

基于深度强化学习的服务功能链跨域映射算法*

朱国晖, 李庆[†], 梁申麟

(西安邮电大学 通信与信息工程学院, 西安 710121)

摘要: 在域内部分信息隔离场景下, 针对 SFC 映射对传输时延和资源开销的影响, 提出一种基于深度强化学习的服务功能链跨域映射算法。首先提出一个集中式编排架构, 在此架构下上层控制器利用全网格聚合技术来构建抽象拓扑, 降低域间映射复杂度; 其次将 SFC 请求分割问题建模为马尔可夫决策过程, 使得虚拟网络功能均衡地分配到各个域中; 最后以域间传输时延以及映射资源开销为奖励函数构建深度强化学习网络, 通过训练完成域间映射, 如果域内映射失败则采用反馈机制提高 SFC 请求接受率。仿真结果表明, 该算法有效地减小了传输时延和资源开销, 同时提高了请求接受率。

关键词: 多网络域; 服务功能链; 深度强化学习; 反馈机制

中图分类号: TP393 **doi:** 10.19734/j.issn.1001-3695.2020.08.0246

Cross-domain mapping algorithm of service function chain based on deep reinforcement learning

Zhu Guohui, Li Qing[†], Liang Shenlin

(School of Communication & Information Engineering, Xi'an University of Post & Telecommunications, Xi'an 710121, China)

Abstract: This paper proposed a cross-domain mapping algorithm of service function chain based on deep reinforcement learning in view of the influence of SFC mapping on transmission delay and resource cost in the partial information isolation. Firstly, this paper constructed a centralized choreography architecture, which the upper controller utilizes the Full Mesh Aggregation technology to construct the abstract topology and reduce the complexity of mapping between domains. Secondly, this paper modeled the SFC request partition problem as Markov decision process, so that virtual network function can evenly distribute in each domain. Finally, this paper constructed the deep reinforcement learning network when taking the inter-domain transmission delay and mapping resource cost as reward function, and completed the inter-domain mapping by training. If the intra-domain mapping fails, use the feedback mechanism to improve the acceptance rate of SFC requests. Simulation results show that the proposed algorithm can effectively reduce the transmission delay and resource cost. Meanwhile, this can improve the request acceptance rate.

Key words: multiple domain; service function chain; deep reinforcement learning; feedback mechanism

0 引言

随着互联网的发展用户体验和服务创新要求越来越高, 业务需要根据用户的需求进行灵活调整以及快速部署。传统网络功能(如防火墙、深度包检测、负载均衡等)均部署于专用硬件设备中, 网络服务提供商(Internet Service Provider, ISP)不得不购买新的物理设备来满足用户不断增长的需求, 使得ISP的运维支出较高; 同时, 传统网络中ISP很难实现对网络功能实时配置及管理, 业务开发周期长、可维护性能差, 使得ISP的资本性支出较高^[1]。软件定义网络(Software Defined Network, SDN)和网络功能虚拟化(Network Function Virtualization, NFV)的出现缓解了这一问题。NFV技术将网络功能从专用硬件中分离出来, 部署到通用服务器上, 将底层资源云化, 通过云服务商提供网络功能^[2]。而SDN技术将控制平面与数据平面相解耦, 利用控制器实现集中统一的管理, 有助于新业务测试和部署。SDN/NFV环境下ISP对服务功能链(Service Function Chain, SFC)的虚拟网络功能(Virtualized Network Function, VNF)的调整和扩缩容操作更加灵活化^[3]。

SFC的实质是引导数据流通过特定顺序的VNF, 实现端到端业务^[4]。SFC的编排问题即在物理链路上确定一条可行

路径, 其中物理节点满足VNF的计算资源请求且物理链路满足虚拟链路的带宽请求, 同时应减少资源消耗使得ISP的利益最大化。因此, 如何合理实现SFC的映射已成为热门研究领域^[5]。

文献[6,7]的基本思想是将SFC映射问题建模为整数规划模型, 从而达到最大化请求接受率和降低端到端时延的优化目标。文献[8]使用马尔可夫决策过程建模解决SFC映射问题, 以减少平均时延和网络运维开销。

