

联合遗传算法和强化学习的虚拟网络 功能映射与调度方法

刘光远^{1,2}, 曹晶仪^{1,2}, 杜婕^{1,2}

(1. 石家庄铁道大学信息科学与技术学院, 050043, 石家庄;

2. 河北省电磁环境效应与信息处理重点实验室, 050043, 石家庄)

摘要: 网络功能虚拟化环境下,为满足用户不同需求并提高资源利用效率,将虚拟网络功能映射与调度联合考虑。首先,通过构建网络低时延、虚拟机资源高利用及能量低损耗的多目标优化模型,设计了一种强化学习(RL)联合第三代非支配排序遗传算法(NSGA III)的优化方法 RL-NSGA III;然后,采用两段式初始化技术求得高质量初始解,利用强化学习的优势自适应调节交叉变异参数,以保持种群多样性;最后,基于参考点的第三代非支配排序遗传算法,将虚拟网络功能映射至虚拟机并进行调度服务,得到多目标优化策略。仿真结果表明:相较于已有的 NSGA III、NSGA II 和 MOPSO 算法,采用 RL-NSGA III 算法计算得到的时延降低了 17%~28%,节点负荷提高了 9%~19%,能量损耗降低了 12%~26%,表明所提算法在提高网络速率和降低网络运营支出上的有效性。

关键词: 网络功能虚拟化;虚拟网络功能;映射与调度;强化学习;第三代非支配排序遗传算法

中图分类号: TP393 **文献标志码:** A

DOI: 10.7652/xjtuxb202408018 **文章编号:** 0253-987X(2024)08-0175-10

Function Mapping and Scheduling Method of Virtual Network Combining Genetic Algorithm and Reinforcement Learning

LIU Guangyuan^{1,2}, CAO Jingyi^{1,2}, DU Jie^{1,2}

(1. School of Information Science and Technology, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

2. Hebei Provincial Key Laboratory of Electromagnetic Environmental Effects and Information Processing,

Shijiazhuang 050043, China)

Abstract: In order to meet different needs of users and improve resource utilization efficiency in the network function virtualization environment, this paper examines virtual network function mapping and scheduling together. Firstly, an optimization method RL-NSGA III based on reinforcement learning (RL) combined with the third-generation non-dominated sorting genetic algorithm (NSGA III) is designed by constructing a multi-objective optimization model with low network delay, high utilization of virtual machine resources and low energy loss. Then, the two-stage initialization technique is used to obtain a high-quality initial solution, and RL's advantage is used to adjust the crossover and variation parameters adaptively to maintain the diversity of the population. Finally, NSGA III based on reference points is used to map virtual network functions for virtual machines and perform scheduling services to obtain a multi-objective optimization

strategy. The simulation results show that compared with the existing methods NSGA III, NSGA II and MOPSO, the RL-NSGA III method reduces latency by 17% to 28%, improves node load by 9% to 19%, and reduces energy loss by 12% to 26%, which verifies the effectiveness of the proposed method in improving network speed and reducing network operating expenses.

Keywords: network function virtualization; virtual network function; mapping and scheduling; reinforcement learning; the third generation of non-dominated sorting genetic algorithm

在传统网络中,网络功能的实现通常要依靠部署专用的硬件设备,若想扩宽或者增加网络功能,则需要更换或者部署新设备^[1]。然而,专用网络设备成本高,能量开销大,灵活性差,给网络运营管理人员带来诸多不便^[2]。为了克服传统网络引起的困难,适应当前网络需求,电信公司提出了网络功能虚拟化(network function virtualization, NFV)技术^[3]。NFV技术是将软件与硬件进行解耦,通过虚拟化技术,在已有商用设备上以软件的形式实现各种各样的网络功能,以便随时供给网络需求,这样不仅减缓了传统网络对硬件的约束,改善了网络的灵活性,也降低了依赖硬件所产生的成本^[4-6]。

在NFV环境中,根据虚拟网络功能(virtual network function, VNF)的类型、功能以及用户的实际需求,将其进行有序组合,编排形成特定网络功能的服务功能链(service function chain, SFC)。通过NFV部署,网络功能的编排和管理均变得十分便捷。针对特定的网络功能需求,运营商可以实时将虚拟网络功能映射在虚拟机节点上进行实例化调度服务^[7]。

虽然网络功能虚拟化技术具有诸多优势,但随着时代的快速发展及技术的不断革新,人们在享受网络带来方便的同时,又对网络提出了新的要求。根据不同用户需求,虚拟网络功能映射与调度有不同的优化目标^[8]。对于虚拟现实(VR)设备、微型手术机器人、短视频平台、语音IP服务商来说,他们对网络的实时传输速率有较高要求,在一定程度下,低时延是优化的首要目标。对于网络数据中心、5G网络基站而言,在网络正常运行的基础上,节省能耗是他们优化的首要目标。

