

生成式大模型承载网络架构与关键技术探索



Network Architecture and Technologies for Large Generative Models

唐宏/TANG Hong, 武娟/WU Juan, 徐晓青/XU Xiaoqing, 张宁/ZHANG Ning

(中国电信股份有限公司研究院, 中国广州 510630)
(Research Institute of China Telecom Company Ltd., Guangzhou 510630, China)

DOI: 10.12142/ZTETJ.202402008

网络出版地址: <http://kns.cnki.net/kcms/detail/34.1228.TN.20240408.0924.004.html>

网络出版日期: 2024-04-09

收稿日期: 2024-02-20

摘要: 生成式大模型训练需要超大规模低时延、高带宽、高可用的网络承载底座。对生成式大模型下高性能网络基础设施的技术发展路线和实现方案进行了研究, 认为商用部署时需针对不同训练阶段的工作负载和流量模式, 开展定制化网络架构设计和传输协议优化。流控/拥塞控制技术、负载均衡技术、自动化运维技术和面向广域远程直接内存访问 (RDMA) 的确定性网络传输技术是未来的重点研究方向。

关键词: 生成式大模型; RDMA; 网络拥塞控制; 网络负载均衡

Abstract: The training of large generative models has posed demands for ultra-large-scale, low latency, high bandwidth, and high-availability network infrastructure. The technological development roadmap and implementation schemes of high-performance network infrastructure for large models are investigated. It is believed that the customized network architecture design and transport protocol optimization should be carried out based on workloads and traffic patterns at different training stages during commercial deployment. Flow control/congestion control technologies, load balancing technologies, automated operation and maintenance solutions, and deterministic network transmission technologies for wide-area remote direct memory access (RDMA) are key research directions for the future.

Keywords: large generative model; RDMA; network congestion control; network load balancing

引用格式: 唐宏, 武娟, 徐晓青, 等. 生成式大模型承载网络架构与关键技术探索 [J]. 中兴通讯技术, 2024, 30(2): 50-55. DOI: 10.12142/ZTETJ.202402008

Citation: TANG H, WU J, XU X Q, et al. Network architecture and technologies for generative models [J]. ZTE technology journal, 2024, 30(2): 50-55. DOI: 10.12142/ZTETJ.202402008

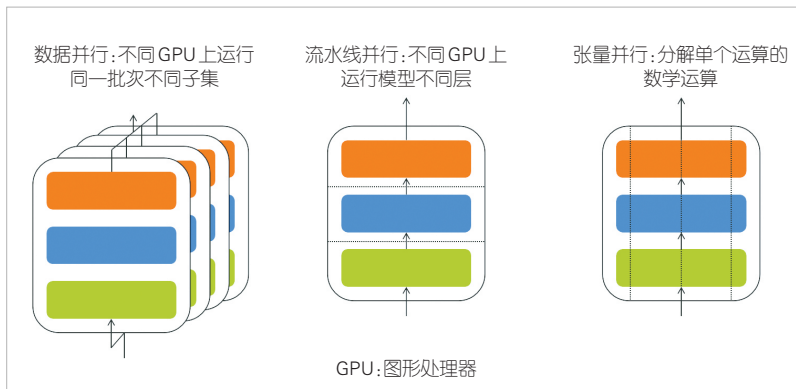
1 生成式大模型对网络基础设施的挑战

近年来, 以 ChatGPT、Sora 为代表的通用生成式大模型的研究取得了显著进展。生成式大模型的参数规模已

实现了从千万级别到万亿级别的飞跃, 并朝着十万亿级别前进^[1]。由于数据量巨大, 需要海量的图形处理器 (GPU) 做并行计算, 而大量的 GPU 并行计算亟需强大的基础网络支撑。与传统的数据中心网络架构相比, 生成式大模型组网呈现以下新需求:

1) 超大规模组网^[2]。在生成式大模型训练时, 数据并行、流水线并行和张量并行同时存在, 如图 1 所示。数据并行和流水线并行所需的“参数面大网”需要跨服务器通信, 规模可达十万甚至百万级别的卡数, 具有超大规模、高网络

