有小流存在时,由于小流一直被调度,那么处于低优先级队列中的大流就会“挨饿”.为了解决挨饿问题,我们打破了这种严格的优先级限制,将带宽分配给了不同的优先级,即发送一部分高优先级中的流,然后再发送一部分低优先级中的流,这样可以保证低优先级中的大流不会被饿死.

4 实验评估

我们用 NS-2 评估了 FISH.围绕两个关键问题来评估.

(1) FISH 在多种复杂流量环境下表现如何?通过 NS-2 模拟,与 PIAS 相比,在一般的流量环境下,FISH 与 PIAS 的性能相差不大;在流量突发的环境下,FISH 与 PIAS 相比,在小流平均的完成时间上最大降低了 3.23%,在 99%的小流完成时间上最大降低了 19.92%.

(2) FISH 在大型数据中心网络中表现如何?使用大规模 NS-2 模拟,结果表明,FISH 可以扩展到大型数据中心网络中.与 PIAS 相比,可以在很大程度上减小小流的 FCT.经过测试,在网络搜索负载下,降低了小流的平均 FCT 可达 8.6%,对于 99%的小流平均 FCT 最高可以减小 20.9%.

4.1 简单拓扑实验

我们使用真实的数据中心负载,在简单的拓扑环境下测试了 FISH 的表现.

拓扑结构:为了验证 FISH 的有效性,用 NS-2 搭建了一个简单的拓扑,如图 1 所示.2 台服务器连接 1 台交换机,2 台服务器分别为流量的发送端和接收端.服务器到交换机的链接采用 10Gbps 链路.

流量负载:使用真实的网络搜索业务[6]作为流量负载,发送端向接收端发送 100 条流,流的大小基本分布在 1KB~10M 之间,流大小的概率分布函数如图 5 所示.本实验中,设置网络搜索负载大小为 80%,根据流的大小把流划分为 3 类:小流(0,100KB]、中型流(100KB,10MB]和大流(10MB,∞).

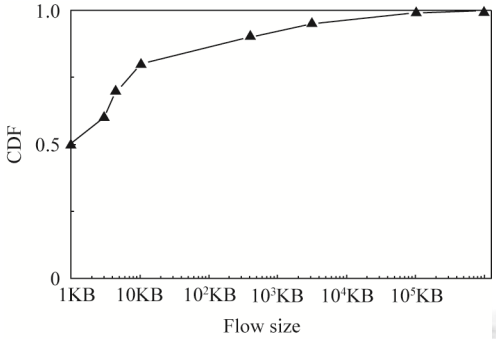

Fig.5 Flow distribution

图 5 流量分布

我们测试了 FISH 在一般的流量环境和流量突发环境下的性能.改变流的平均到达间隔(Δt)来模拟流量突发的情况,对比了 FISH 和 PIAS 在这些环境下的表现.在本文中,设置每个队列每次只发送一个数据包.FISH 和 PIAS 的性能表现如图 6 所示.经过统计,在一般流量环境下,流到达间隔为 1ms,在这种环境下,FISH 对各种大小的流的完成时间与 PIAS 相差不大,如图 6(a)所示.但是随着流达到间隔的不断减小,FISH 的性能优势逐渐显示出来.在流到达间隔为 0.1ms 和 0.01ms 时,如图 6(b)和图 6(c)所示,FISH 比 PIAS 在小流平均完成时间上分别减小了 2.64%和 3.23%;FISH 比 PIAS 在 99%的小流平均完成时间上分别减小了 19.92%和 2.2%.一般流量环境中的流到达间隔比较大,PIAS 中的队列同时被多条流占用的概率降低,而这种情况很难让 FISH 发挥它的作用,所以此时 FISH 和 PIAS 的性能差距不大.而流量突发会使队列被多条流占用的概率增加,此时 FISH 就可以完全发挥它的调度优势,所以 FISH 的性能就会比 PIAS 要好.

针对所有的小流、中型流和大流的完成时间,FISH 与 PIAS 相差不超过 0.6%,见表 1 和表 2.这是由于 FISH 使小流较早被调度,导致大流或者中型流在更晚一些时刻才能被调度完.