网络功能虚拟化是SFC根据网络需求的变化,动态地将VNF映射到虚拟机上进行实例化调度服务。因此,随着业务需求的变化和网络请求分配调度的结束,网络负载变得不均衡,大量的资源碎片降低了物理资源利用率,导致网络请求接受率低下,浪费物理资源的同时增加了能量损耗。

在网络功能虚拟化背景下,为满足用户需求、降低网络时延及能量损耗,本文将强化学习算法(RL)与第三代非支配排序遗传算法(NSGA III)相结合,设计了RL-NSGA III算法。该算法通过优化虚拟节点映射与功能调度顺序,可有效降低端到端网络整体时延,提高虚拟机工作负荷,降低能量损耗。本文的主要贡献如下:

(1)在网络功能虚拟化环境下,根据其特性建立了低时延、低能耗、虚拟机高利用率的映射与调度模型;

(2)设计了一种自适应交叉及变异参数的RL-NSGA III算法,将虚拟网络功能动态映射到虚拟节点,同时优化功能调度排序,得到映射与调度最优方案;

(3)将本文方法与其他现有方法进行比较,验证了方法的有效性。

本文结构如下:第1节,对研究人员在虚拟网络功能映射与调度方面的工作进行简要总结;第2节,对虚拟网络功能映射与调度进行描述,构建相关网络模型;第3节,对RL-NSGA III多目标映射与调度算法进行介绍;第4节,采用上述网络模型和算法进行仿真实验研究,并将所提方法与其他现有算法进行对比,展示本方法的优越性;第5节,对文章进行总结,并展望了未来的工作。

1 相关工作

与本文相关的研究工作大多集中在针对VNF映射或调度的单一问题上。文献[8]提出VNF调度本身为非确定性多项式(NP-hard)问题,从而以总服务时延最短为目标,研究了VNF调度延迟的特定问题,并通过建立整数线性模型,设计了一种基于贪婪的启发式算法进行优化求解,结果表明所提算法降低了网络总体服务时延。文献[9]针对模拟部署卫星VNF映射到底层物理网络时延过大的问题,提出了一种维特比(Viterbi)算法与图形模式匹配相结合的动态映射方法,结果表明所提算法能够

有效降低网络时延,并减少资源消耗。文献[10]在 VNF 映射相关问题中,提出采用第二代非支配排序遗传算法(NSGA II)优化求解,结果表明该算法能够提高物理资源利用率及减少物理主机的数量,并具有鲁棒性。文献[11]为了在物联网环境中解决 VNF 映射相关问题,提出了一种新的基于模糊推理的方法,通过优化 VNF 映射机制以及 VNF 动态实例化,以满足特定的服务需求。文献[12]为提高物理资源利用率,提出了一种服务功能链的设计及 VNF 映射算法,采用整数线性规划模型在小规模网络中求出总带宽消耗(TBC)的最优解,结果表明在不同的网络场景下,该方法都能够有效地降低带宽消耗。文献[13]以服务功能链中所有 VNFs 调度的执行时间最小化为目的,提出了一种讨价还价的分布式带宽策略,并引入多层编码遗传算法求解 VNF 模型,验证了算法的有效性。文献[14]考虑了 VNF 传输和处理延迟,以最小化端到端网络服务的总延迟为目标,通过改进遗传算法的交叉变异,降低了问题的复杂性,结果表明改进的遗传算法可以有效降低端到端网络延迟。文献[15]将 NFV 环境中的 SFC 调度问题表述为混合整数非线性规划,以满足延迟和可靠性约束请求数量的最大化为目标,采用改进的强化学习算法学习 SFC 调度策略,提高了 SFC 调度请求的成功率,实验结果表明:改进强化学习算法的调度请求成功率明显高于基准算法。

由于多数情况下 SFC 是动态达到,VNF 映射情况未知,不同节点的运算及资源存储能力具有较大差异,因此将 VNF 映射在不同的节点上,导致服务功能链调度的完成时间、物理资源利用率、网络服务能量损耗等均有较大差异。VNF 映射和 VNF 调度两阶段紧密相连,二者统筹考虑既是当前技术趋势,又是 NFV 实施过程中面临的巨大挑战。虽然 VNF 映射和 VNF 调度联合优化技术尚不成熟,但随着学者对 VNF 映射和 VNF 联合优化的关注,目前在该方面也有一些成果。

文献[16]联合 VNF 布局 and 调度问题,将其表述为整数线性规划(ILP)问题,并提出了基于贪婪和基于禁忌搜索两种启发式算法来解决该问题,实验结果表明所提方法实现了较大收益。文献[17]综合考虑网络服务 VNF 映射和调度,将其描述为一个灵活的作业车间调度问题,以优化最大与最小公平性、同时确保不同服务链的延迟为目标,提出了一种基于离线近端策略优化的深度强化学习方法,该方法基于未完成的 SFC 状态,能够动态地确定映射

