



研究与开发

基于虚拟网络嵌入的异构算力网络资源管理

余竞航, 赵一辰, 王凌, 陈欣, 邹昊东

(国网江苏省电力有限公司信息通信分公司, 江苏 南京 210024)

摘 要: 随着人工智能大模型引领的新应用和新需求的蓬勃兴起, 算力规模和计算技术正经历着前所未有的快速演进与多元化创新。然而, 在算力网络呈现集群化和异构化趋势的同时, 算力需求迅猛增长与资源利用低效性之间的矛盾日益凸显。如何实现对异构算力的统一高效管控以提升资源利用率, 已成为当前研究的重要课题。基于网络虚拟化 (network virtualization, NV) 技术, 提出了一种基于虚拟网络嵌入 (virtual network embedding, VNE) 异构跨域算力资源分配方法。具体而言, 构建了一个基于深度强化学习 (deep reinforcement learning, DRL) 模型的策略网络, 负责精准计算候选算网节点与链路, 以实现资源优化分配。通过一系列仿真实验, 验证了该方法的有效性, 为解决异构算力管理问题提供了新的思路和方法。

关键词: 异构算力网络; 网络虚拟化; 虚拟网络嵌入; 算力资源管理; 深度强化学习

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024230

Heterogeneous computing network resource management based on virtual network embedding

YU Jinghang, ZHAO Yichen, WANG Ling, CHEN Xin, ZOU Haodong

Information and Communication Company, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210024, China

Abstract: With the booming development of new applications and demands led by large AI models, computing scale and technology are experiencing unprecedented rapid evolution and diversified innovation. However, as computing networks show a trend of clustering and heterogeneity, the contradiction between the rapid growth of computing demand and the inefficiency of resource utilization has become increasingly prominent. How to achieve unified and efficient management of heterogeneous computing to improve resource utilization has become an important research topic. Based on network virtualization (NV) technology, a heterogeneous cross-domain computing resource allocation method based on virtual network embedding (VNE) was proposed. Specifically, a policy network based on a deep reinforcement learning (DRL) model was constructed to accurately calculate candidate computing nodes and links for optimal resource allocation. Through a series of simulation experiments, it verifies the effectiveness of this method and provides new ideas for solving the problem of heterogeneous computing management.

Key words: heterogeneous computing network, network virtualization, virtual network embedding, computing resource management, deep reinforcement learning

0 引言

计算能力（简称算力）是指计算机系统或网络处理数据的能力，是执行复杂计算任务的核心因素。《中国算力发展指数白皮书（2023 年）》指出，算力在促进数字经济与实体经济深度融合中发挥着至关重要的作用^[1]。然而，在全球范围内，算力发展多样化及供需不平衡的挑战依然存在，特别是以人工智能大模型为代表的新应用和新需求的崛起，一方面推动了算力规模的快速扩展和计算技术的多元创新，另一方面算力需求增长与算力资源利用不充分的矛盾越来越突出。此外，随着云计算、边缘计算和智能终端设备的迅速发展，计算资源的部署呈现日益泛在化的趋势。根据紫金山实验室的《算力网络研究进展综述》，集群化和异构化已成为算力网络发展的重要趋势^[2]。

在人工智能快速发展的今天，面对日益增长的算力需求，宝贵的算力资源显得愈发紧缺。以大语言模型（large language model, LLM）为例，其特点在于参数规模庞大、训练数据量巨大以及计算需求极高^[3]，因此 LLM 的训练需要极大的算力支持。例如，OpenAI 开发的 GPT-3^[4]模型包含 1 750 亿个参数，其训练数据集可能包含数百万甚至数十亿个样本，整个训练过程需要 3.14×10^{11} TFLOPS，为此 OpenAI 投入了上万张高性能显卡用于 GPT-3 模型的训练。因此，为应对算力需求持续增长所引发的供需失衡等问题，除了增加算力硬件资源外，亟须解决已有算力资源利用不充分的问题。

近年来我国算力总规模高速增长，但算力资源未能实现充分利用^[5]。同时，由于缺乏高效的异构资源管理方法，尤其是在多域异构算力网络场景下，系统无法根据任务请求合理地分配算力资源，导致异构算力资源未能充分利用，进而引起资源闲置、浪费等现象。因此，如何对异构算力资源进行统一管控，并依据实际业务需求合理

分配资源，从而提高算力资源利用率，成为一个非常重要的研究点。

目前，许多研究集中于异构算力资源管理这一关键问题^[2]。一方面，5G 和移动互联网技术快速发展，对计算资源的需求正不断增长；另一方面，在多域异构算力网络中，计算需求呈现多样化趋势。研究重点是如何合理调度底层资源以满足巨大的计算需求，以及如何根据计算需求和算力资源的特性差异来提供相应计算资源，这依赖于合理的资源管理、高效的资源分配方法。因此，高效的异构算力资源管理方法已成为当前研究的一个关键点。

计算资源的异构特性既有资源融合的优势又为资源调度过程带来巨大的挑战，计算资源由不同的硬件架构组成，如 CPU、GPU、FPGA 等，每种架构都有其特定的优势和局限性，这增加了整体异构算力网络的复杂性。因此，需要建立统一的资源抽象模型来屏蔽底层算力的差异性，进行异构资源的有效整合，实现不同算力之间的协同。同时，面对资源的动态变化和应用需求的波动，如何高效、智能地调度资源，确保应用性能和资源利用率最优化，也是算力网络的一个关键问题。由于跨域算力网络的广泛分布和异构算力资源的不均匀分布，按需调用算力资源和动态挂载算力节点变得极其复杂。这些问题使得异构算力资源管理极具挑战性。

针对上述问题，本文基于网络虚拟化（network virtualization, NV）技术，实现异构算力资源管理，处理多域异构算力网络中的资源分配请求^[6]。NV 常用于 5G 网络、边缘计算、算力网络等领域^[7-8]，可以将异构算力网络分割成多个独立的虚拟异构算力网络，分割出的虚拟网络在功能、操作和管理上都与物理异构算力网络相似，从而提高网络资源利用率。同时，虚拟网络嵌入（virtual network embedding, VNE）是 NV 的关键技术^[9]，旨在将虚拟网络资源映射