研究人员对SFC映射问题的研究基本上局限于单域网络中。然而, 实际上的网络一般包含多个网络域, 每个域由于政策或竞争关系的原因在不同程度上限制各自域内信息的公开, 且每个域拥有不同的管理策略, 这增加了解决多域网络中SFC映射问题的难度^[9,10]。因此, 如何在不违背多域网络隐私的前提下实现SFC的跨域映射成为了近年来的热点问题, 而域间映射是SFC跨域映射的关键问题, SFC的合理分割对SFC跨域映射有着重要影响^[11]。

现有文献解决SFC跨域映射问题主要分为集中式和分布式两种^[12]。Nestor是文献[13]提出的一种集中式映射框架, 将数据中心网络的关键拓扑信息公开给第三方(即网络服务组合层), 第三方由收集到的本地信息构造一个数据中心级的抽象拓扑, 然后对SFC进行分割, 并使用全局视图部署子链,

收稿日期: 2020-08-18; 修回日期: 2020-09-27 基金项目: 国家自然科学基金资助项目(61371087)

作者简介: 朱国晖(1969-), 男, 陕西西安人, 副教授, 硕导, 博士, 主要研究方向为新一代移动互联网和复杂网络路由算法; 李庆(1996-), 女(通信作者), 陕西西安人, 硕士研究生, 主要研究方向为网络功能虚拟化、服务功能链的跨域映射(1132232794@qq.com); 梁申麟(1995-), 男, 河南漯河人, 硕士研究生, 主要研究方向为弹性光网络中的生存性虚拟网络映射。

此算法未考虑域内是否部署成功。文献[14]提出了平均分割和按权分割两种 SFC 请求分割算法。文献[15]使用了分布式思想, 提出一种基于深度强化学习的算法解决非合作域之间 SFC 的跨域映射问题, 在仅已知域内资源成本的前提下利用竞价机制对 SFC 进行分割。此外, 文献[16]利用 SDN 控制器的全局视图, 通过重新组合 SFC 和 SFC 部署再调整最小化 SFC 跨域映射的成本和时延, 然而此算法破坏了网络域的隐私性。

本文侧重于合作域之间的 SFC 跨域映射问题, 在域内信息部分隔离场景下最小化资源消耗和端到端时延, 提出一种基于深度强化学习的 SFC 请求(SFC Request, SFCR)分割算法, 以有效实现 SFC 跨域映射。首先提出一种集中式编排架构, 域控制器仅将各个域公开信息共享给上层控制器, 上层控制器进行拓扑抽象, 然后由 NFV 主编排器对 SFCR 进行分割, 域编排器按照域内映射策略完成域内映射, 当域内映射不成功时引入反馈机制进行 SFCR 重分割。

1 系统架构和问题描述

1.1 系统架构

SDN/NFV 场景下 SFC 映射更加灵活化, SFC 跨域映射框架如图 1 所示, 包括三个部分: 基础设施层、控制管理层以及应用层。本文将基础设施层划分为多个域, 每个域由 SDN 域控制器进行管理; 在控制管理层中, 本文考虑域内信息部分隔离场景, 域控制器仅将各自域的可用计算资源总和与平均单位开销共享给上层控制器, 上层控制器将底层网络拓扑利用全网格聚合技术[14]进行抽象, 根据抽象拓扑及掌握的部分信息对 SFC 进行切链, 完成域间映射, 域控制器指导域内映射。