和调度决策,结果表明该算法在服务公平性、接受率两方面均优于传统的随机森林和贪婪算法。

针对 VNF 映射与调度优化的相关问题,虽然学者们已提出许多模型和解决方案,但当前研究仍存在以下问题:①大多数文献仅考虑虚拟网络功能映射或调度的单一问题,少有文献将其进行联合优化;②优化的目标较少。在实际的虚拟网络功能映射与调度问题中,应将网络服务的时延、能耗及虚拟机的利用率这3种影响因素结合起来研究;③使用启发式算法,未对参数因子进行自适应,影响解的质量。

2 物理网络与问题模型

2.1 物理网络模型

在问题模型中,底层物理网络用无向图 $G = (A, E)$ 表示,其中 A 为分布式资源服务池中为网络执行实例化服务的虚拟机(virtual machine, VM),数量为 m ,可表示为 $A_j (j = 1, 2, \dots, m)$,或 $A_o (o = 1, 2, \dots, m)$; E 为物理链路的集合, $E = \{(A_j, A_o) \mid A_j, A_o, A_{j,o} > 0\}$,其中 $A_{j,o}$ 表示两节点之间的链路。

2.2 VNF 映射与调度模型

在端到端网络中,当客户端对网络产生需求时,会对网络端发出网络服务请求,网络端根据网络数据流量特性,选取 k 个大小合适的 VNF,按特定的顺序组建 n 条 SFC。此时,VNF 可表示为 $v_h (h = 1, 2, \dots, k)$,SFC 可表示为 $f_i (i = 1, 2, \dots, n)$ 。

SFC 组建完成后,需要将 VNF 进行映射并调度。VNF 映射问题也被称作转发图嵌入(FGE)问题,是一个 NP-hard 问题。映射阶段的主要任务是有效地将 VNF 映射到可执行实例化服务器上,该阶段也是影响网络服务性能和资源利用的关键^[13]。VNF 通常可映射在多个服务器上,但 VNF 只能被一个虚拟机执行实例化,故在该阶段,需将 VNF 与 VM 一对多的映射关系形成集合列表,然后将 VNF 与 VM 进行一对一映射后进行调度服务。每个虚拟节点 VM 可对不同功能大小的 VNF 进行实例化服务,例如,当 v_h 选择虚拟机 A_j 进行映射,则 v_h 将在 A_j 上进行实例化调度服务,此时 v_h 在虚拟节点 A_j 进行实例化服务的产出时延为 $t_{f_i v_h A_j}$,其中 $f_i v_h A_j \in (0, 1)$, $f_i v_h A_j$ 为 1 表示虚拟任务在该虚拟机中执行实例化完成。此外,虚拟网络功能数据流量 l_{v_h} 从虚拟节点 A_j 到 A_o 进行虚拟链路传输,产生的传输时延为 $t_{l_{v_h}}$ 。

SFC 映射实例如图 1 所示。其中, SFC1、SFC2 为 2 条待映射的服务功能链, 分别由 3 个不同功能的 VNF 组建而成。VNF1-1 代表服务功能链 SFC1 上的第一个虚拟网络功能, 根据约束条件只能被映射到

虚拟机 A_1 进行实例化服务; VNF1-2 对应 A_2 、 A_3 , 代表 VNF1-2 可以选择映射至 A_2 或者 A_3 进行实例化服务; VNF1-3 对应 A_3 、 A_5 、 A_6 , 代表 VNF1-3 可以映射至 A_3 、 A_5 或者 A_6 进行实例化服务。余者同理。




图 1 SFC 映射集合示意图
Fig. 1 SFC mapping set diagram

VNF 映射与调度阶段的约束条件可表示为

$$t_{\text{ini}} + t_{f_i v_h A_j} \leq t_{\text{fin}} \leq t_{f_i v_{h+1}} \quad (1)$$

式中: t_{ini} 表示 f_i 上 v_h 开始执行实例化时间; $t_{f_i v_h A_j}$ 表示 f_i 上 v_h 在虚拟机节点 A_j 上执行实例化所用时间; t_{fin} 表示 f_i 上 v_h 执行完成时间; $t_{f_i v_{h+1}}$ 表示 f_i 上 v_{h+1} 开始执行实例化时间。

在同一时间内, 一个 VM 只能对一个 VNF 进行实例化服务, 表示如下

$$t_{f_i v_h} + t_{f_i v_h A_j} \leq t_{f_c v_p} + z(1 - y_{f_i v_h f_c v_p A_j}) \quad (2)$$

$$t_{f_i v_h} \leq t_{f_i v_{h+1}} + z(1 - y_{f_i v_{h+1} f_c v_p A_j}) \quad (3)$$

式中: z 为正整数; $y_{f_i v_h f_c v_p A_j}$ 为二值变量, 其值为 1 表示 f_i 上 v_h 先于服务功能链 f_c 上的 v_p 在 A_j 上执行调度, 其值为 0 表示 f_i 上 v_h 不先于 f_c 上的 v_p 在 A_j 上执行调度。