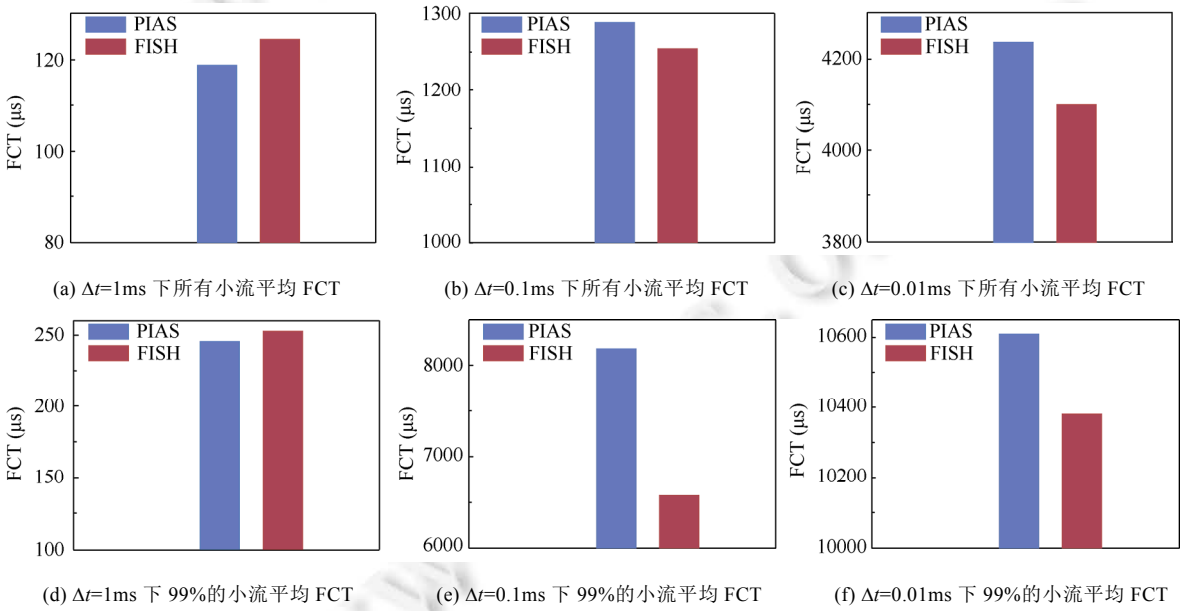

(a) Δt=1ms 下所有小流平均 FCT (b) Δt=0.1ms 下所有小流平均 FCT (c) Δt=0.01ms 下所有小流平均 FCT

(d) Δt=1ms 下 99%的小流平均 FCT (e) Δt=0.1ms 下 99%的小流平均 FCT (f) Δt=0.01ms 下 99%的小流平均 FCT

Fig.6 FCT of small flow in the Web search workload

图 6 网络搜索负载下的小流完成时间

Table 1 FCT of medium flows

表 1 中型流的平均 FCT

流到达的平均间隔(ms)	中型流的平均 FCT(ms)	
	PIAS	FISH
1	11.133	11.157
0.1	37.907	38.133
0.01	43.296	43.534

Table 2 FCT of large flows

表 2 大流的平均 FCT

流到达的平均间隔(ms)	大流的平均 FCT(ms)	
	PIAS	FISH
1	79.672	79.450
0.1	122.966	123.287
0.01	128.476	128.198

4.2 数据中心网络拓扑实验

为了观察 FISH 在数据中心网络中的性能,我们在 NS-2 上构建了一个数据中心的网络拓扑来加以评估.使用了真实的数据中心网络负载评估了 FISH.数据中心网络拓扑采用现在比较常用的叶脊(leaf-spine)结构[12],如图 7 所示,一共有 4 台叶交换机、4 台脊交换机和 16 台服务器,叶交换机的上行链路为 20Gbps,下行链路为 10Gbps;服务器两两相互发送数据流共 800 条.设置网络搜索负载大小为 80%.我们选择第 4.1 节给出的实验中的流量作为流量负载,调整流到达间隔,测试 FISH 在各种流量环境下的性能.