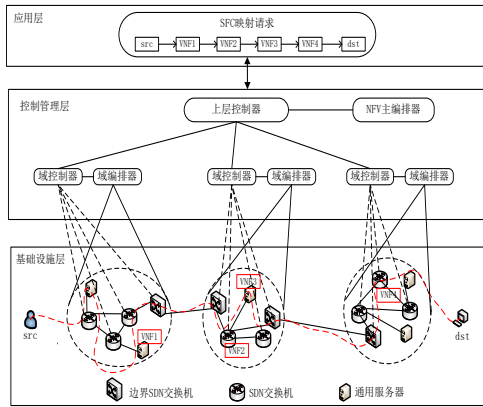


图 1 SFC 跨域映射框架

Fig. 1 Framework of SFC mapping cross multi-domain

1.2 服务链跨域问题描述

a) 物理网络: 物理网络被划分为 k 个域, 可用无向图 $Nets = (G^s, E^s)$ 表示, 其中, $e_{i,j}^s (e_{i,j}^s \in E^s)$ 为第 i 个域和第 j 个域之间的物理链路, 第 i 个域可以抽象为无向图 $G_i^s = (N_i^s, L_i^s) (1 \leq i \leq k)$, N_i^s 和 L_i^s 分别表示第 i 个域内的物理节点和链路集合。因此, $Nets = G_1^s \cup G_2^s \cup \dots \cup G_k^s \cup E^s$ 。

物理网络资源约束定义为 $A^s = (A^N, A^E)$, 其中, A^N 和 A^E 分别表示物理节点 $n^s (n^s \in N^s)$ 和链路 $l^s (l^s \in E^s \cup L^s)$ 的属性集合。 A^N 包括节点剩余计算资源 $cpu(n^s)$ 和资源单位成本 $u(n^s)$, A^E 包括链路带宽资源 $bw(l^s)$ 、链路资源单位成本 $u(l^s)$ 和链路时延 $del(l^s)$ 。

b) SFCR: 用有向加权图 $SFCR = (N^v, E^v, src, dst)$ 表示, 其中, N^v 为 VNF 节点, E^v 为虚拟链路, src 和 dst 分别为 SFCR 源节点和目的节点。对于每个虚拟节点 $n^v (n^v \in N^v)$ 其所需计算资源用 $dem(n^v)$ 表示, 每条虚拟链路 $e^v (e^v \in E^v)$ 其所需带宽资源用 $dem(e^v)$ 表示。

c) 抽象网络: 利用全网格聚合技术生成抽象网络, 用 $G = (N^a, E^a)$ 表示。其中, N^a 为抽象拓扑节点, E^a 为抽象拓扑链路。由于上层控制器要根据抽象拓扑以及掌握的域内信息指导 SFC 的跨域映射, 本文定义 $d(e^a)$ 和 $b(e^a) (e^a \in E^a)$ 分别为域间链路的时延和带宽, 每个域内可用计算资源总和用 $sum(c_i)$ 表示, 平均单位开销用 $avg(u_i)$ 表示, 其中 $i = 1, 2, \dots, k$ 表示第 i 个域。 $sum(c_i)$ 和 $avg(u_i)$ 的表达式如下:

$$sum(c_i) = \sum_{n^s \in N_i^s} cpu(n^s) \quad (1)$$

$$avg(u_i) = \frac{\sum_{n^s \in N_i^s} u(n^s) cpu(n^s)}{\sum_{n^s \in N_i^s} cpu(n^s)} \quad (2)$$

全网格聚合方法如图 2 所示, 在多域网络中, 每个物理节点可以通过边界网关协议获得所有域边界节点(灰色节点)信息, 为了保证隐私性仅利用共享信息构造抽象拓扑, 通过抽象拓扑降低映射复杂度。

本文算法所需信息包括: a) 边界节点和域间链路; b) SFC 的源节点和目的节点; c) 每个域的可用计算资源总和以及平均单位开销; d) 域间链路带宽和时延。

在求解 SFCR 分割问题时应引入布尔变量 x_{ij} , 表示第 j 个 VNF 在第 i 个域的映射情况, 当 n_j^v 被映射到 G_i^s 内时 $x_{ij} = 1$, 否则为 0。 $y_{d,dadj}^{ij}$ 为一布尔变量, 表示虚拟链路 $e_{ij}^v = (n_i^v, n_j^v)$ 与域 d 和 $dadj$ 之间链路的映射情况, 当被映射时 $y_{d,dadj}^{ij} = 1$, 否则为 0。