到物理网络上,通过资源复用、按需分配、布局优化等方法实现物理网络资源的高效灵活使用,并且有效地管理节点、链路、带宽等虚拟网络资源^[10]。网络虚拟化技术赋能异构算力资源按需调度、动态挂载如图1所示,使用跨域虚拟网络嵌入算法可以在确保最优虚拟网络嵌入成本情况下,将虚拟网络请求嵌入多域、共享的异构算力集群网络上,降低资源分配过程中产生的资源消耗,并提高算力资源分配效率。

具体来说,本文贡献如下。

(1) 根据算力网络的异构性与集群性特性,将其建模为多域物理网络结构。其中,每个物理

域表示一个算力集群,其由不同功能的算力设备和链路构成。以算力和带宽资源为研究目标,建立了多目标感知的嵌入约束。

(2) 提出了一种基于虚拟网络嵌入的异构跨域算力资源分配方法。具体来说,构建了一个基于深度强化学习模型的策略网络,用于计算高效资源分配的候选算力节点与链路。并且,其基于与环境的高效互动指导智能体向高奖励方向优化。

(3) 通过一系列仿真实验,验证了所提方法在长期平均收益、长期收益成本比、任务请求接收成功率指标方面相比于实验基准的有效性。




图1 网络虚拟化技术赋能异构算力资源按需调度、动态挂载

1 相关工作

算力网络旨在将分布式计算节点打通互联、统筹调度,通过对网络架构和协议的改进,实现网络和计算资源的优化和高效利用^[11]。近年来,算力网络发展迅速,引起越来越多的学者关注^[12]。然而,由于网络规模的不断扩大,算力资源无法得到充分利用。因此,本文主要采用 VNE 技术,实现异构算力资源管理。

1.1 算力网络发展

算力网络作为一种智能化的新型网络形态,其构建基础涵盖了通信网络以及多样化的异构算力设施。它通过深度整合网络、算力及数据等各类资源,并对其进行精细化编排管理,实现了网络、算力、数据、运维、智能以及服务等多个维度的全面融合^[13]。同时,算力网络也逐步成为信息通信技术融合创新的重要方向,引领着新一轮的技术变革与产业升级^[14]。

1.1.1 国际国内算力网络研究的分析

国际上,因特网工程任务组(Internet Engineering Task Force, IETF)已经启动了计算优先网络框架(computing first network framework)系列研究;欧洲电信标准组织(European Telecommunications Standard Institute, ETSI)和宽带论坛(Broadband Forum, BBF)也分别开展了 NFV-EVE020 和 SD-466 相关技术的研究工作。在国内,三大运营商与中国通信标准化协会(China Communications Standards Association, CCSA)同步开展了一系列全方位的标准技术研究,包括算力网络需求与架构、算力路由协议技术、算力网络标识解析技术、算力网络控制器技术、算力网络交易平台技术、算力网络管理与编排技术、算力度量与算力建模技术等^[15]。这些研究有力地推动了算力网络的发展。

1.1.2 异构算力资源高效分配的战略意义

随着数字经济的不断发展,不同应用场景对

算力资源的要求呈现较大差异,同时物联网、AI、边缘计算、高性能计算等新技术的发展也对算力资源性能提出了更高要求,二者共同推动算力资源逐渐朝着多元异构和泛在部署的方向发展,以达到更高的算力资源利用率和用户体验度^[16]。异构算力资源的高效分配至关重要,它能够最大化资源利用率、优化性能、降低成本,并灵活应对多样化需求。合理分配不同类型的计算资源(如 CPU、GPU、FPGA 等),不仅提高了计算效率和经济效益,还提升了系统的可靠性和可用性^[17]。此外,这种高效分配为技术创新和应用发展提供了坚实基础,推动了科技进步,具有重要的战略意义。

1.2 虚拟网络嵌入问题

VNE 技术在资源管理中具有重要作用,其发展显著提升了网络资源的利用率和灵活性。最初,VNE 技术主要用于静态嵌入方案,解决固定拓扑结构下的资源分配问题,提高了资源利用率^[18]。随着虚拟化技术和云计算的普及,VNE 逐渐发展出动态嵌入方案,能够根据实际需求动态调整资源分配,增强了网络的适应性和灵活性^[19]。近年来,软件定义网络(software defined network, SDN)和网络功能虚拟化(network function virtualization, NFV)的引入,使得 VNE 技术实现了智能化和自动化的资源管理,进一步优化了资源分配效率。特别是机器学习和人工智能技术的应用,使 VNE 在大规模复杂网络环境中的资源管理能力显著提升,推动了虚拟网络嵌入技术向更高效和智能的方向发展^[8]。

1.2.1 启发式算法研究综述

VNE 技术的发展在网络资源管理中起到了关键作用,有效提高了网络的整体性能和服务质量。因此,许多学者对 VNE 问题有着广泛兴趣,而启发式算法被认为是求解该问题的有效方法之一。对于 VNE 问题,Chowdhury 等^[18]提出了处理节点映射以及链接映射阶段之间相关性的线性规