容量以及高接入带宽等特点。而实现张量并行的“参数面小网”则通常局限于单个服务器范围内, 具有规模小、容量大以及高接入带宽等特点。



▲图 1 3层模型上的并行计算

2) 超高带宽。机内通信中GPU间的AllReduce集合通信数据量可达百GB级别。机间GPU通信涉及多种并行模式，产生大量集合通信数据，机间GPU的高速互联对于网络的单端口带宽、节点间的可用链路数量及网络总带宽提出了很高的要求。同时，高速串行计算机扩展总线标准(PCIe)的总线带宽限制了网卡性能的发挥，需适配更高带宽的总线技术以提升机间通信效率。

3) 超低时延。对于千亿参数模型来说，通信的端到端耗时占比仅为20%，而对于万亿参数模型，占比增加至50%^[1]。传统的流控算法和拥塞控制算法在面对生成式大模型训练网络时，会遇到拥塞头阻、拥塞扩散等挑战。此外，AI训练中流量的特征是“少流”和“大流”，使得传统的等价多路径(ECMP)流量均衡机制因ECMP哈希极化问题造成链路上流量不均而失效。

4) 自动化运维。当GPU集群规模达到一定量级后，保障集群系统的稳定高效运行就成为大模型工程化实践中极其重要的环节。与单点GPU故障相比，网络故障会影响数十个甚至更多GPU的连通性。高性能网络的自动化部署、一键式故障定位和业务无感自愈，将决定整个集群的计算稳定性。

随着生成式大模型参数规模的快速增长，传统的数据中心网络架构已经很难满足其训练需求。高性能、高可用的承载网络底座将成为推动其发展的核心基础设施。

2 大模型云网基础架构与关键技术

2.1 网络架构

传统的数据中心拓扑结构为3层的树形拓扑结构。树形结构原理简单，易于部署，但是当面对大模型训练中要求集群内服务器协作完成训练任务的场景时，该结构拓展能力显得不足，服务器间通信受限。

与传统树形网络拓扑中的逐层带宽收敛相比，Fat-Tree网络具有无阻塞和无带宽收敛的特性^[3]，目前被主流公有云厂商大规模应用于GPU密集型集群中^[4]，如图2所示。单台服务器配备高性能的400 Gbit/s NIC网卡，K台服务器为一组，通过架顶式(ToR)交换机互连。ToR交换机与聚合交换机相连形成一个Pod，实现跨机架的连接。Pod与主干交换机相连，确保中央处理器(CPU)集群中的服务器能够实现any-to-any通信。但是当网络大规模扩展时，受到核心交换机端口数限制，Fat-Tree的横向拓展能力变差^[5]。同时，为数以万计的GPU提供非阻塞连接的成本非常昂贵。