图 2 全网格聚合技术

Fig. 2 Full mesh aggregation technology

同时, 映射时需满足以下约束:

$$\sum_{i=1}^k x_{ij} \leq 1 \quad (3)$$

$$\sum_{n_j^v \in N^v} dem(n_j^v) x_{ij} \leq sum(c_i) \quad (4)$$

$$\sum_{d \in N^a} \sum_{dadj \in N^a} y_{d,dadj}^{ij} dem(e_{ij}^v) \leq bw(e_{d,dadj}^a) \quad (5)$$

其中, $e_{d,dadj}^a$ 表示域 d 和域 $dadj$ 之间的链路, $i = 1, 2, \dots, k$ 。式(3)保证 VNF 只能映射到一个域内, 式(4)保证第 i 个域有足够的计算资源, 式(5)保证域间链路有足够的带宽资源。边界节点需要与其他网络域进行通信, 本文假设其不用于 VNF 映射。

2 基于 DQN 的 SFC 跨域映射算法

SFC 的跨域映射需要解决 SFCR 分割和子链映射两个关键问题。单域内 SFC 映射问题的研究已相对完善, 本文重点研究如何合理分割 SFCR 完成跨域映射。已有文献证明 SFCR 分割问题为 NP 难问题, 因此本节中将该问题建模为马尔可夫决策过程(Markov decision process, MDP), 提出基于深度强化网络 DQN 的 SFCR 分割算法以求得最优解[17]。同时, 引入反馈机制在域内映射失败时对 SFCR 重分割。

2.1 MDP 建模

MDP 可由 $\{S, A, P, R, \gamma\}$ 表示, 其中 S 为状态的有限集, A 为行为的有限集, P 表示转移概率的集合, R 为即时奖励的有限集, $\gamma \in (0, 1)$ 为折扣因子, 表示未来奖励对当前奖励的重要程度。

SFCR 分割过程中, 上层控制器作为智能体, 根据所掌

握的部分域内信息执行映射动作, 本节将 SFCR 分割问题 MDP 建模描述如下:

状态集合 S : 状态 $s \in S$ 代表网络环境, 包括每个域的可用计算资源之和、已分割的 VNF 与各个域间的映射关系以及正在处理的 SFCR 的资源需求。

动作集合 A : 动作 $a \in A$ 代表从 G^s 中选择一个满足约束条件的域映射下一个 VNF, 从而完成 SFCR 分割。

奖励函数 R : 奖励 $r \in R$ 代表选择第 i 个域映射下一个 VNF 时获得的增益。本文以域间传输时延以及映射资源成本开销两方面来刻画奖励函数。域间链路传输时延可表示为

$$Del = \sum_{d \in N^s} \sum_{dadj \in N^s} y_{d,dadj}^j del(e_{d,dadj}) \quad (6)$$

由于域内信息的隔离, 无法对域内链路成本开销优化, 因此, 映射资源成本开销包括以下两个部分: a) 各个域计算资源开销总和; b) 域间链路带宽资源开销。使用下式表示:

$$Cost = \sum_{i=1}^k \sum_{n_j^i \in N^s} x_{ij} dem(n_j^i) avg(u_i) + \sum_{d \in N^s} \sum_{dadj \in N^s} y_{d,dadj}^j bw(e_{ij}^s) u(e_{d,dadj}) \quad (7)$$

本文考虑在合作域之间最小化端到端时延与资源成本。为保证奖励函数为一正值, 将其表达如下:

$$R(s,a) = -(\eta Cost + \mu Del) + M \quad (8)$$

其中, M 是一个足够大的常数。 $\eta + \mu = 1$, 通过调节两者的值来平衡用户对传输时延及资源开销的需求。

2.2 动作值函数

动作值函数 $Q(s,a)$ 定义了跟随策略 π 时, 在状态 s 下执行动作 a 的奖励期望。可采用时间差分法进行更新:

$$Q(s,a) = Q(s,a) + \alpha [R + \gamma \max_{a'} Q(s',a') - Q(s,a)] \quad (9)$$

考虑到状态 s 包含每个域的可用计算资源之和等连续变量, 基于表格的强化学习算法不适用于 Q 值的更新, 因此本文提出基于 DQN 的 SFCR 分割算法(DQN-SFCR partition, DQN-partition)。