划算法,即确定性算法D-ViNE以及随机性算法R-ViNE。由于使用了一些其他约束条件,增加了嵌入所需时间。为了解决该问题,Cheng等^[20]提出了基于马尔可夫随机游动模型理论的VNE算法(NodeRank),该算法根据网络节点的资源属性和拓扑属性对网络节点进行排序,提出了两种基于节点排序的VNE算法,有效提高了虚拟网络请求接受率。但是,它忽略了虚拟网络请求的成本代价。为了使得嵌入成本最小化,Wang等^[21]设计并实现了一个基于强化学习的策略网络,利用贪婪策略筛选合适的节点,没有考虑虚拟网络请求的未来资源需求,从而导致资源碎片程度高,限制了算法灵活性。针对随机虚拟网络请求带来的底层网络资源碎片化问题,Lu等^[22]提出了一种资源碎片感知的在线VNE算法(VNE-RFD)和基于RFD的启发式虚拟网络重构算法(VNR-RFD),旨在减少资源碎片累积,提高资源利用率。但是,该研究没有考虑不同虚拟网络请求下的资源竞争问题,算法在复杂虚拟网络中的效率受限。针对不同虚拟网络请求映射之间资源分配的协调问题,Fan等^[23]提出了一种新的数据中心网络节点重要性评估模型及分布式协同虚拟网络嵌入算法。该算法通过拓扑感知提高资源分配协调性,减少映射代价,提升系统性能。实验结果显示,在真实Fat-tree DCN测试平台上,算法提升了映射接受率和平均收益,降低了带宽消耗。此外,启发式思想和强化学习的结合为解决VNE问题带来许多新思路,Zhang等^[24]提出了一种基于强化学习的启发式安全感知VNE算法,该算法在训练阶段使用策略网络作为学习代理,以底层节点属性作为输入形成特征矩阵,并在测试阶段根据映射概率映射节点,同时考虑了安全问题,为虚拟节点和底层节点添加了安全需求级别约束。

1.2.2 深度强化学习技术在资源管理中的优势

强化学习(reinforcement learning, RL)作

为机器学习的重要组成部分,能够在奖励中不断优化其决策以及具备优越的探索和学习能力^[25]。深度学习(deep learning, DL)则具有良好的感知能力。强化学习近年来与深度学习进行了广泛结合,形成了深度强化学习的研究领域。作为一种崭新的机器学习方法,深度强化学习(deep reinforcement learning, DRL)同时具有感知复杂输入和求解最优策略的能力,可以应用于资源管理分配等复杂决策问题^[26-27]。与传统机器学习方法相比,深度学习在无线网络中展现了更大的潜力,不仅预测准确度更高,还能够直接使用从网络中采集的特征进行训练,无须对输入数据进行烦琐的预处理,从而降低了模型复杂度。通过将深度学习与强化学习相结合,在动态学习的过程中,可以将获取的历史经验存储为神经网络的训练数据,借助深度学习的强大能力,有效提升强化学习算法的学习速度和决策性能。

随着5G技术的成熟以及超越5G(B5G)和6G技术的前景,移动设备的有限寿命和计算对服务质量(quality of service, QoS)提出了重大挑战。此外,在通信系统中仍然存在计算、存储、通信和其他资源的低效使用问题。为了减少启发式搜索等静态VNE所带来的物理资源碎片化问题,Yao等^[28]提出了一种结合强化学习的连续决策(CDRL)策略来增强与环境交互。在之前的工作中,提出了一种基于DRL的调度网络^[29],该网络可以与多层计算网络(multi-tier computing network, MTCN)有效地交互,以提高资源灵活性,对3个广泛使用的评估指标(长期平均收入、长期平均收入成本比和任务请求接受成功率)进行了比较实验,验证了所提算法与所有基线的平均改进分别为19.042%、2.563%和3.932%。针对计算的普及和设备规模的激增为任务卸载提供合理的资源分配带来的问题,在之前的工作中,提出了一种新的基于DRL辅助联合学习(federated learning, FL)的两阶段协调、分

布式在线多域虚拟网络嵌入算法^[30]。与基线相比,该算法的长期卸载收入、资源利用率和任务卸载成功率分别平均提高了 17.66%、5.97% 和 4.52%。为了更有效地提取网络的底层特征信息,研究人员采用了图卷积神经网络 (graph convolutional neural network, GCNN) 来解决 VNE 问题。Yan 等^[31]通过图卷积网络自动提取图像的高级特征,辅助处理与 VNE 相关的任务。将卷积神经网络 (convolutional neural network, CNN) 应用于非欧几里得图,如网络拓扑结构,可以显著提升解决 VNE 问题的效率。Zhang 等^[32]提出了一种创新的 VNE 算法,该算法融合了图卷积神经网络和强化学习理论。利用自定义的适应度矩阵和适应度值构建了算法目标函数,设计了一种高效的动态 VNE 算法 (GCNRL-VNE),仿真实验验证了基于 RL 和 GCNN 的动态 VNE 算法具有良好的基本 VNE 特性,有效减少了资源碎片化。以上工作表明,资源分配策略大多以深度强化学习技术作为基础,在满足约束条件的情况下,找到最优的资源管理方案,大大提高了资源分配效率,因此本文采用深度强化学习方法进行建模。

2 问题定义

异构算力网络是一个由多元化、互补性强的算力集群网络所组成的复杂系统。这些算力集群各自独立,由承担不同功能、处理不同任务类型的算力终端设备所构成。这些终端设备可能涵盖从高性能计算 (high performance computing, HPC) 服务器到边缘计算设备,再到专门用于机器学习和人工智能 (artificial intelligence, AI) 加速的硬件,如 CPU、GPU、TPU、FPGA 等多种类型,它们共同协作,形成一个强大而灵活的算力网络,以应对各种复杂多变的计算需求。

2.1 网络建模

为研究基于 VNE 的异构算力网络的资源管理

问题,首先需要对网络进行抽象建模。本文所使用的属性符号定义见表 1。

表 1 本文所使用的属性符号定义

网络定义	网络属性	符号定义
异构算力网络 G^C	第 i 个算力网络集群域	C_i
	第 i 个算力网络集群域中的第 j 个元素	C_{ij}
	算力网络集群域数量	$ C $
	算力节点	N^{C_i}
	算力网络域内链路	AL^{C_i}
	算力网络域间链路	EL^{C_i}
	算力节点的位置	LN^{C_i}
	算力节点的算力资源	$C_N^{C_i}$
	域内链路的带宽资源	$W_AL^{C_i}$
	域间链路的带宽资源	$W_EL^{C_i}$
算力任务请求虚拟网络 G^V	算力请求的虚拟节点	N^V
	算力请求的虚拟链路	L^V
	请求的虚拟节点算力资源	C_N^V
	请求的虚拟链路带宽资源	W_L^V