生成式大模型的发展确立了以GPU为中心的集群主导

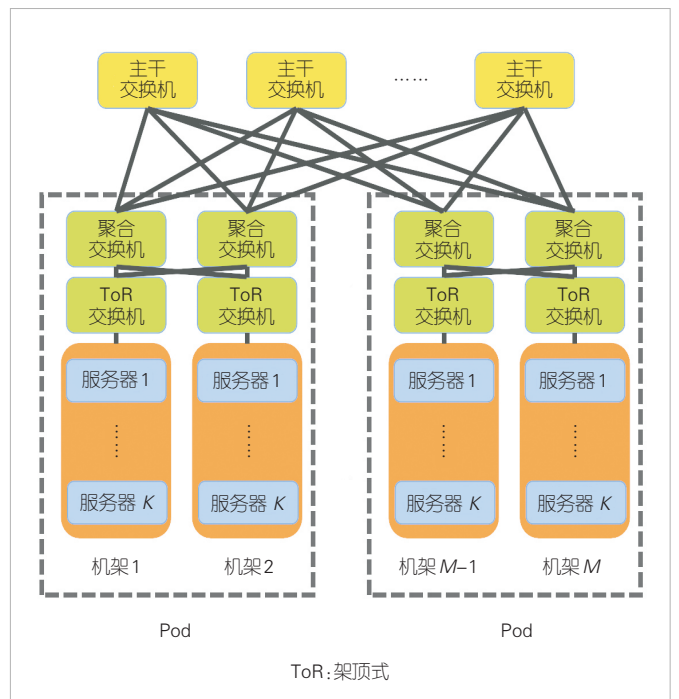
地位。现阶段，GPU间通信采用层次化网络承载：

1) 机内网络：利用PCIe总线、NVLink、NVSwitch等技术，实现单台服务器内等多个GPU高带宽短距离互联，为每个GPU提供太比特级的无阻塞any-to-any带宽输入/输出，以便将短程通信流量驻留在高带宽域内。

2) 机间网络：利用网卡+交换机模式，实现多个高带宽域互连。服务器间使用远程直接内存访问(RDMA)将数据(中间结果、梯度等)从一个GPU内存传输到另一个GPU内存中(在不同服务器上)。

在生成式大模型训练中，模型参数和数据集分布在集群中的不同GPU上，开展并行训练。训练各阶段的工作负载特征(参数大小、数据集大小和模型架构)不同，流量模型也差异很大。为此，模型设计在优化网络拓扑和提高GPU效率方面发挥着至关重要的作用。在实际网络部署中，需要根据各训练阶段的工作负载模型和流量特征，有针对性地开展网络拓扑设计优化和硬件设备(如交换机)定制。如Google使用了3D环面和光学主干交换机，Meta使用的具有超额订阅主干链路的轨道优化叶交换机。一些高性能计算(HPC)结构还使用蜻蜓拓扑来优化GPU之间的跳数。

目前，大模型集群多部署于同一个地域机房内。随着大模型训练的模型参数规模、数据规模和算力规模的快速发展，单个数据中心机房的硬件设施如电力、液冷、空调等硬件基础设施能力将趋于极限。大模型集群数据中心的超长距



▲图2 Fat-Tree网络架构

广域互联场景需求将逐步增加。但是，与数据中心内部大模型流量相比，广域网承载了多种不同类型的业务，流量特征复杂。虽然流控和拥塞控制等机制使得RDMA在数据中心内部实现了落地部署，但在复杂组网的广域环境下，RDMA远距离直连传输技术并不成熟，在现网中难于规模部署。运维人员需要根据不同的网络环境和流量模型进行RDMA参数设计和调优，这将会面临运维利用率、拥塞、时延等一系列挑战^[6]。

相比之下，面向广域RDMA的确定性网络技术（Det-Net）较为成熟，成为近期研究热点。随着灵活以太网（FlexE）、切片分组网（SPN）、时间敏感网络（TSN）、优先级调度队列增强机制、网络演算等各类确定性技术的不断涌现，后续可通过延续优先级流控（PFC）信号、长距离拥塞控制、网络负载均衡等技术实现RDMA的长距离扩展。

2.2 数据传输技术

在生成式大模型训练中，服务器之间需要频繁地进行大量数据的传输和交换。传统的传输控制协议/互联网协议（TCP/IP）在数据传输的过程中需要在用户空间与内核空间之间多次拷贝，降低了数据传输效率。相比之下，RDMA允许应用程序直接访问远程节点的内存，不经过内核，具有高吞吐、低延迟、无CPU占用等优点，可提升模型训练效率，更为适合生成式大模型训练。RDMA从1999年诞生以来，经过20年的发展，技术逐步从高大上的HPC领域走向广阔的通用数据中心领域，广泛应用于大模型训练、高性能计算等场景。

RDMA主要包括3种类型协议：InfiniBand（简称IB）、基于以太网的RDMA（RoCE）以及基于TCP/IP协议栈的RDMA（iWARP）。3种协议都符合RDMA标准，使用相同的上层接口，具体如图3所示。