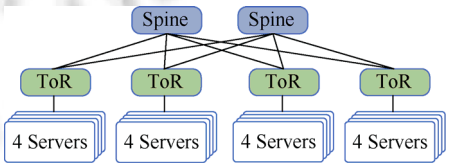

Fig.7 Data center network topology

图 7 数据中心网络拓扑

实验结果显示,在小流的处理上,FISH 明显优于 PIAS.FISH 降低了小流平均完成时间高达 8.6%,降低了 99%的小流平均完成时间最高可达 20.9%.对于中型流和大流,FISH 的性能没有 PIAS 那么好,但是 FISH 与 PIAS 相差不超过 3.8%.

影响 FISH 性能的不但与其机制本身有关,而且与硬件条件也有很大的关系.队列容量指的是所有队列可以容纳的数据包数量.我们比较了不同队列容量的下 FISH 与 PIAS 在不同流到达间隔(Δt)下对小流的处理能力,实验结果如图 8 和图 9 所示,其中,FISH-240、FISH-480 和 FISH-960 分别表示 FISH 中的队列最大可以容纳 240 个、480 个和 960 个包.在实验中我们发现,队列容量对 FISH 的影响比较大.在流量突发情况下,FISH 的性能好坏与队列容量的大小呈正相关性.对于小流,在流量没有发生突发时,如图 8(a)所示,不同容量下的 FISH 比 PIAS 性能都好,最高可以提高 9.5%.这是因为,由于流的到达间隔比较大,FISH 中的队列被数据包占满的概率比较低,队列拥塞丢包出现的情况比较少,所以队列容量的变化对 FISH 影响并不大.在流量突发时,如图 8(b)和图 8(c)所示,FISH 在队列容量为 240 个包时的性能没有 PIAS 好,随着队列容量逐渐变大,FISH 的性能才逐渐超过 PIAS.出现这种现象的原因在于,当 A 的队列容量为 240 个包时,突发的流量使较短的队列在很短的时间内被占满,拥塞丢包导致大量的数据包重传,所以 FISH 在队列容量不够大时性能可能没有 PIAS 好.但是,如图 8(b)~图 8(g)所示,随着 FISH 的队列容量的不断扩展,在降低小流平均完成时间和 99%的小流平均完成时间上,FISH 的性能越来越好.例如,在流到达间隔为 0.01ms 时,随着队列容量的不断增大,在 99%的小流平均完成时间上,在队列容量为 480 个包时,FISH 比 PIAS 性能高 1.8%;在队列容量为 960 个包时,FISH 比 PIAS 性能高 8.2%.由于队列有了足够大的空间就可以容纳更多的等待发送的数据包,FISH 在容量扩展到 960 个包时的性能明显优于

PIAS.在实际部署中,可以考虑增加队列容量以提高 FISH 的性能.