具体来说,异构算力网络被建模为一个多域的带权无向图,如式 (1) 所示:

$$G^C = \{C_i, EL^{C_i}, W_EL^{C_i}\}, \text{s.t. } C_i = \{N^{C_i}, LN^{C_i}, C_N^{C_i}, AL^{C_i}, W_AL^{C_i}\}, 1 \leq i \leq |C| \quad (1)$$

其中, C_i 表示第 i 个算力网络集群域, EL^{C_i} 表示算力网络域间链路, $W_EL^{C_i}$ 表示域间链路的带宽资源, N^{C_i} 表示算力节点, LN^{C_i} 表示算力节点的位置, $C_N^{C_i}$ 表示算力节点的算力资源, AL^{C_i} 表示算力网络域内链路, $W_AL^{C_i}$ 表示域内链路的带宽资源。

此外,算力任务请求定义为虚拟网络请求 (virtual network request, VNR), 每个虚拟网络都表示一个独立的任务需求。同样地,其也被建模为一个带权无向图,如式 (2) 所示:

$$G^V = \{N^V, L^V, C_N^V, W_L^V\} \quad (2)$$

其中, N^V 表示算力请求的虚拟节点, L^V 表示算力请求的虚拟链路, C_N^V 表示所请求的虚拟节



点算力资源, W_L^V 表示所请求的虚拟链路带宽资源。

在实际应用中, 任务请求在一定时间范围内接续到达, 且每个任务需要在指定的生命周期内响应并完成, 即存在开始时间 (t_s) 与结束时间 (t_e)。因此, 第 i 个任务的算力任务请求 V_i 被建模为式 (3):

$$V_i = \{G^{V_i}, t_s, t_e\} \quad (3)$$

2.2 方法原理

通过深度神经网络对策略函数或价值函数进行近似, 从而在高维状态空间中学习和执行最优策略。具体而言, DRL 算法利用深度神经网络的强大表示能力, 处理复杂的高维状态信息, 将其映射为适合决策的低维特征, 从而实现对环境的有效建模与响应。核心算法如深度 Q 网络 (deep Q-network, DQN) 通过引入深度神经网络来近似传统 Q-learning 中的 Q 值函数, 同时采用经验回放 (experience replay) 和固定目标网络 (fixed target network) 来提高训练过程的稳定性和效率, 解决了 Q-learning 在复杂环境下易于陷

入局部最优解的问题。此外, DRL 中的策略梯度方法 (policy gradient method) 直接优化策略函数, 通过对策略的概率分布进行调整, 提升决策的灵活性和准确性。常见策略梯度算法如 REINFORCE 和 Actor-Critic 方法, 后者通过引入 Critic 网络来评估当前策略的优劣, 并指导策略 (actor) 的优化方向。DRL 算法还需要在探索 (exploration) 与利用 (exploitation) 之间实现平衡, 以确保代理既能够发现新的有效策略, 又能够充分利用已有经验, 逐步提升决策性能。为了实现这一目标, DRL 采用 ϵ -贪心 (ϵ -greedy) 策略、熵正则化 (entropy regularization) 等机制来动态调整探索与利用的比例, 深度强化学习算法原理如图 2 所示。

2.3 问题定义

基于 VNE 的异构算力资源分配示例如图 3 所示。因此, 算力分配过程即将虚拟网络映射到算力网络的过程, 该问题可以被建模为式 (4):

$$\text{for } \forall 1 \leq i \leq |V|, G^{C'} \rightarrow V_i(t_s \rightarrow t_e) \quad (4)$$




图2 深度强化学习算法原理




图3 基于VNE的异构算力网络资源分配示例

其中, $|V|$ 表示VNR数量。该问题是一个NP难问题, 因此目标是以尽可能少的异构算力网络资源满足尽可能多的算力任务请求, 以提高算力网络资源利用率。

3 相关指标

3.1 约束指标

利用指标 $\alpha_{n^c \rightarrow n^v}$ 来表示是否算力网络节点 n^c 被成功映射到虚拟网络节点 n^v , 即算力网络节点资源是否被成功分配至虚拟网络节点。如果成功, 则 $\alpha_{n^c \rightarrow n^v}$ 为1, 否则为0, 如式(5)所示:

$$\alpha_{n^c \rightarrow n^v} = \begin{cases} 1, & \text{节点映射成功} \\ 0, & \text{节点映射失败} \end{cases} \quad (5)$$

其中, 使用小写字母表示具体元素。例如, n^c 表示异构算力网络中的其中一个算力节点。

利用指标 $\beta_{l^c \rightarrow l^v}$ 表示是否算力网络链路 l^c 被成功映射到虚拟网络链路 l^v , 即算力网络链路资源是否被成功分配至虚拟网络链路。如果成功, 则 $\beta_{l^c \rightarrow l^v}$ 为1, 否则为0, 如式(6)所示:

$$\beta_{l^c \rightarrow l^v} = \begin{cases} 1, & \text{链路映射成功} \\ 0, & \text{链路映射失败} \end{cases} \quad (6)$$

其中, l^c 表示 al^c 和 el^c 的统称。

通过VNE进行算力资源分配过程中还需满足相关资源约束。具体如下。

(1) 每个虚拟网络节点所分配的算力资源只能来源于一个算力网络节点, 如式(7)所示:

$$\sum_{j=1}^{|N^C|} \alpha_{n_j^c \rightarrow n_k^{V_i}} = 1, \forall n_k^{V_i} \in N^{V_i} \quad (7)$$

其中, $|N^C|$ 表示算力网络节点数量。

(2) 每个虚拟网络链路所分配的带宽资源可以来源于多条算力网络链路, 如式(8)所示:

$$\sum_{j=1}^{|L^C|} \beta_{l_j^c \rightarrow l_k^{V_i}} \geq 1, \forall l_k^{V_i} \in L^{V_i} \quad (8)$$