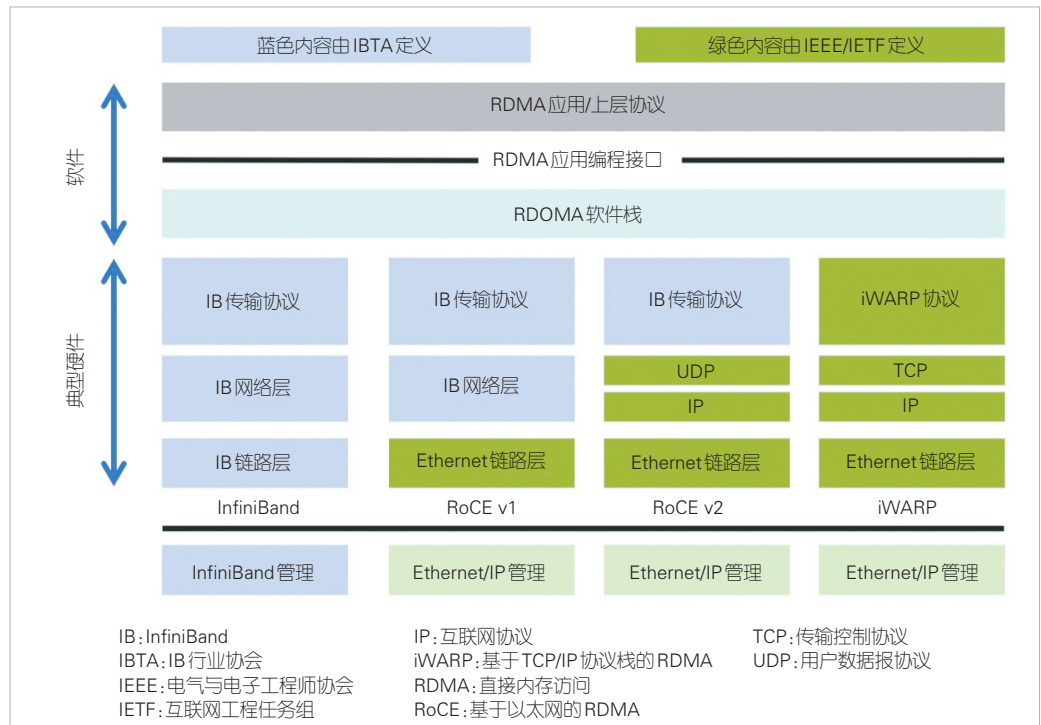
IB从链路层到传输层定义了一套全新的层次架构，是为高性能计算设计的专用技术。IB在部署时需要专用设备，如IB专用交换机、IB专用网卡、IB

专用线缆等，无法与现有的以太网设备兼容。相比于传统以太网，IB具备高带宽、低延迟的数据传输能力以及无损网络的特征，可满足大型数据中心和超级计算中心对高性能网络的需求。但是，IB体系独立封闭，采购维护成本高昂，现阶段主要被用于高性能计算领域，如超级计算机、数据中心和科研机构等。

现网中部署着大量基于以太网的产品。为了扩大RDMA的应用范围，IB行业协会（IBTA）组织定义了基于以太网（Ethernet）的RoCE技术标准，允许在不依赖IB专用硬件的情况下使用RDMA。

RoCE通过扩展以太网协议栈，使标准以太网设备支持RDMA操作，实现了高性能远程内存访问与以太网易用性和广泛部署特点的结合。现阶段RoCE有两个主要版本：RoCEv1和RoCEv2。RoCEv1发布于2010年，是基于以太网链路层实现的RDMA协议，但由于它不支持路由，也没有拥塞控制机制，难以在数据中心规模使用。RoCEv2版本是对RoCEv1版本的重大改进，它基于以太网的用户数据报协议（UDP）。RoCEv2支持路由，并且定义了基于显式拥塞通知（ECN）/拥塞通知报文（CNP）的拥塞控制机制。相同场景下，RoCE虽然较IB性能有所降低，但是因其性价比更高，目前已经在一些超大规模数据中心商用部署。

iWARP是国际互联网工程任务组（IETF）提出的基于TCP的RDMA协议。由于TCP是面向连接的可靠协议，这使



▲图3 远程直接内存访问协议

得iWARP在面对有损网络场景时相比于RoCEv2和IB具有更好的可靠性。但是大量的TCP连接会耗费很多的内存资源,另外TCP复杂的流控等机制会导致性能问题,限制了其应用范围,现阶段并未大规模使用。