一个 VNF 只能选择一个 VM 映射后进行实例化调度服务, 写为

$$\sum_{j=1}^{m_h} f_i v_h A_j = 1 \quad (4)$$

式中: m_h 表示第 i 条服务功能链上第 h 个 VNF 可映射虚拟机的个数。

2.3 优化目标

映射集合阶段存在 VNF 映射一个或多个物理节点, 而 VNF 仅需选取一个物理节点执行实例化节点, 于是如何选取物理节点将 VNF 进行映射与排序调度, 将会直接影响到链路传输时延和实例化执行时延。不同学者在 VNF 映射与调度问题的研

究上有着不同的目标。本文的主要优化目标如下。

(1) VNF 映射与调度服务时延目标, 表示为

$$T = \min \left(\max \left(\sum_{i=1}^n \sum_{h=1}^m \sum_{j=1}^k t_{f_i v_h A_j} \right) + \sum_{i=1}^n \sum_{h=1}^k f_i v_h t_{l_{v_h}} \right) \quad (5)$$

(2) VNF 映射与调度服务虚拟机工作负荷目标, 表示为

$$W = \sum_{i=1}^n \sum_{h=1}^k \sum_{j=1}^m f_i v_h A_j t_{f_i v_h A_j} p_j \quad (6)$$

式中: p_j 为虚拟机节点 A_j 的流量负载功率。

(3) VNF 映射与调度服务能量损耗目标, 表示为

$$E = \sum_{j=1}^m \left(\sum_{i=1}^n \sum_{h=1}^k f_i v_h A_j t_{f_i v_h A_j} p_j + \left(t_j - \sum_{i=1}^n \sum_{h=1}^k f_i v_h A_j t_{f_i v_h A_j} \right) u_j \right) \quad (7)$$

式中: u_j 为虚拟机节点 A_j 空载功率; t_j 为虚拟机节点 A_j 上任务完成的时间。

3 RL-NSGA III 映射与调度算法

虚拟网络任务映射与调度优化是多目标优化求解问题, 学者们提出采用高维多目标进化算法来解决此类问题。根据多目标进化机制的不同, 可分为基于非支配关系的多目标进化算法、基于分解的多目标进化算法、基于指标的多目标进化算法等。现阶段, 启发式基于非支配关系的多目标进化算法有

着较多的研究成果。NSGA 系列算法在求解多目标任务时也受到了诸多学者的青睐,但目前仍存在一些问题,如 NSGA II 算法采用拥挤度和拥挤度比较算子,代替了需要指定共享半径的适应度共享策略,但在高维目标空间中的作用并不明显;NSGA II 算法在求解两个以上目标时表现得力不从心,且随着求解目标的增多求解性能会逐渐变差。NSGA III 算法^[19]是在 NSGA II 算法的基础上改进而来,虽然二者具有相似的算法框架,但选择机制有较大不同。NSGA III 算法对拥挤度排序进行了较大修改,通过引入广泛分布参考点维持种群的多样性,能够适应较多的求解目标,从而解决了 VNF 映射与调度的多目标问题。

NSGA III 算法是在遗传算法基础上演变而来,交叉变异操作对求解结果有着至关重要的作用,如果交叉或变异参数过大,种群中较合适的个体容易被摧毁丢失,不利于解的收敛和最优解;如果交叉或变异参数太小,则很难产生新的个体^[20],不利于得到最优解。在传统的 NSGA 系列求解算法中,交叉变异参数经常是固定,然而随着算法迭代求解过程进行,固定的交叉变异概率会影响多样性。

为避免固定交叉变异因子的影响,以求得高质量的解,本文设计了一种自适应多目标求解算法 RL-NSGA III,首先,采用 VNF-VM 两段式初始化方法对 VNF、VM 分别进行初始化,在保留种群多样性的同时提高初始解的质量;其次,采用强化学习的演员-评论家(actor-critic, AC)算法,随着算法迭代,根据过去和未来的状态做出适当预测,自适应地调节交叉变异参数;最后,通过第三代非支配排序,对 VNF 映射与调度所产生的时延、能量损耗、虚拟机负荷 3 个目标进行联合优化求解。

3.1 种群初始化

在使用启发式算法求解该类问题时,学者常常使用集成编码的方式,该方式虽然简单,但因基因过多,在交叉变异过程中极易出现非法解。为了避免非法解的产生并保持种群多样,采用 VM-VNF 两段式方法对染色体进行编码,设定 VM 部分染色体长度为 $\sum_{i=1}^n \sum_{h=1}^k f_i v_h$,然后依次按照虚拟网络功能和调度顺序进行编码排序。

VM-VNF 编码分为两部分,以下给出 3 条服务功能链上共 8 个虚拟网络功能、6 个虚拟机编码的初始化实例。设置染色体 $c_i = [13121214 \mid 12131223]$,其中前 8 个数值表示 VM 选择结果,为