其中, $|L^C|$ 表示算力网络链路数量。

(3) 算力网络节点可用算力资源(如式(9)所示)表示为初始算力资源与已分配算力资源的差值, 其不能为负值, 如式(10)所示:

$$\begin{aligned} AC_N(n_j^C) &= C_N^C(n_j^C) - \\ &\sum_{i=1}^{|V|} \sum_{k=1}^{|N^{V_i}|} \alpha_{n_j^c \rightarrow n_k^{V_i}} C_N^{V_i}(n_k^{V_i}) \end{aligned} \quad (9)$$

$$AC_N(n_j^C) \geq 0, \forall n_j^C \in N^C \quad (10)$$

其中, $|N^{V_i}|$ 表示第 i 个虚拟网络中虚拟节点数量。

(4) 算力任务请求的虚拟节点所请求的算力资源需小于映射到的算力网络节点的可用算力资源, 如式(11)所示:

$$C_N^{V_i}(n_k^{V_i}) \leq AC_N(n_j^C), \alpha_{n_j^c \rightarrow n_k^{V_i}} = 1 \quad (11)$$

(5) 算力网络链路可用带宽资源(如式(12)所示)表示为初始带宽资源与已分配带宽资源的差值, 其不能为负值, 如式(13)所示:

$$AW_L(l_j^C) = W_L^C(l_j^C) - \sum_{i=1}^{|V|} \sum_{k=1}^{|L^{V_i}|} \beta_{l_j^c \rightarrow l_k^{V_i}} W_L^{V_i}(l_k^{V_i}) \quad (12)$$

$$AW_L(l_j^C) \geq 0, \text{ for } \forall l_j^C \in L^C \quad (13)$$

其中, $|L^{V_i}|$ 表示第 i 个虚拟网络中虚拟链路数量。

(6) 算力任务请求的虚拟链路所请求的带宽资源需小于映射到的算力网络链路的可用带宽资源, 如式(14)所示:



$$W_L^{V_i}(l_k^{V_i}) \leq AW_L(l_j^C), \beta_{l_j^C \rightarrow l_k^{V_i}} = 1 \quad (14)$$

3.2 评价指标

通过VNE进行资源分配的优化目标是以最小的资源成本获得最大的资源分配收益。为此,采用资源成本和收益指标来衡量,分别如式(15)和式(16)所示。其中,成本表示嵌入算力任务请求的虚拟网络所需的异构算力网络资源总量, hops表示嵌入虚拟链路所需的算力网络路径跳数,路径越长则链路成本越高。收益表示算力任务请求的虚拟网络所需求的资源综合,若嵌入成功则会产生相应收益。

$$C(V_i) = (t_e - t_s) \left(\sum_{n^{V_i} \in N^{V_i}} C_N^{V_i}(n^{V_i}) + \sum_{l^{V_i} \in L^{V_i}} W_L^{V_i}(l^{V_i}) \times \text{hops}(l^{V_i}) \right) \quad (15)$$

$$R(V_i) = (t_e - t_s) \left(\sum_{n^{V_i} \in N^{V_i}} C_N^{V_i}(n^{V_i}) + \sum_{l^{V_i} \in L^{V_i}} W_L^{V_i}(l^{V_i}) \right) \quad (16)$$

采用下列常用的长期平均收益、长期收益成本比、任务请求接收成功率评价指标^[33]进行算法评价,分别如式(17)、式(18)和式(19)所示:

$$LR = \lim_{T \rightarrow \infty} \frac{\sum_{i=1}^{|V|} \sum_{t=0}^T R(V_i)}{T} \quad (17)$$

$$LRC = \lim_{T \rightarrow \infty} \frac{\sum_{i=1}^{|V|} \sum_{t=0}^T R(V_i)}{\sum_{i=1}^{|V|} \sum_{t=0}^T C(V_i)} \quad (18)$$

$$Acc = \lim_{T \rightarrow \infty} \frac{\sum_{t=0}^T \text{Suc}V}{\sum_{t=0}^T \text{All}V} \quad (19)$$

其中, SucV表示成功嵌入的算力任务请求数量,它由所有算力任务请求的成功嵌入概率相加所得。其具体计算如式(20)所示:

$$\text{Suc}V = \sum_{i=1}^{|V|} \left(\prod_{j=1}^{|N^{V_i}|} \alpha_{n_j^C \rightarrow n_j^{V_i}} \times \prod_{k=1}^{|L^{V_i}|} \beta_{l_k^C \rightarrow l_k^{V_i}} \right) \quad (20)$$

4 本文所提算法

本文提出了一种基于深度强化学习的模型,用于计算被嵌入的候选算网节点集合和候选算网链路集合。具体来说,提出了基于策略梯度算法的策略网络。首先,基于时间片重复提取异构算力网络的环境状态矩阵,作为智能体的输入。其次,智能体基于上述所提出的一系列相关约束,结合DRL训练范式,计算候选算网节点和链路。

4.1 状态提取

在异构算力网络环境中,算力设备与用户的高强度交互使其处于实时分配的动态环境中。且大量的算力任务请求的VNR生命周期使得算网部分资源处于被占用与释放的动态状态。因此,需要基于时间片重复提取算网环境状态信息,实时关注环境的动态变化。

(1) 算力网络节点可用算力资源 (AC_N(n_j^C)), 如式(9)所示。其值越大,说明该节点算力资源越丰富,计算能力越强,其周围链路的宽带资源越丰富,使之越容易被嵌入。

(2) 算力节点相连的链路可用带宽 (Sum_W(n_j^C)), 如式(21)所示。其表示为与当前算网节点相连的所有算网链路的带宽之和。其值越大,说明当前节点周围的传输能力越强,资源成本损耗也会随之降低。

$$\text{Sum_W}(n_j^C) = \sum_{l_{jk}^C \in L^C} AW_L(l_{jk}^C) \quad (21)$$

其中, l_{jk}^C 表示与算网节点 n_j^C 相连的算网链路。

(3) 到其他算网节点的平均距离 (A_Dis(n_j^C)), 如式(22)所示。其表示将所有节点对的距离求和后,除以权重因子的总和,就得到了节点 n_j^C 到算网C中其他节点的平均距离:

$$A_Dis(n_j^C) = \frac{\sum_{l_{jk}^C \in L^C} \|LN^C(n_j^C) - LN^C(n_k^C)\|_2}{1 + \text{hops}(l_{jk}^C)} \quad (22)$$