DQN 是对 Q-learning 的修改, 引入神经网络, 拟合一个函数来近似替代 Q 值, 使得 $Q(s,a;\theta) \approx Q(s,a)$, 其中 θ 为神经网络参数^[18]。该网络中将状态 s 作为输入, 然后经过激活函数为 Relu 的两个卷积层和两个全连接层, 最后输出包含每一个动作 Q 值的向量。神经网络训练目的就是最优化损失函数, 即让预测值尽可能接近目标值, 故将其定义为两者的均方误差, 如下式所示。

$$L(\theta) = E[(R + \gamma \max_{a'} Q(s',a';\theta') - Q(s,a;\theta))^2] \quad (10)$$

通过反向传播机制和随机梯度下降法来更新神经网络的参数^[19]。损失函数的梯度可表示为

$$\frac{\partial L(\theta)}{\partial \theta} = E[(R + \gamma \max_{a'} Q(s',a';\theta') - Q(s,a;\theta)) \frac{\partial Q(s,a;\theta)}{\partial \theta}] \quad (11)$$

2.3 算法描述

基于上述 MDP 建模, 可知每一个状态都是连续的, 即前后状态相关联, 而神经网络的训练样本需要相互独立^[20]。因此, DQN 中引入经验回放池和目标网络以切断相关性。

本文将 DQN-partition 算法分为训练阶段和映射阶段。训练阶段如算法 1 所示。

算法 1 DQN-partition 算法训练阶段

输入: 训练集, 训练次数 N_e , minibatch 大小 b_size 。

输出: 神经网络收敛的参数 θ 。

- a) 初始化经验池容量 T , 目标网络更新频率 C , 训练网络参数 θ , 目标网络参数 θ'
- b) for $epoch=1$ to N_e do
- c) 初始化环境
- d) for $SFCR \in$ 训练集 do
- e) 初始化服务链, 获得当前环境状态 s
- f) for $node \in SFCR$ do

- g) 根据 ϵ -greedy 策略选择动作 a , 根据式(8)获得奖励, 并观察下一个状态 s' , 将 (s,a,t,s') 存放在经验池中
- h) if $\forall node \in SFCR$ 成功映射, break
- i) $s = s'$
- j) end for
- k) 从经验池中随机采样 b_size 条 (s,a,t,s') 数据
- l) 根据式(11)更新训练网络参数
- m) 每 C 步更新目标网络, $\theta' = \theta$
- n) end for
- o) end for

通过多次训练后神经网络得到收敛的权重参数, 此时使用算法 2 对 SFC 进行跨域映射, 同时为避免由于不适当的 SFCR 分割, 导致域内子链有可能无法成功映射, 造成 SFCR 阻塞, 故采用反馈机制以提高请求接受率。

算法 2 DQN-partition 算法映射阶段

输入: 测试集。

输出: SFC 跨域映射方案。

- a) 初始化神经网络参数为算法 1 所得参数 θ
- b) for $SFCR \in$ 测试集 do
- c) for $node \in SFCR$ do
- d) 获取当前环境状态 s , 训练后所得收敛的神经网络根据式(9)计算 Q 值
- e) 将 Q 值从小到大排序, 构建队列 R
- f) 选择队头进行映射, 域间映射得到 m 条子链 sub_SFC
- h) end for
- i) for $i=1$ to m do
- j) for $VNF \in sub_SFC$ do
- k) 该 VNF 映射域的控制策略根据域内映射策略选择映射方案
- l) if VNF 映射失败 then
- m) 删除 R 队头, 对 SFCR 进行重分割后执行域内映射
- n) end if
- o) end for
- p) end for
- q) end for