综上所述,IB在高性能计算领域表现出色,可提供卓越的性能、低延迟和可扩展性,目前在高性能计算领域占据较大优势。相比之下,RoCE则更容易集成到现有以太网基础设施中,并具有较低的成本,是现阶段大模型训练网络的主流方案。

生成式大模型的迅速发展对底层承载网络的性能要求越来越高。业界仍持续开展传输协议的创新。一些云计算和互联网巨头推出新的自研协议。例如,亚马逊提出的可扩展的可靠数据报(SRD)^[7]。SRD设计了多路径负载均衡机制,利用尽可能多的不拥塞的网络路径喷洒数据包,在上层消息传递层实现对可靠但乱序的交付数据包进行顺序恢复。通过多路径发送和数据包重排序,提升了网络吞吐能力,降低了传输延迟。

2023年,由众多云计算和网络科技巨头组成超以太网联盟,针对IB的封闭生态和原有RoCE的不足,提出了下一代人工智能(AI)和HPC网络的协议:超级以太网传输(UET)^[8]。基于IP和以太网进行设计,在基于多路径和数据包喷洒负载均衡、Incast管理机制、高效的速率控制算法、允许乱序数据包传递的应用程序编程接口(API)等方向进行了创新,以减少针对特定网络和负载对拥塞算法的复杂参数调优,支持百万节点的大规模网络扩展。

在2023开源计算(OCP)全球峰会上,谷歌还提出基于新硬件的传输协议Falcon^[9],集成了谷歌多年在网络传输方面的一系列创新技术,包括拥塞控制Swift和保护性负载均衡(PLB)等,推动以太网现代化,以满足下一代大规模AI集群网络的高可靠、高性能、低时延需求。

2.3 拥塞控制技术

RDMA设计目标是高性能和低延迟,它对于底层网络的稳定性和可靠性有极高的要求。网络的可用性决定了整个集群的计算稳定性。RDMA在无损网络状态下可以满足速率传输。但一旦发生丢包,将启动“go-back-N”重传机制,放弃已到达的多个包,重新传输N个包,性能急剧下降。然而,现网拓扑复杂度高,流量流向不可预测。因此流控、拥塞控制、负载均衡机制对于RDMA现网落地商用非常重要。

传统的RDMA网络采用基于优先级的流量控制(PFC)流控实现无损以太网^[10]。PFC允许交换机在传输数据帧时,对不同数据流设置不同的优先级。一旦交换机的队列超过设

定门限,通过逐跳的流量反压,限制发送方的流量速率保障网络无丢包。PFC流控可以在理论上保证不丢包,但PFC以端口级别运行,是一种粗粒度控制机制。规模部署时存在头部阻塞、受害者流、PFC风暴和PFC死锁等问题。

流级别的拥塞控制算法可以缓解PFC缺陷。网络路径上的交换机对流量拥塞情况进行标记。携带拥塞标记信号的报文到达接收者后,再被传回发送者由其根据网络拥塞情况进行调速。在充分利用带宽的前提下,降低网络拥塞程度可以避免频繁触发PFC。现阶段存在多种拥塞控制算法,已大规模部署的有:数据中心量化拥塞通知(DCQCN)^[11]、基于延迟的拥塞控制(TIMELY^[12]、Swift^[13])和高精度拥塞控制(HPCC)^[14]。它们主要区别在于采用的拥塞反馈信号和发送端速率调整方式不同。

DCQCN采用IP报文头中的显示拥塞指示算法(ECN)作为拥塞标记。发送端根据ECN标记情况来推测网络拥塞情况,对源速率进行调整。但ECN标记只携带了有限的信息,拥塞控制调节的颗粒度较粗。目前RDMA网卡商业上直接可用,应用最为广泛。