在此基础上, 需要对状态进行最大最小归一化以加快模型收敛速度与精度, 如式 (23) 所示:

$$\mathbf{x}' = \frac{\mathbf{x} - \mathbf{x}_{\min}}{\mathbf{x}_{\max} - \mathbf{x}_{\min}} \quad (23)$$

其中, $\mathbf{x}_{\min}$ 表示向量 $\mathbf{x}$ 中的最小值; $\mathbf{x}_{\max}$ 表示向量 $\mathbf{x}$ 中的最大值。因此, 可以得到归一化状态向量 $\mathbf{AC_N}'(n_j^C)$ 、 $\mathbf{Sum_W}'(n_j^C)$ 和 $\mathbf{A_Dis}'(n_j^C)$ 。结合上述向量, 可以得到状态矩阵如式 (24) 所示:

$$\mathbf{S} = \begin{bmatrix} \mathbf{AC_N}'(n_1^C) & \mathbf{Sum_W}'(n_1^C) & \mathbf{A_Dis}'(n_1^C) \\ \mathbf{AC_N}'(n_2^C) & \mathbf{Sum_W}'(n_2^C) & \mathbf{A_Dis}'(n_2^C) \\ \vdots & \vdots & \vdots \\ \mathbf{AC_N}'(n_{|N^C|}^C) & \mathbf{Sum_W}'(n_{|N^C|}^C) & \mathbf{A_Dis}'(n_{|N^C|}^C) \end{bmatrix} \quad (24)$$

4.2 策略网络

基于深度强化学习的策略网络如图 4 所示, 其中智能体结构包含以下几层。

(1) 卷积层: 将如式 (24) 所提取的状态矩阵作为智能体的输入。该层利用卷积运算计算异构算力网络中各个算力节点的可用资源, 其计算方式如式 (25) 所示:

$$\mathbf{O}_I = \mathbf{S} \times \mathbf{W} + \mathbf{b} \quad (25)$$

其中, $\mathbf{W}$ 表示权重矩阵, $\mathbf{b}$ 表示偏差向量。

(2) 概率层: 该层通过 softmax 函数计算每个算力节点的嵌入概率, 将资源向量缩放至 (0, 1) 内, 如式 (26) 所示。其表示为通过将节点 n_j^C 的原始资源向量值除以所有节点的原始资源向量值之和, 计算节点 n_j^C 的嵌入概率。

$$\mathbf{O}_2(n_j^C) = \frac{e^{n_j^C}}{\sum_{i=1}^{|N^C|} e^{n_i^C}} \quad (26)$$

(3) 过滤层: 该层根据第 3.1 节中所描述的相关约束指标, 筛选出符合相关规范的候选算力网络节点和链路。其中, 候选算力网络节点根据计算出的概率降序排序。在此基础上, 按照最短路算法对候选算力网络进行搜索。最终, 确定符合算力任务请求的相关算力网络的节点和链路及相关资源配置情况。

智能体的动作是在某时刻所采用的资源分配决策, 其定义为算力节点嵌入方案和链路嵌入方案。具体来说, 对于 V_i 其表示如式 (27) 所示:

$$\begin{aligned} a_t^i = & \left\{ (a_t^{n,i}(1), a_t^{n,i}(2), \dots, a_t^{n,i}(j), \dots, a_t^{n,i}(|N^C|)) \right. \\ & \left. \left| a_t^{n,j}(j) = 0, 1 \ \& \ \sum_{j=1}^{|N^C|} a_t^{n,i}(j) = |N^{V_i}| \right. \right\}, \\ & \left\{ (a_t^{l,i}(1), a_t^{l,i}(1), \dots, a_t^{l,i}(k), \dots, \right. \\ & \left. \left. a_t^{l,i}(|L^C|)) \right| a_t^{l,i}(k) = 0, 1 \right\}, \end{aligned} \quad (27)$$

其中, $a_t^{n,i}(j)=1$ 表示使用算力节点 n_j^C 来承载虚拟节点, $a_t^{l,i}(k)=1$ 表示使用算力链路 l_k^C 来承载虚拟链路。

智能体的奖励是所采取动作所获得的反馈信号值, 用于引导智能体的优化方向。在本文中定义式 (18) 长期收益成本比作为奖励函数, 如式 (28) 所示:

$$r_t = \text{LRC} \quad (28)$$




图4 基于深度强化学习的策略网络



5 仿真实验和分析

5.1 环境配置

本文使用 GT-ITM 工具生成异构算力网络和算力任务需求的仿真拓扑和资源配置,并将其保存于文本文档中,仿真参数配置见表2。具体来说,共4个算力网络集群域,100个算力网络节点随机分布于4个域,600个算力网络链路。2000个算力任务需求,1000个作为训练集,1000个作为测试集。每个算力任务请求包含2~10个虚拟节点,并按照50%的概率随机生成虚拟链路。最后,为生成一个连续的过程,所有算力任务请求按照泊松过程到达。

表2 仿真参数配置

仿真参数	配置
算力网络集群域数量	4
算力网络节点数量	100
算力网络链路数量	600
算力网络节点的算力资源	$U[50, 100]$
算力网络链路的带宽资源	$U[50, 100]$
算力任务需求数量	2 000
训练集和测试集数量	1 000, 1 000
算力请求的虚拟节点数量	2~10
算力请求的虚拟链路生成概率	50%
请求的虚拟节点算力资源	$U[1, 20]$
请求的虚拟链路带宽资源	$U[1, 20]$