另外, 由于反馈机制在增加 SFC 请求映射接受率的同时会增加请求响应时间, 所以为了平衡请求接受率和响应时间本文只执行一次反馈机制。

3 仿真与性能分析

将本文所提算法 DQN-partition 与 Nestor^[13]、WGT_D^[14]和 Heuristic^[16]算法进行比较。Nestor 使用 CPLEX 求解 ILP 模型, 其本质是暴力搜索算法; WGT_D 根据每个域中剩余可用资源为权重对 SFC 进行分割; Heuristic 在考虑 VNF 之间依赖关系的前提下提出基于 Dijkstra 的启发式算法来选择部署策略。本文域内映射方案采用文献[14]所提子链映射算法求解, 目标函数为最小化传输时延。

3.1 仿真环境

本文使用 IGEN^[21]工具生成物理网络拓扑, 通过 python 进行仿真分析, 利用 tensorflow 框架构建深度学习网络。网络拓扑包含 4 个域, 分别拥有 5、8、11 和 14 个计算节点, 每个域内按 IGEN 中的 Delaunay 模式连接, 域间链路的连通概率为 0.5, 其网络拓扑参数如表 1 所示。SFCR 所需资源都服从均匀分布 $U(10,40)$, 假设每单位资源开销都在 1-5 之间。

表 1 网络拓扑相关参数

物理节点	域内链路		域间链路	
	带宽资源	时延	带宽资源	时延
$U(200,300)$	$U(200,300)$	$U(1,6)$	$U(4000,6000)$	$U(10,20)$

在仿真中, SFCR 的到达服从参数为 $\lambda=60$ 的泊松分布。对不同长度的 SFCR 均生成 2000 条 SFCR 将其映射到底层网络并计算平均值。DQN 的相关参数如表 2 所示。

表 2 DQN 配置参数

Tab. 2 DQN configuration parameters

仿真参数	数值	仿真参数	数值
学习率	10^{-3}	经验池容量	512
折扣因子	0.9	神经网络卷积核大小	(3,3)
批处理大小	64	神经元个数	64,128

3.2 评价指标

本章以请求接受率、平均传输时延及平均资源开销评价所提算法性能。

1) 请求接受率

$$P = \frac{|SFC_{ac}|}{|SFC_{ar}|} \quad (12)$$

其中, $|SFC_{ac}|$ 表示被成功映射的 SFC 请求数, $|SFC_{ar}|$ 表示总共到达的 SFC 请求数。

2) 平均传输时延

$$\bar{D} = \frac{1}{|SFC_{ar}|} \times \sum_{j \in SFC_{ar}} D^j \quad (13)$$

其中, D^j 表示第 j 条到达的 SFCR 的传输时延, 可表示为

$$D^j = \sum_{i=1}^m D_i^{total} + Del \quad (14)$$

其中, $m(m \geq 1)$ 为映射方案经过域的个数, D_i^{total} 表示第 i 个域的总传输时延, Del 为域间链路传输时延。 $m=1$ 表示单域内即可完成映射, 这种情况下 $Del=0$ 。

3) 平均资源开销

资源开销包括节点计算资源开销和链路带宽开销, 与式 (14) 相似, 第 j 条 SFCR 的资源开销 C^j 可表示为每个域部署 SFC 子链的资源开销与域间链路带宽开销之和, 定义如下:

$$C^j = \sum_{i=1}^m C_i^{total} + Cost_b \quad (15)$$

其中, C_i^{total} 表示第 i 个域的总资源开销, $Cost_b$ 为式 (7) 的第二部分, 表示域间链路带宽资源开销。因此, 平均资源开销可表示为

$$\bar{C} = \frac{1}{|SFC_{ar}|} \sum_{j \in SFC_{ar}} C^j \quad (16)$$

3.3 性能分析

图 3 是本文算法的损失函数曲线, 随着训练次数的增加, 损失值逐渐下降, 在经历 100 次训练后趋于平稳。结果表明, 随着训练的进行, 本文所提基于深度强化学习的算法有更好的性能, 这意味着上层控制器可以通过不断学习求得最优映射方案。




图 3 损失函数曲线

Fig. 3 Loss function curve

由图 4 可得, 在特定 SFC 长度下, 本文算法产生的平均传输时延最低, 这是由于本文以域间传输时延和资源开销作为奖励函数, 在 SFCR 分割时最小化域间传输时延和资源开销, 同时在域内映射时优化域内传输时延; Heuristic 算法将 VNF 合并到相同的服务器节点上以减少 SFC 的处理时延和传输时延, WGT_D 算法在部署子链时以传输时延为优化目