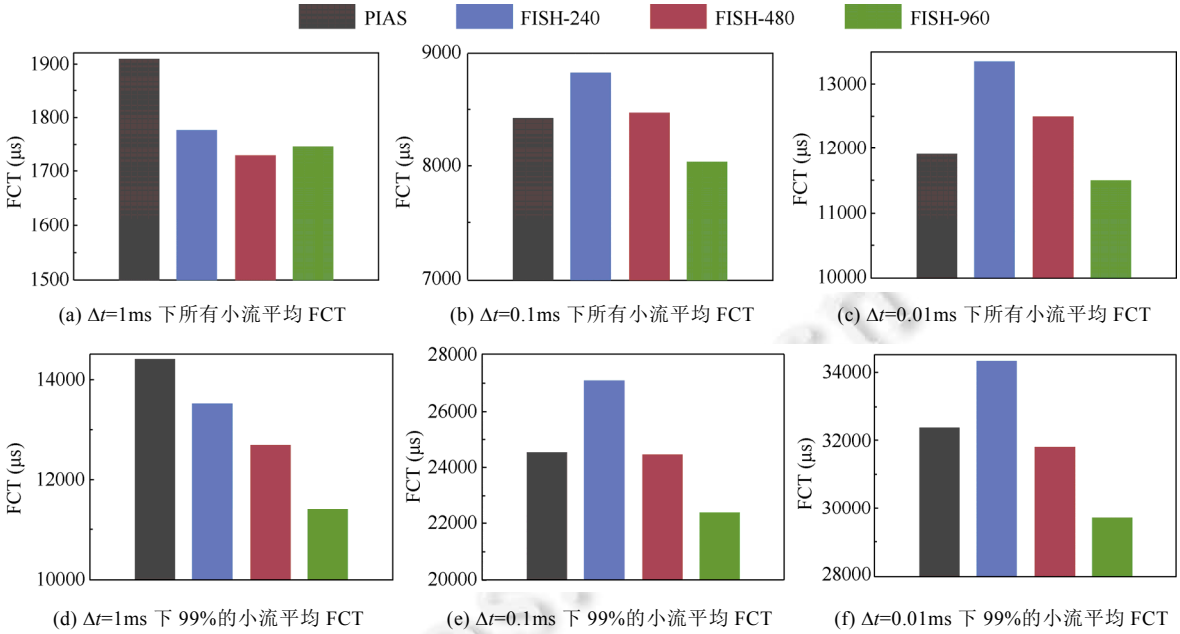

Fig.8 FCT for small flows by FISH and PIAS under the data center network

图 8 FISH 与 PIAS 在数据中心网络下对小流进行处理的性能比较

FISH 在处理中型流和大流方面,如图 9 所示,FISH 与 PIAS 的性能相接近,甚至 FISH 没有 PIAS 那么好,但是它们相差最多不超过 3.8%.因为 FISH 已让较短的流得到了优先的调度,所以较大的流可能会花费更多的时间才能被传输完毕.