$f_1 v_1, f_1 v_2, f_1 v_3, f_2 v_1, f_2 v_2, f_2 v_3, f_3 v_1, f_3 v_2$, 分别对应可执行实例化服务的虚拟机集合中的编号,第一个数值 1,表示 $f_1 v_1$ 对应可执行实例化服务的虚拟机集合列表中的第 1 个,如 $f_1 v_1$ 可执行实例化服务的虚拟机列表中有 $A_1, A_2, A_3, \dots$,对应的编号 1 即代表 A_1 ;第二个数值 3,表示 $f_1 v_2$ 对应可执行实例化服务的虚拟机集合列表中的第 3 个,如 $f_1 v_2$ 可执行实例化服务的虚拟机列表有 $A_1, A_3, A_5, \dots$,对应的编号 3 即代表 A_5 。根据虚拟机选择,可得出 $f_1 v_1, f_1 v_2, f_1 v_3, f_2 v_1, f_2 v_2, f_2 v_3, f_3 v_1, f_3 v_2$ 选择的机器号分别为 $A_1, A_5, A_2, A_2, A_4, A_3, A_1, A_6$ 。染色体中后 8 个数值表示 VNF 的排序结果,即虚拟网络功能执行调度的顺序,对该段染色体从左到右进行编码,数值对应服务功能链,则该部分染色体虚拟网络功能排序为: $f_1 v_1 \rightarrow f_2 v_1 \rightarrow f_1 v_2 \rightarrow f_3 v_1 \rightarrow f_1 v_3 \rightarrow f_2 v_2 \rightarrow f_2 v_3 \rightarrow f_3 v_2$ 。

3.2 交叉变异操作

初始化部分采用两段式编码方式,故种群需要分别对 VM、VNF 进行交叉变异,以生成新的个体。为保证种群的多样性,根据编码中每个基因先后顺序不变的特点,VM 选择时采用均匀交叉和随机点变异^[16]方式,VNF 排序时为保留父代特性,采用 POX 交叉方式。

取出染色体 c_i 中代表虚拟机选择部分的 $\sum_{i=1}^n \sum_{h=1}^k f_i v_h$ 基因因子,在该区间内随机产生 r 个互不相等的整数,根据产生的整数将父代虚拟机选择部分染色体 c_1 与 c_2 中对应的基因分别复制给子代虚拟机选择部分染色体 $c_{2,1}$ 与 $c_{2,2}$ 并保持其位置与顺序,再将剩余的基因分别复制给子代虚拟机选择部分染色体 $c_{2,2}$ 与 $c_{2,1}$ 并保持其位置与顺序。虚拟机选择部分经过交叉生成了新的个体。取出染色体 c_i 中代表虚拟网络任务排序部分的基因因子,将其随机划分为两个网络任务排序集合 VNF1、VNF2,将父代虚拟网络任务部分染色体 c_1 与 c_2 中包含在 VNF1/VNF2 中的虚拟网络任务,复制到子代虚拟网络任务部分染色体 $c_{2,1}$ 与 $c_{2,2}$ 中保持其位置和顺序,其余 VNF1/VNF2 中的虚拟网络任务复制到子代虚拟网络任务部分染色体 $c_{2,2}$ 与 $c_{2,1}$ 并保持其位置与顺序。

在虚拟网络任务不进行变异的前提下,虚拟机选择部分采用随机多点变异,即在变异染色体 c_i 中选取代表虚拟机选择部分的 $\sum_{i=1}^n \sum_{h=1}^k f_i v_h$ 基因因子,随机选取多个基因位,依次将基因上的虚拟机设定

为当前虚拟网络可执行实例化服务所用时间最短的虚拟机。

3.3 非支配排序

在虚拟网络任务多目标优化求解问题中,非支配排序是关键部分,由于执行与传输时延、虚拟机负荷、能量损耗多个目标相互作用及相互影响,导致优化方向具有不一致性,有时多个目标无法全部求取最优解,因而在该阶段需要将多个目标之间进行整体优化,实现均衡可行。

第三代非支配排序算法是在第二代算法的基础上,引入广泛分布参考点以维持种群的多样性。第三代非支配排序求解的主要步骤如下。

步骤一 通过交叉变异获得子代种群 Q_t ,将父代种群 P_t 与生成的子代种群 Q_t 合并成为种群 R_t , t 表示代的数量。

步骤二 求出理想点 $Z_{\min}$,对种群 R_t 进行非支配排序,形成若干非支配层 $F_1, F_2, F_3, \dots, F_l, l$ 表示层

数。从 F_1 层开始,依次选择个体放入个体集 S_i 中,到 F_l 层时,依次选取最不拥挤的参考点以及距离该参考点最近的点,直到 K 个个体完全加入到 S_i 中。

3.4 AC 调节参数

RL-NSGA III 算法由环境、状态、动作集合、奖励 4 个模块组成。该算法将 NSGA III 算法当作环境,将交叉变异概率作为动作集合,随着算法迭代,环境状态从当前状态变为下一步状态,再根据算法做出的动作得到奖励。一旦环境和状态进行变化,AC 算法需要重新进行探索学习,适应新的状态空间。此外,状态数目过大或无限,均会影响价值函数和策略函数的计算能力,进而影响算法的性能。本文根据文献[20]定义环境状态的范围,研究服务时延(记为 x)、工作负荷(记为 y)、能量损耗(记为 z)3 个目标整体最优,故将奖励设定为 3 个目标即 x, y, z 的加权回报最高。AC 调节 NSGA III 算法的流程如图 2 所示。