5.2 训练性能

记录了训练阶段策略网络的3项评估指标的变化,训练阶段评价指标变化情况如图5所示。从波动趋势来看,由于智能体随机初始化,未经过任何训练,前期各项指标的初始性能均较差。而随着学习过程的推进,智能体执行动作后环境反馈奖励信号,使得其会选择更高奖励的方向优化,3项指标值不断升高,并在迭代100次左右均达到稳定状态。因此,所提策略网络可以有效地学习和优化异构算力网络的资源分配策略。




图5 训练阶段评价指标变化情况

5.3 算法对比性能

为了证明所提算法有效性,选取了 NodeRank^[20]、CDRL^[27]以及 GCNRL-VNE^[32]算法作为实验基准。为了消除外界因素干扰,所有方法均

运行于相同的仿真环境与实验软硬件。任务请求流的开始时间是 22 s 和 30 000 s，本文将时间单位设置为 1 000 s，目的是观察 30 个时间单位内各指标的变化。在长期平均收益上的对比结果如图 6 所示，在长期收益成本比上的对比结果如图 7 所示，在任务请求接受成功率上的对比结果如图 8 所示。总体来说，基于机器学习的 VNE 算法优于启发式算法。其中，对于启发式算法 NodeRank，由于其基于节点资源权重进行贪婪选择，初始表现较好。然而，从长期表现来看，NodeRank 的表现不尽如人意。CDRL 算法引入了强化学习机制，提高了与环境的交互性质，因此性能得到显著提升。在此基础上，GCNRL-VNE 算法引入了图神经网络，并通过构建适应度函数增强了模型感知能力，进一步减少了资源碎片化现象。整体来看，本文所提方法更优异，这主要得益于 DRL 模型同时具备与环境高强度交互特性，而且结合了神经网络强大的感知能力，可以更好地关注异构算力网络的动态性与异构性。此外，长期平均收益与任务请求接受成功率均呈现下降趋势，这主要由于在响应算力任务请求的同时，算力网络的可用资源不断减少，后续算力任务请求响应的成功率也会随之降低。根据式 (17) 和式 (19)，两者均呈现下降趋势。而根据式 (18)，长期收益成本比还与成本资源有关，因此其值随着时间推进而呈现波动趋势。总体来说，本文所提方法优于其他基准。




图6 在长期平均收益上的对比结果




图7 在长期收益成本比上的对比结果




图8 在任务请求接受成功率上的对比结果

6 结束语

针对在算力网络发展呈现集群化与异构化趋势的同时，算力需求持续增长与资源利用不充分的矛盾日益突出的问题，本文提出一种基于虚拟网络嵌入的异构跨域算力资源分配方法，旨在赋能异构算力网络资源的统一高效管控。具体来说，本文提出了一种基于深度强化学习策略网络，其通过基于3层结构的智能体计算可用于资源分配的候选算网节点与链路，并通过与环境高效交互指导智能体优化。最后，进行了一系列仿真实验，验证了所提方法在长期平均收益、长期收益成本比、任务请求接受成功率等指标方面的有效性和高效性。在未来研究工作中，计划进一步探索基于深度强化学习的网络资源管理方法。



这包括优化深度神经网络结构,或引入图卷积神经网络来增强模型性能,完善复杂物理网络的抽象建模和特征提取过程。此外,还将考虑集成安全控制和差错控制机制,以增强算法的稳健性和可靠性。

参考文献:

- [1] 中国信息通信研究院. 中国算力发展指数白皮书(2023年)[R]. 2023.
CAICT. White Paper on the development of China's computing power index(2023)[R]. 2023.
- [2] 贾庆民, 丁瑞, 刘辉, 等. 算力网络研究进展综述[J]. 网络与信息安全学报, 2021, 7(5): 1-12.
JIA Q M, DING R, LIU H, et al. Survey on research progress for compute first networking[J]. Chinese Journal of Network and Information Security, 2021, 7(5): 1-12.
- [3] CHANG Y P, WANG X, WANG J D, et al. A survey on evaluation of large language models[J]. ACM Transactions on Intelligent Systems and Technology, 2024, 15(3): 1-45.
- [4] BROWN T, MANN B, RYDER N, et al. Language models are few-shot learners[J]. Advances in neural information processing systems, 2020, 33: 1877-1901.
- [5] 国家信息中心. “人工智能+”时代公共云发展模式与路径研究[R]. 2023.
The State Information Center. “Artificial intelligence +” research on the development mode and path of public cloud in the era[R]. 2023.
- [6] WU S, CHEN N, XIAO A L, et al. AI-empowered virtual network embedding: a comprehensive survey[J]. IEEE Communications Surveys & Tutorials, 2024(99): 1.
- [7] 雷波, 王江龙, 赵倩颖, 等. 基于计算、存储、传送资源融合化的新型网络虚拟化架构[J]. 电信科学, 2020, 36(7): 42-54.
LEI B, WANG J L, ZHAO Q Y, et al. Novel network virtualization architecture based on the convergence of computing, storage and transport resources[J]. Telecommunications Science, 2020, 36(7): 42-54.
- [8] CHEN N, SHEN S, DUAN Y, et al. Non-euclidean graph-convolution virtual network embedding for space-air-ground integrated networks[J]. Drones, 2023, 7(3): 165.
- [9] FISCHER A, BOTERO J F, BECK M T, et al. Virtual network embedding: a survey[J]. IEEE Communications Surveys & Tutorials, 2013, 15(4): 1888-1906.
- [10] ZHANG P Y, CHEN N, LI S B, et al. Multi-domain virtual network embedding algorithm based on horizontal federated learning[J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 3363-3375.
- [11] WANG X J, LI J M, NING Z L, et al. Wireless powered mobile edge computing networks: a survey[J]. ACM Computing Surveys, 2023, 55(13s): 1-37.
- [12] 林睿, 邢文娟, 雷波. 一种面向计算的网路模态: 算力网络模态探讨[J]. 电信科学, 2023, 39(10): 128-135.
LIN R, XING W J, LEI B. Discussion on a computation-oriented network modality—computing power network modality[J]. Telecommunications Science, 2023, 39(10): 128-135.
- [13] 段晓东, 姚惠娟, 付月霞, 等. 面向算网一体化演进的算力网络技术[J]. 电信科学, 2021, 37(10): 76-85.
DUAN X D, YAO H J, FU Y X, et al. Computing force network technologies for computing and network integration evolution[J]. Telecommunications Science, 2021, 37(10): 76-85.
- [14] ZHANG Y M, LAN X L, REN J, et al. Efficient computing resource sharing for mobile edge-cloud computing networks[J]. IEEE/ACM Transactions on Networking, 2020, 28(3): 1227-1240.
- [15] 何涛, 杨振东, 曹畅, 等. 算力网络发展中的若干关键技术问题分析[J]. 电信科学, 2022, 38(6): 62-70.
HE T, YANG Z D, CAO C, et al. Analysis of some key technical problems in the development of computing power network[J]. Telecommunications Science, 2022, 38(6): 62-70.
- [16] 雷波, 刘增义, 王旭亮, 等. 基于云、网、边融合的边缘计算新方案: 算力网络[J]. 电信科学, 2019, 35(9): 44-51.
LEI B, LIU Z Y, WANG X L, et al. Computing network: a new multi-access edge computing[J]. Telecommunications Science, 2019, 35(9): 44-51.
- [17] 张叶红, 董一川, 相洋, 等. 从“算力中心”到“算力网”: 从算力角度谈算网一体的机遇与挑战[J]. 信息通信技术, 2023, 17(3): 28-33.
ZHANG Y H, DONG Y C, XIANG Y, et al. From “computing centers” to “computing net”—the opportunities and challenges of computing and networking convergence from the perspective of computing resources[J]. Information and Communications Technologies, 2023, 17(3): 28-33.
- [18] CHOWDHURY N M M K, RAHMAN M R, BOUTABA R. Virtual network embedding with coordinated node and link mapping[C]//Proceedings of the IEEE INFOCOM 2009. Piscataway: IEEE Press, 2009: 783-791.
- [19] CHEN N, ZHANG P Y, KUMAR N, et al. Spectral graph theory-based virtual network embedding for vehicular fog computing: a deep reinforcement learning architecture[J]. Knowledge-Based Systems, 2022, 257: 109931.
- [20] CHENG X, SU S, ZHANG Z B, et al. Virtual network embedding through topology-aware node ranking[J]. ACM SIGCOMM Computer Communication Review, 2011, 41(2):