TIMELY将数据包的往返时延(RTT)作为反馈信号来调整发送端的速率。发送者在主机网卡上对端到端RTT进行测量,基于其变化进行梯度计算,再根据梯度实现基于速率的调速方法。Swift在TIMELY基础上进行改进,将时延进一步区分为网络拥塞和主机拥塞造成的时延,并维持两个拥塞窗口进行调速。目前主要是在Google数据中心使用,依赖于Google的自研网卡。

HPCC利用带内网络遥测收集更详细的链路和端口负载信息,包括时间戳、队列长度、已传输字节数和链路带宽容量等,并以此调整发送端的发送窗口,实现高精度拥塞控制。

面向超大规模的大模型集群网络,上述拥塞控制和流控技术的性能仍然需要提升。现阶段的研究主要集中在两个方向:一方面研究更合适的效能函数来准确评价网络环境的拥塞状态,更准确地探测可用带宽和时延等参数,使发送端获得更准确的数据,从而提高决策的精确性;另一方面,可以进一步细化拥塞窗口的调节方案和不同类型流量调度机制,在兼顾网络的稳定和带宽利用率的同时,保证数据传输质量。

此外,在研的新一代的RDMA网卡将采用更为高效的丢包恢复机制和更好的端到端流控来约束in-flight数据包,不依赖于PFC的RoCEv2网络成为了未来的发展方向。这将有助于把RDMA推广到规模更大、跳数更多的网络中。

2.4 负载均衡技术

RDMA的大规模组网通常采用基于Fat-Tree的Clos架构。基于Fat-Tree的Clos架构的基本理念是使用大量的商用交换机，在服务器之间构造出多个等价路径，交换机对流进行ECMP实现负载均衡，进而形成大规模的无阻塞网络。

与传统数据中心的流量分布不同，大模型训练网络中多为大象流，数量相对较少。这使得传统的ECMP存在哈希极化现象，即多个流可能分配到同个链路上，负载不均造成流冲突。同时，由于ECMP还是一个无状态的局部决策，不关心不同流的大小差异，在流数目不多且大小流长尾严重时，容易造成多条路径中某些路径拥塞而另一些路径空闲，从而造成带宽浪费和影响传输效率。因此，负载均衡是大规模AI集群网络面临的又一挑战。针对ECMP存在问题，有以下两种负载均衡优化方案：

第1种方案是改变流的属性，把流分散到多个等价路径上。在交换机ECMP不变的情况下，改变流的标签，或增加流的熵（将流分割成更小的流或基于报文头的其他位置字段做哈希），让流变得更多从而能通过哈希散开。代表性方法有PLB^[15]，在主机端利用拥塞探测感知拥塞的流，对拥塞流的流标签进行更改，引导交换机对流进行重新等价多路径ECMP/加权多路径（WCMP）哈希，从而为拥塞流选择新路径。

第2种方案是基于网络状态的流量调优。通过实时收集网络拓扑和流量等信息，由集中软件定义网络（SDN）控制器为每条流计算出最优路径，或由交换机进行自适应路由选择，包括集中式流量工程^[16]、自适应路由技术^[17]和网络级负载均衡技术^[18]等。

1) 集中式流量工程^[16]：SDN控制器实时收集网络拓扑和任务放置信息，基于约束最短路径算法为各个流计算最优路径。

2) 网络级负载均衡技术^[17]：根据大模型训练的流量特征，综合网络拓扑等整网信息，计算出最优的流量转发路径。

3) 自适应路由技术^[18]：交换机根据出口队列负载评估拥塞情况，为每个数据包选择最不拥塞的端口进行数据传输，以实现负载均衡。由于同一流的不同数据包可能由不同网络路径传输，到达目的节点时可能出现乱序，因此需要网卡侧在RoCE传输层完成对无序数据的转换，再将有序数据传递给应用程序。

此外，目前一些研究^[19-20]也指出：原生RoCE协议中规定数据包顺序到达的设计弊端是制约负载均衡的关键因素。未来应从根本上改进传输协议，采用数据包喷洒等技术，使