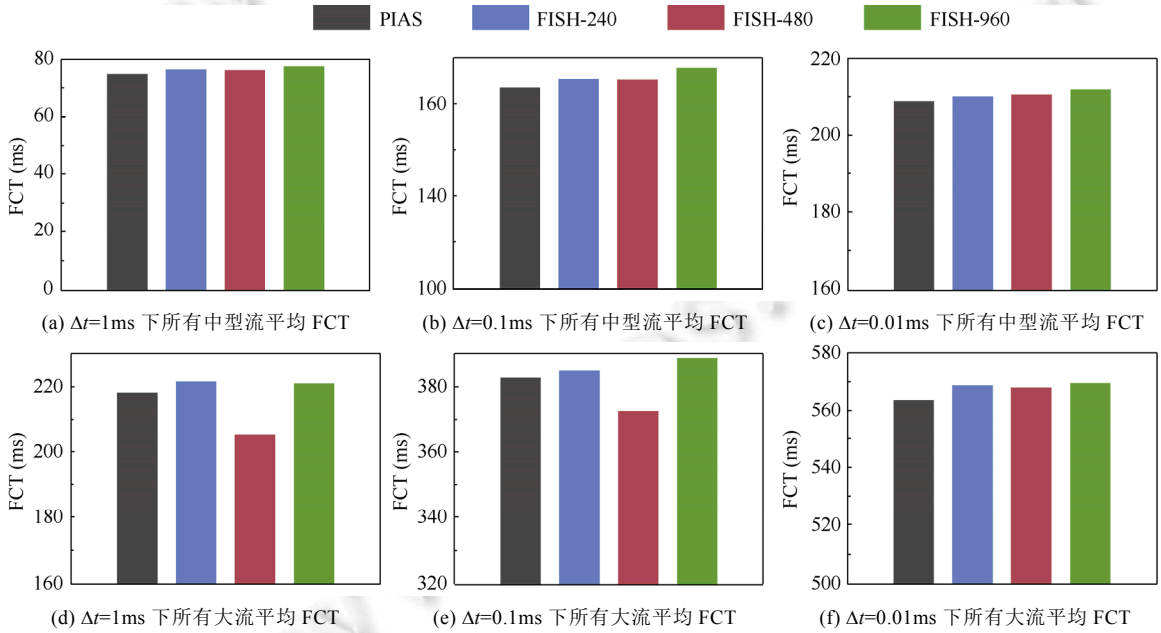

Fig.9 FCT for medium and large flows by FISH and PIAS in the data center network

图 9 FISH 在数据中心网络下中型流和大流的平均 FCT

5 结 论

我们针对数据中心网络流量突发性提供了一种流调度方案 FISH.该方案把 per-flow 调度的思想引入到 MFLQ 中,在交换机上实现了一个多维的 MFLQ,对流进行调度,解决了流量突发情况下,不同大小的流的排队干扰问题.我们通过一系列实验评估了 FISH 在不同流量环境下的性能,对比实验结果表明,在网络流量突发的情况下,FISH 在减小所有流(特别是小流)的完成时间方面更有优势.

References:

[1] Alizadeh M, Greenberg A, Maltz DA, Padhye J, Patel P, Prabhakar B, Sengupta S, Sridharan M. Data center TCP (DCTCP). In: Bonaventure O, ed. Computer Communication Review. New York: ACM, 2010. 63−74.

[2] Alizadeh M, Kabbani A, Edsall T, Prabhakar B, Vahdat A, Yasuda M. Less is more: Trading a little bandwidth for ultra-low latency in the data center. In: Proc. of the 10th USENIX Symp. on Networked Systems Design and Implementation (NSDI). Berkeley: USENIX, 2012. 19.

[3] Hong CY, Caesar M, Godfrey P. Finishing flows quickly with preemptive scheduling. In: Bonaventure O, ed. Computer Communication Review. New York: ACM, 2012. 127−138.

[4] Alizadeh M, Yang S, Sharif M, Katti S, McKeown N, Prabhakar B, Shenker S. pFabric: Minimal nearoptimal datacenter transport. In: Bonaventure O, ed. Computer Communication Review. New York: ACM, 2013. 435−446.

[5] Munir A, Baig G, Irteza SM, Qazi IA, Liu AX, Dogar FR. Friends, not foes-synthesizing existing transport strategies for data center networks. In: Bonaventure O, ed. Computer Communication Review. New York: ACM, 2014. 491−502.

[6] Bai W, Chen L, Chen K, Han DS, Tian C, Wang H. Information-Agnostic flow scheduling for commodity data centers. In: Proc. of the 12th USENIX Symp. on Networked Systems Design and Implementation (NSDI). Berkeley: USENIX, 2015. 455−468.

[7] Chen L, Chen K, Bai W, Alizadeh M. Scheduling mix-flows in commodity datacenters with Karuna. In: Proc. of the ACM SIGCOMM. New York: ACM, 2016. 174−187.

[8] Braden R, Clark D, Shenker S. Integrated services in the Internet architecture: An overview. IERF RFC 1633, 1994.

[9] Kumar VP, Lakshman TV, Stiliadis D. Beyond best effort: Router architectures for the differentiated services of tomorrow's Internet. IEEE Communications Magazine, 1998,36(5):152−164.

[10] Network Simulator NS-2. https://www.isi.edu/nsnam/ns/

[11] Hu C, Tang Y, Chen X, Liu B. Per-Flow queueing by dynamic queue sharing. In: Proc. of the 26th IEEE Int'l Conf. on Computer Communications (INFOCOM). Piscataway: IEEE, 2007. 1613−1621.

[12] Cisco Data Center Spine-and-Leaf Architecture: Design Overview. https://www.cisco.com/c/en/us/products/collateral/switches/nexus-7000-series-switches/white-paper-c11-737022.pdf

张帆(1985－),男,陕西西安人,博士生,主要研究领域为计算机网络,数据中心网络.

胡成臣(1981－),男,博士,教授,博士生导师,CCF 专业会员,主要研究领域为计算机网络,软件定义网络,云数据中心网络.