图 2 AC 调节 NSGA III 算法流程
Fig. 2 AC adjusts NSGA III algorithm flow

图 2 所示流程图的具体描述如下。

①状态:强化学习所在的环境状态为 NSGA III 算法中交叉变异的概率数值。根据文献[20]定义交叉参数 p_c ,取值为 $0.4 \sim 0.9$,每个动作间隔为 0.05 ;变异参数 p_m ,取值为 $0.01 \sim 0.21$,每个动作间隔为 0.02 。

②动作:在算法的每一次迭代时,智能体都会选取合适的 p_c, p_m ,强化学习在未知环境中进行探索,通过不断尝试做出的动作得到回报,智能体在

NSGA III 每一次迭代过程中选择一组 p_c, p_m 。

③奖励:智能体通过做出的动作得到奖励,由于文本的优化目标有 3 个,且方向具有不一致性,故需要对 3 个适应度进行加权处理,通过归一化加权处理得到整体的优化目标,表示如下

$$Y_t = w_x a_x x + w_y a_y y + w_z a_z z \tag{8}$$

式中: w_x, w_y, w_z 分别为目标 x, y, z 的权重; a_x, a_y, a_z 为目标权重归一化参数。

将优化的增量作为回报,奖励函数可写为

$$R(t) = Y(t) - Y(t-1) \tag{9}$$

式中: $Y(t)$ 、 $Y(t-1)$ 分别为 t 时刻及 $t-1$ 时刻的回报。

4 仿真实验

本节中,针对虚拟网络功能映射与调度联合优化问题,采用 RL-NSGA III 算法对网络时延、节点负荷、能量损耗 3 方面的性能进行评估,通过与现有文献中较优方案进行对比,验证本文模型与算法的优越性。

4.1 实验设置

在 Win10 操作系统、Intel i7 处理器、DDR4 16 GB 内存、NVIDIA GTX 1050 显卡的环境下,采用 Pytorch 工具开展仿真实验,随后在 Openstack 平台上进行部署,以验证算法的有效性。实验参数设置与文献[22]相似,服务功能链条数为 10~100,服务功能链上的虚拟网络功能个数为 3~5,虚拟机节点数为 10,虚拟网络映射的虚拟机节点数为 2~4,虚拟机节点采用全连通的方式。此外,参照文献[8]将虚拟网络功能在映射的虚拟节点执行实例化时间设置为 10~20 ms,对应的传输时延设置为 5~20 ms。服务功能链均为可完全到达状态,虚拟网络功能均为完全执行实例化服务。

4.2 结果分析

为了验证本文 RL-NSGA III 算法的优越性,将其与 NSGA III 算法、文献[10,23]中的 NSGA II 算法、文献[24-25]中的 MOPSO 算法在网络时延、虚拟机节点负荷及能量损耗 3 个方面的性能进行对比。

首先,采用 10 条服务功能链进行虚拟网络功能映射与调度服务。为直观地展示算法性能,图 3 给出了本文算法与对比算法所得结果的三维散点图。由图可见,对于本文的 RL-NSGA III 算法,优化虚拟网络功能映射与调度服务的时延稳定在 90~110 ms,虚拟机节点综合负荷在 590~605 W,能量损耗在 1 000 W 以下,100 次实验所求得的解均比较集中;而 NSGA II 与 MOPSO 算法得到的优化虚拟网络功能映射与调度服务的时延均较长,能量损耗较高,解相对不稳定。相较于其他算法,本文算法在时延、能量损耗等方面均较小,而虚拟机整体负荷较高,表明了资源能够得到有效利用。由于 RL-NSGA III 算法中,RL 需对 NSGA III 算法进行动态调整,从而提升了算法的整体复杂度,导致实验中 CPU 的平均执行时间较其他 3 个算法略长;然而,由于 RL-NSGA III 算法具有较强的自适应能力,相

较于其他 3 个算法能够较快收敛,所以在平均迭代到第 16 次时,即可收敛达到最优解。




图 3 不同算法下 VNF 映射与调度性能的对比
Fig. 3 Comparison of VNF mapping and scheduling results under different algorithms

为了进一步验证 RL-NSGA III 算法的优越性与稳定性,采用 200 条服务功能链在 10 个虚拟机节点上进行映射与调度实验。图 4~图 6 分别给出了相同 SFC 数量下,本文 RL-NSGA III 算法与其他 3 种算法在映射与调度总时延、虚拟机总负荷及能量损耗方面的对比结果。可见,随着 SFC 数量的增加,4 种算法的总时延、虚拟机负荷、能量损耗均增大。