得数据包可以通过多路径顺序传输，然后再利用可编程交换机或智能网卡重新对数据包排序，以充分利用网络的多个可用路径实现负载均衡。

2.5 自动化运维技术

现阶段针对大模型训练的AI集群网络已达万卡规模^[21]，未来要扩展到十万和百万卡量级，传统依靠人工的网络运维已经无法满足需求。同时，由于故障无法避免，需要有自动化机制来实现部署和测试，并持续监控网络状态，减少故障和排除故障，实现自动化运维。自动化网络运维技术研究主要集中在以下几个方向：

1) 端网一体自动化部署和测试：集成多种自动化工具，研发自动选择配置模板，实现全网流控、拥塞控制、负载均衡等关键指标参数的自动化配置和测试验证，缩短大模型训练系统的整体部署时间。

2) 信息采集压缩和关键信息提取：传统运维采用简单网络管理协议（SNMP）“拉模式”流量采样方式，采样精度在分钟级别，颗粒度较粗。为实现无损网络，RDMA网络需要全栈巡检和毫秒级的实时监控。除流量信息外，还要采集拓扑、网卡、交换机端口、流控参数等更细颗粒度的信息。Telemetry采用“推模式”流量采集方式，虽然可以实现精细化采集，但在网络中全面开启开销巨大，严重影响网络性能。为此，需要根据网络架构和训练模型，定制化采样精度和信息采集策略，并动态按需调整。为实现高效分析，还需对低频变化信息进行高压压缩，提取关键信息，结合带内网络遥测探测流交叉覆盖，实现轻量级近似全链路监控。

3) 快速故障定位及自愈：基于多维度的网络指标信息进行故障根因分析，快速定位故障。同时配置故障自愈策略，故障时通过路径切换或节点替换，尽可能地缩短故障恢复时间。例如，利用硬件实现故障感知，无须通过控制面，仅通过数据面的故障通告和故障切换策略；无须等待全网收敛，仅基于端侧智能网卡修改数据包头特定字段的重路由策略等。

3 未来技术展望

大模型的持续发展对算力需求增长迅速，因此高性能高可用的云网基础设施非常必要。打造满足下一代大模型训练需求的低时延、大带宽和高吞吐网络，需要构建新型网络架构，以匹配大模型训练的“大流”“少流”的流量特征；需要研究确定性网络等新技术，满足广域网远距离大模型中心互联需求；需要设计针对大模型通信流量的新型网络协议、拥塞控制和负载均衡机制，实现网络无拥塞和丢包，有效利

用计算资源；需要实现自动化和精细化的运维保障，保障网络持续高效运行。同时，这些技术的系统创新如何实现现网设备和生态结合、如何在工程领域商用落地部署将是一个长期而艰巨的任务，需要产业链各方共同探索解决。