标, 但两种算法均未考虑域间链路的传输时延, 实际上域间链路的传输时延远大于域内链路, 因此导致平均传输时延较高; Nestor 算法在 SFC 请求分割和域内映射策略中 SFC 虚拟链路需要映射到更长的物理路径上, 增加了传输时延和资源开销。




图 4 平均传输时延

Fig. 4 Average transmission delay

图 5 比较了不同 SFC 长度下, Nestor 算法、WGT_D 算法、Heuristic 算法和 DQN-partition 算法的平均资源开销, 随着 SFC 长度的增加, 所有算法的平均资源开销均明显增加。其中, DQN-partition 算法平均资源开销低于其他三种算法。这是因为本文算法将整个跨域映射分为训练阶段和映射阶段, 在训练阶段对当前环境进行学习, 从而在映射阶段将 VNF 合理地分配到各个域, 以降低资源开销。




图 5 平均资源开销

Fig. 5 Average resource cost

图 6 表明, 随着 SFC 长度的增加, DQN-partition 算法的请求接受率高于 WGT_D 算法和 Heuristic 算法, 而 Nestor 算法远低于其他三种算法。Nestor 算法未考虑子链映射不成功的情况, 因此其请求接受率非常低; Heuristic 算法对 SFC 映射进行了再调整但未考虑域内剩余资源容量, 会生成更多的资源碎片, 因此其请求接受率较低; 本文算法在 SFC 分割时考虑域内总剩余资源的影响, 并在域内映射失败时采用反馈机制对 SFC 重分割, 提高了请求接受率。另外, 当 SFC 长度为 4 时本文算法与 WGT-D 算法的请求接受率相同且为 1, 这是因为这两种算法均考虑了各个域的剩余资源情况, 并且此时 SFC 请求所需消耗的资源较少, 网络资源容量充足。




图 6 请求接受率

Fig. 6 Request acceptance rate

4 结束语

本文研究合作域下服务功能链的跨域映射, 在不违背各网络域隐私性前提下, 提出一种基于深度强化学习的 SFC 跨域映射算法, 通过学习当前网络环境合理分配 VNF 到各个域中并在域内映射失败时引入反馈机制。仿真结果表明, 与之前多域网络中 SFC 映射算法相比, 该算法提高了 SFC 请求接受率, 降低了平均传输时延以及平均资源开销。如何降低多域网络中 SFC 跨域映射的电能开销问题将在下一步研究中进行完善。

参考文献:

- [1] Liu Junjie, Lu Wei, Zhou Fen, *et al.* On dynamic service function chain deployment and readjustment [J]. *IEEE Transactions on Network & Service Management*, 2017, 14 (3): 543-553.
- [2] P T A Quang, K D Singh, G Picard, *et al.* Single and multi-domain adaptive allocation algorithms for VNF forwarding graph embedding [J]. *IEEE Transactions on Network and Service Management*, 2019, 16 (1): 98-112.
- [3] 周晶玮. NFV 环境下服务功能链的跨域映射研究 [D]. 成都: 电子科技大学, 2019. (Zhou Jingwei. Service Function Chain Mapping Across Multiple Domains in NFV [D]. Chengdu: University of Electronic Science and Technology of China, 2019.)
- [4] H Hantouti, N Benamar. Service function chaining in 5G and beyond networks: challenges and open research issues [J]. *IEEE Network*, 2020, 34 (4): 320-327.
- [5] 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. (Zhu Guohui, Liu Lu, Lei Lanjie. Service function chain mapping algorithm based on VNF combination [J]. *Computer Engineering*, 2020, 46 (4): 183-188.)
- [6] H A Alameddine, L Qu, C Assi, *et al.* Scheduling service function chains for ultra-low latency network services [C]// *International Conference on Network and Service Management*. Tokyo, Japan: IEEE, 2017: 1-9.
- [7] J Pei, P Hong, K Xue, *et al.* Two-phase virtual network function selection and chaining algorithm based on deep learning in SDN/NFV-enabled networks [J]. *IEEE Journal on Selected Areas in Communications*, 2020, 38 (6): 1102-1117.
- [8] 金明, 李琳琳, 张文瑾等. 基于深度强化学习的服务功能链映射算法 [J/OL]. *计算机应用研究*. <http://doi.org/10.19734/j.issn.1001-3695.2019.08.0278>. (Jin Ming, Li Linlin, Zhang Wenjin, *et al.* Service Function Chain mapping algorithm based on deep reinforcement learning [J/OL]. *Application Research of Computer*. <http://doi.org/10.19734/j.issn.1001-3695.2019.08.0278>.)
- [9] E Datsika, A Antonopoulos, N Zorba, *et al.* Software Defined Network Service Chaining for OTT Service Providers in 5G Networks [J]. *IEEE Communications Magazine*, 2017, 55 (11): 124-131.
- [10] F Tusa, S Clayman, D Valocchi, *et al.* Multi-domain orchestration for the deployment and management of Services on a slice enabled NFVI [C]// *IEEE Conference on Network Function Virtualization and Software Defined Networks (NFV-SDN)*. Verona, Italy: IEEE, 2018.
- [11] Li Guanglei, Zhou Huachun, Feng Bohao, *et al.* Horizontal-based orchestration for multi-domain SFC in SDN/NFV-enabled satellite/terrestrial networks [J]. *China Communications*, 2018, 15 (5): 77-91.
- [12] A Abujoda, P Papadimitriou. DistNSE: Distributed network service embedding across multiple provides [C]// *International Conference on Communication Systems & Networks*. Bangalore, India: IEEE, 2016: 1-8.
- [13] D Dietrich, A Abujoda, A Rizk. Multi-provider service chain embedding with Nestor [J]. *IEEE Transactions on Network & Service Management*, 2017, 14 (1): 91-105.
- [14] Sun Gang, Li Yayu, Liao Dan, *et al.* Service function chain orchestration across multiple domains: A Full Mesh Aggregation approach [J]. *IEEE Transactions on Network and Service Management*, 2018, 15 (9): 1175-1191.
- [15] P T A Quang, A Bradai, K D Singh, *et al.* Multi-domain non-cooperative VNF-FG embedding: A deep reinforcement learning approach [C]// *IEEE Conference on Computer Communications Workshops*. Paris, France: IEEE, 2019: 886-891.
- [16] Zhang Chuangchuang, Wang Xinwei, Zhao Yong, *et al.* Cost Efficient and Low-Latency Network Service Chain Deployment Across Multiple Domains for SDN [J]. *IEEE Access*, 2019, 7: 143454-143470.
- [17] J Martín-Pérez, C J Bernardos. Multi-domain VNF mapping algorithms [C]// *IEEE International Symposium on Broadband Multimedia Systems and Broadcasting*. Valencia, Spain: IEEE, 2018: 1-6.
- [18] 魏亮, 黄韬, 张娇等. 基于强化学习的服务链映射算法 [J]. *通信学报*, 2018, 39 (1): 90-100. (Wei Liang, Huang Tao, Zhang Jiao, *et al.* Service chain mapping algorithm based on reinforcement learning [J]. *Journal on Communications*, 2018, 39 (1): 90-100.)
- [19] Xi Chen, Li Zonghang, Zhang Yupeng, *et al.* Reinforcement learning-based QOS/QOE-aware service function chaining in software-driven 5G slices [J]. *Transactions on Emerging Telecommunications Technologies*, 2018, 29 (11): 477-491.
- [20] K Arulkumaran, M P Deisenroth, M Brundage, *et al.* Deep reinforcement learning: a brief survey [J]. *IEEE Signal Processing Magazine*, 2017, 34 (6): 26-3.
- [21] B Quoitin, V Schriek, P Francois, *et al.* IGen: generation of router-level internet topologies through network design heuristics [C]// *International Teletraffic Congress*. Paris, France: IEEE, 2009: 1-8.