从图 4 和图 5 可以看出,当第一阶段 SFC 数量为 20 时,本文算法的时延最低,机器负载最高,但总的来说,此时 4 种算法得到的时延、机器负荷方面差距较小。随着 SFC 不断增加,4 种算法的差距明显增大,本文 RL-NSGA III 算法几乎成线性且始终保持时延最小,虚拟机负载最大。当 200 条服务功能链服务全部完成时,与 NSGA III、NSGA II 和 MOPSO 算法相比,本文 RL-NSGA III 算法所得到的时延分别减少了 17%、25%、28%,机器负荷分别提高了 9%、13%、19%。

由图 6 可见,随着服务功能链数量增加,4 种算法在能量损耗方面逐渐增加,本文 RL-NSGA III 算法的能量损耗最小,这是由于 RL-NSGA III 算法利用 AC 算法预测并调节其交叉变异参数,在得到优秀基因的同时保持了种群的多样性。由于 RL-NSGA III 算法将 VNF 分配并排序至较空闲的虚拟机,提高了整体利用率,因此有效节省了能耗。与 NSGA III、NSGA II、MOPSO 算法相比,本文 RL-NSGA III 算法得到的能量损耗分别降低了 12%、19%、26%。




图4 不同算法下总时延的对比

Fig. 4 Comparison of total delay under different algorithms




图5 不同算法下虚拟机负荷的对比

Fig. 5 Comparison of virtual machine node load under different algorithms




图6 不同算法下能量损耗的对比

Fig. 6 Comparison of energy loss under different algorithms

5 结 论

针对虚拟网络功能映射和调度服务时间长、能

量损耗高、物理资源利用率低的问题,构建了低时延、低能耗、虚拟机节点资源高利用的多目标优化模型,设计了一种自适应多目标 RL-NSGA III 算法,将虚拟网络功能映射和调度服务联合优化,采用两段式初始化自适应多目标优化算法,得到了质量的初始解;采用强化学习 AC 算法控制 NSGA III 交叉变异参数,保留了种群多样性;采用第三代非支配排序算法将虚拟网络功能动态映射到合适虚拟机的同时,优化了虚拟网功能调度顺序。

仿真结果表明:相较于 NSGA III、NSGA II 和 MOPSO 算法,RL-NSGA III 算法在时延方面减少了 17%~28%,在节点负荷方面提高了 9%~19%,能量损耗降低了 12%~26%。本文为虚拟网络功能映射和调度联合优化问题提供了一种新的思路,接下来将进一步研究网络功能虚拟化中 VNF 组链、映射、调度系统性问题,并将算法部署到真实的联通云上进行测试,以提高算法的实用性。

参考文献:

- [1] LI Biyi, CHENG Bo, LIU Xuan, et al. Joint resource optimization and delay-aware virtual network function migration in data center networks [J]. IEEE Transactions on Network and Service Management, 2021, 18 (3): 2960-2974.
- [2] ZHANG Dong, ZHENG Zhifan, LIN Xiang, et al. Dynamic backup sharing scheme of service function chains in NFV [J]. China Communications, 2022, 19 (5): 178-190.
- [3] GIL HERRERA J D J, BOTERO VEGA J F. Network functions virtualization: a survey [J]. IEEE Latin America Transactions, 2016, 14(2): 983-997.
- [4] 孙士清, 彭建华, 游伟, 等. 5G 网络下资源感知的服务功能链协同构建和映射算法 [J]. 西安交通大学学报, 2020, 54(8): 140-148.
SUN Shiqing, PENG Jianhua, YOU Wei, et al. A coordinating composition and mapping algorithm for a service function chain with resource-aware [J]. Journal of Xi'an Jiaotong University, 2020, 54(8): 140-148.
- [5] 王珂, 曲桦, 赵季红. 多域 SFC 部署中基于强化学习的多目标优化方法 [J]. 计算机科学, 2021, 48(12): 324-330.
WANG Ke, QU Hua, ZHAO Jihong. Multi-objective optimization method based on reinforcement learning in multi-domain SFC deployment [J]. Computer Science, 2021, 48(12): 324-330.
- [6] 唐伦, 贺兰钦, 连沁怡, 等. 基于改进深度强化学习