参考文献

- [1] 华为. 星河AI网络白皮书 [R]. 2024
- [2] 中国移动研究院. 面向AI大模型的智算中心网络演进白皮书 [R]. 2023
- [3] AL-FARES M, LOUKISSAS A, VAHDAT A. A scalable, commodity data center network architecture [J]. ACM SIGCOMM computer communication review, 2008, 38(4): 63-74. DOI: 10.1145/1402946.1402967
- [4] WANG W, GHOBADI M, SHAKERI K, et al. Optimized network architectures for large language model training with billions of parameters [EB/OL]. [2024-02-25]. <https://arxiv.org/pdf/2307.12169v2.pdf>
- [5] 蒋炜, 钱声攀, 邱奔. 数据中心网络拓扑结构设计策略研究 [J]. 中国电信业, 2021, (S1): 73-78
- [6] 赵俊峰, 李芳, 叶晓峰, 等. 面向广域RDMA的确定性网络需求与技术 [J]. 电信科学, 2023, 39(11): 39-51. DOI: 10.11959/j.issn.1000-0801.2023248
- [7] SHALEV L, AYOUB H, BSHARA N, et al. A cloud-optimized transport protocol for elastic and scalable HPC [J]. IEEE micro, 2020, 40(6): 67-73. DOI: 10.1109/mm.2020.3016891
- [8] Overview and Motivation for the forthcoming ultra ethernet consortium specification [EB/OL]. (2023-09-17) [2024-02-24]. <https://ultraethernet.org/wp-content/uploads/sites/20/2023/10/23.07.12-UEC-1.0-Overview-FINAL-WITH-LOGO.pdf>
- [9] Google opens Falcon, a reliable low-latency hardware transport, to the ecosystem [EB/OL]. [2024-02-25]. <https://cloud.google.com/blog/topics/systems/introducing-falcon-a-reliable-low-latency-hardware-transport>
- [10] IEEE DCB. 802.1Qbb - priority-based flow control [EB/OL]. [2024-02-25]. <http://www.ieee802.org/1/pages/802.1bb.html>
- [11] ZHU Y B, ERAN H, FIRESTONE D, et al. Congestion control for large-scale RDMA deployments [J]. ACM SIGCOMM computer communication review, 2015, 45(4): 523-536. DOI: 10.1145/2829988.2787484
- [12] MITTAL R, LAM V T, DUKKIPATI N, et al. TIMELY [J]. ACM SIGCOMM computer communication review, 2015, 45(4): 537-550. DOI: 10.1145/2829988.2787510
- [13] KUMAR G, DUKKIPATI N, JANG K, et al. Swift: delay is simple and effective for congestion control in the datacenter [C]// Proceedings of the Annual conference of the ACM Special Interest Group on Data Communication on the applications, technologies, architectures, and protocols for computer communication. ACM, 2020: 514-528. DOI: 10.1145/3387514.3406591
- [14] LI Y L, MIAO R, LIU H H, et al. HPCC: high precision congestion control [C]// Proceedings of the ACM Special Interest Group on Data Communication. ACM, 2019: 44-58. DOI: 10.1145/3341302.3342085
- [15] QURESHI M A, CHENG Y, YIN Q W, et al. PLB: congestion signals are simple and effective for network load balancing [C]// Proceedings of the ACM SIGCOMM 2022 Conference. ACM, 2022: 207-218. DOI: 10.1145/3544216.3544226
- [16] Meta networking@scale 2023 [EB/OL]. (2023-09-07)[2024-02-26]. <https://atscaleconference.com/events/networking-scale-2023/>
- [17] 华为. HPC无损以太网和AI Fabric网络技术白皮书 [R]. 2023
- [18] NVIDIA Spectrum-X network platform architecture [EB/OL]. [2024-02-26]. <https://nvdam.widen.net/s/h6klwtqv5z/nvidia-spectrum-x-whitepaper-2959968>
- [19] SONG C H, KHOOI X Z, JOSHI R, et al. Network load balancing with In-network reordering support for RDMA [C]// Proceedings of the ACM SIGCOMM 2023 Conference. ACM, 2023: 816-831. DOI: 10.1145/3603269.3604849
- [20] Cisco. Cisco silicon one [EB/OL]. [2024-02-26]. <https://blogs.cisco.com/sp/building-ai-ml-networks-with-cisco-silicon-one>
- [21] JIANG Z H, LIN H B, ZHONG Y M, et al. MegaScale: scaling large language model training to more than 10,000 GPUs [EB/OL]. (2024-02-23) [2024-02-25]. <https://arxiv.org/abs/2402.15627>

作者简介



唐宏，中国电信股份有限公司研究院IP领域首席专家，正高级工程师，中国电信科技委常委；长期从事IP网络及其新技术的研发工作；发表论文30余篇，获发明专利100余项。



武娟，中国电信股份有限公司研究院正高级工程师；主要从事IP网络、人工智能相关工作；已发表多篇论文。



徐晓青，中国电信股份有限公司研究院工程师；主要从事网络设计、网络优化和人工智能相关工作；已发表多篇论文。



张宁，中国电信股份有限公司研究院算法工程师；研究方向包括联邦学习、激励机制、负载均衡等；已发表TMC论文2篇。