- 38-47.
- [21] WANG C, ZHENG F H, ZHENG G C, et al. Modeling on virtual network embedding using reinforcement learning[J]. Concurrency and Computation: Practice and Experience, 2020, 32 (23): e6020.
- [22] LU H C, ZHANG F Y. Resource fragmentation-aware embedding in dynamic network virtualization environments[J]. IEEE Transactions on Network and Service Management, 2022, 19 (2): 936-948.
- [23] FAN W B, XIAO F, LV M J, et al. Node essentiality assessment and distributed collaborative virtual network embedding in datacenters[J]. IEEE Transactions on Parallel and Distributed Systems, 2023, 34(4): 1265-1280.
- [24] ZHANG P Y, WANG C, JIANG C X, et al. Security-aware virtual network embedding algorithm based on reinforcement learning[J]. IEEE Transactions on Network Science and Engineering, 2021, 8(2): 1095-1105.
- [25] ZHANG P Y, CHEN N, SHEN S G, et al. AI-enabled space-air-ground integrated networks: management and optimization[J]. IEEE Network, 2024, 38(2): 186-192.
- [26] DE BAST S, TORREA-DURAN R, CHIUMENTO A, et al. Deep reinforcement learning for dynamic network slicing in IEEE 802.11 networks[C]//Proceedings of the IEEE INFOCOM 2019 - IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS). Piscataway: IEEE Press, 2019: 264-269.
- [27] WU S, CHEN N, XIAO A L, et al. AI-enabled deployment automation for 6G space-air-ground integrated networks: challenges, design, and outlook[J]. IEEE Network, 2024(99): 1.
- [28] YAO H P, MA S H, WANG J J, et al. A continuous-decision virtual network embedding scheme relying on reinforcement learning[J]. IEEE Transactions on Network and Service Management, 2020, 17(2): 864-875.
- [29] ZHANG P Y, CHEN N, XU G J, et al. Multi-target-aware dynamic resource scheduling for cloud-fog-edge multi-tier computing network[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(5): 3885-3897.
- [30] WU S, CHEN N, WEN G H, et al. Virtual network embedding for task offloading in IIoT: a DRL-assisted federated learning scheme[J]. IEEE Transactions on Industrial Informatics, 2024, 20(4): 6814-6824.
- [31] YAN Z X, GE J G, WU Y L, et al. Automatic virtual network embedding: a deep reinforcement learning approach with graph convolutional networks[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(6): 1040-1057.
- [32] ZHANG P Y, WANG C, KUMAR N, et al. Dynamic virtual network embedding algorithm based on graph convolution neural network and reinforcement learning[J]. IEEE Internet of Things Journal, 2022, 9(12): 9389-9398.
- [33] ZHANG P Y, CHEN N, KUMAR N, et al. Energy allocation for vehicle-to-grid settings: a low-cost proposal combining DRL and VNE[J]. IEEE Transactions on Sustainable Computing, 2024, 9(1): 75-87.

[作者简介]



余竞航 (1995-), 男, 国网江苏省电力有限公司信息通信分公司工程师, 主要研究方向为电力信息技术、算力网络。



赵一辰 (1988-), 男, 现就职于国网江苏省电力有限公司信息通信分公司, 主要研究方向为电力信息技术、人工智能。



王凌 (1992-), 男, 国网江苏省电力有限公司信息通信分公司工程师, 主要研究方向为电力信息技术、云计算。



陈欣 (1994-), 男, 国网江苏省电力有限公司信息通信分公司工程师, 主要研究方向为电力信息技术、人工智能。



邹昊东 (1987-), 男, 国网江苏省电力有限公司信息通信分公司高级工程师, 主要研究方向为电力信息技术、云计算。