- 的虚拟网络功能部署优化算法 [J]. 电子与信息学报, 2021, 43(6): 1724-1732.
- TANG Lun, HE Lanqin, LIAN Qinyi, et al. Virtual network function placement optimization algorithm based on improve deep reinforcement learning [J]. Journal of Electronics & Information Technology, 2021, 43(6): 1724-1732.
- [7] 刘光远, 曹晶仪, 庞紫园, 等. 一种低时延虚拟网络功能映射及调度优化算法 [J]. 西安交通大学学报, 2023, 57(2): 121-130.
- LIU Guangyuan, CAO Jingyi, PANG Ziyuan, et al. An optimized algorithm with low latency for virtual network function mapping and scheduling [J]. Journal of Xi'an Jiaotong University, 2023, 57(2): 121-130.
- [8] 徐冉, 王文东, 龚向阳, 等. 网络功能虚拟化中延时感知的资源调度优化方法 [J]. 计算机研究与发展, 2018, 55(4): 738-747.
- XU Ran, WANG Wendong, GONG Xiangyang, et al. Delay-aware resource scheduling optimization in network function virtualization [J]. Journal of Computer Research and Development, 2018, 55(4): 738-747.
- [9] 魏德宾, 杨鹏, 杨力, 等. 一种基于卫星网络的虚拟网络功能快速映射算法 [J]. 计算机科学, 2020, 47(3): 248-254.
- WEI Debin, YANG Peng, YANG Li, et al. Virtual network function fast mapping algorithm over satellite network [J]. Computer Science, 2020, 47(3): 248-254.
- [10] TAVAKOLI-SOMEH S, REZVANI M H. Multi-objective virtual network function placement using NSGA-II meta-heuristic approach [J]. The Journal of Supercomputing, 2019, 75(10): 6451-6487.
- [11] TARIQ M A, FAROOQ M U, ZEESHAN M, et al. FIPAM: fuzzy inference based placement and migration approach for NFV-Based IoTs [J]. IEEE Transactions on Network and Service Management, 2022, 19(4): 4298-4309.
- [12] 朱国晖, 刘璐, 雷兰洁. 基于 VNF 组合的服务功能链设计及映射算法 [J]. 计算机工程, 2020, 46(4): 183-188, 197.
- ZHU Guohui, LIU Lu, LEI Lanjie. Service function chain design and mapping algorithm based on VNF combination [J]. Computer Engineering, 2020, 46(4): 183-188, 197.
- [13] YUAN Quan, TANG Hongbo, YOU Wei, et al. Virtual network function scheduling via multilayer encoding genetic algorithm with distributed bandwidth allocation [J]. Science China Information Sciences, 2018, 61(9): 092107.
- [14] LI Qi, WANG Xing, ZHAO Tao, et al. An improved genetic algorithm for the scheduling of virtual network functions [C]//2019 20th Asia-Pacific Network Operations and Management Symposium (APNOMS). Piscataway, NJ, USA: IEEE, 2019: 1-4.
- [15] JIA Junzhong, YANG Lei, CAO Jiannong. Reliability-aware dynamic service chain scheduling in 5G networks based on reinforcement learning [C]//IEEE INFOCOM 2021-IEEE Conference on Computer Communications. Piscataway, NJ, USA: IEEE, 2021: 1-10.
- [16] PRO MWONGSA N, EBRAHIMZADEH A, GLITHO R H, et al. Joint VNF placement and scheduling for latency-sensitive services [J]. IEEE Transactions on Network Science and Engineering, 2022, 9(4): 2432-2449.
- [17] KUA I Zhenran, WANG Tianyu, WANG Shaowei. Fair virtual network function mapping and scheduling using proximal policy optimization [J]. IEEE Transactions on Communications, 2022, 70(11): 7434-7445.
- [18] HU Hongchao, ZHANG Fan, MAO Yuxing, et al. A forwarding graph embedding algorithm exploiting regional topology information [J]. Frontiers of Information Technology & Electronic Engineering, 2017, 18(11): 1854-1866.
- [19] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based non-dominated sorting approach: solving problems with box constraints [J]. IEEE Transactions on Evolutionary Computation, 2014, 18(4): 577-601.
- [20] CHEN Ronghua, YANG Bo, LI Shi, et al. A self-learning genetic algorithm based on reinforcement learning for flexible job-shop scheduling problem [J]. Computers & Industrial Engineering, 2020, 149: 106778.
- [21] 张韵, 钟慧超, 张春江, 等. 基于机器学习的多策略并行遗传算法 [J]. 计算机集成制造系统, 2021, 27(10): 2921-2928.
- ZHANG Yun, ZHONG Huichao, ZHANG Chunjiang, et al. Multi-strategy parallel genetic algorithm based on machine learning [J]. Computer Integrated Manufacturing Systems, 2021, 27(10): 2921-2928.
- [22] 王琛, 汤红波, 游伟, 等. 一种 5G 网络低时延资源调度算法 [J]. 西安交通大学学报, 2018, 52(4): 117-124.
- WANG Chen, TANG Hongbo, YOU Wei, et al. A resource scheduling algorithm with low latency for 5G

networks based on effective hybrid genetic algorithm and Tabu search [J]. Journal of Xi'an Jiaotong University, 2018, 52(4): 117-124.

- [23] GAMAL M, JAFARIZADEH S, ABOLHASAN M, et al. Mapping and scheduling for non-uniform arrival of virtual network function (VNF) requests [C]// 2019 IEEE 90th Vehicular Technology Conference (VTC2019-Fall). Piscataway, NJ, USA: IEEE, 2019: 1-6.
- [24] CHANTRE H D, DA FONSECA N L S. Multi-objective

optimization for edge device placement and reliable broadcasting in 5G NFV-based small cell networks [J]. IEEE Journal on Selected Areas in Communications, 2018, 36(10): 2304-2317.

- [25] WANG Ranyin, AGHVAMI H, FRIDERIKOS V. An end-to-end network slicing design policy [C]// 2020 IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications. Piscataway, NJ, USA: IEEE, 2020: 1-6.

(编辑 李慧敏 刘杨)