

自适应路由服务合成:模型及优化*

卜超¹, 王兴伟¹, 黄敏²

¹(东北大学 软件学院, 辽宁 沈阳 110819)

²(东北大学 信息科学与工程学院, 辽宁 沈阳 110819)

通讯作者: 王兴伟, E-mail: wangxw@mail.neu.edu.cn



摘要: 当前,新型网络应用不断涌现,用户对不同类型应用的通信需求也呈现出多样化和个性化的特点.面向用户频繁产生和变化的通信需求,网络服务提供商(Internet service provider,简称 ISP)通常以不断地购买及部署大量新型的专用网络设备的方式来应对,导致其运营成本高昂,资源浪费严重,网络建设与发展的可持续性差.对此,从软件角度出发,考虑路由功能重用,通过选择合适的路由功能,在通信路径上为应用合成定制化的路由服务,满足用户差异化的需求.基于网络功能虚拟化(network function virtualization,简称 NFV)和软件定义网络(software-defined networking,简称 SDN),提出了一种自适应路由服务合成机制,运用软件产品线技术构建路由服务产品线,作为路由功能选择和路由服务优化的基础.基于机器学习,运用多层前馈神经网络构建路由服务离线模式和在线模式两阶段学习模型,对路由功能选择及组合进行持续学习和优化,实现路由服务的定制化目标,以提高用户的服务体验.进行了仿真实验,研究表明,所提出的模型是可行和有效的.

关键词: 路由服务;网络功能虚拟化;软件定义网络;软件产品线;机器学习;多层前馈神经网络

中图法分类号: TP393

中文引用格式: 卜超,王兴伟,黄敏. 自适应路由服务合成:模型及优化. 软件学报,2017,28(9):2481–2501. <http://www.jos.org.cn/1000-9825/5299.htm>

英文引用格式: Bu C, Wang XW, Huang M. Adaptive routing service composition: Modeling and optimization. Ruan Jian Xue Bao/Journal of Software, 2017,28(9):2481–2501 (in Chinese). <http://www.jos.org.cn/1000-9825/5299.htm>

Adaptive Routing Service Composition: Modeling and Optimization

BU Chao¹, WANG Xing-Wei¹, HUANG Min²

¹(College of Software, Northeastern University, Shenyang 110819, China)

²(College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: Currently, a lot of new types of applications are constantly emerging, and the user communication demands for different applications are also becoming diversified and personalized. To match users' frequent and changing communication demands, internet service provider (ISP) usually constantly purchases and operates new specialized network equipment, which leads to high operating cost and resource waste, and it is obviously unsustainable for network construction and development. This paper addresses the above challenge from the perspective of software-based method by reusing diverse routing functions. The suitable routing functions are selected to compose the customized routing services on communication paths of applications, in order to satisfy the user demands. Based on network function virtualization (NFV) and software defined networking (SDN), the paper proposes an adaptive routing service composition mechanism. It leverage software product line (SPL) to establish routing service product line, which serves as the basis to select routing

* 基金项目: 国家自然科学基金(61572123); 国家杰出青年科学基金(71325002)

Foundation item: National Natural Science Foundation of China (61572123); National Science Foundation for Distinguished Young Scholars of China (71325002)

收稿时间: 2016-09-18; 修改时间: 2017-04-13; 采用时间: 2017-05-05; jos 在线出版时间: 2017-06-05

CNKI 网络优先出版: 2017-06-05 16:32:39, <http://kns.cnki.net/kcms/detail/11.2560.TP.20170605.1632.001.html>

functions and optimize routing services. In addition, based on machine learning, it establishes two-phased routing service learning model, that is, offline mode and online mode, by leveraging multilayer feed-forward neural network. It can constantly adjust and optimize routing function selection and service composition to achieve routing service customization and improve user service experience. Simulation and performance results show that the proposed model is feasible and efficient.

Key words: routing service; network function virtualization; software defined networking; software product line; machine learning; multilayer feed-forward neural network

随着互联网技术的迅速发展和网络规模的持续扩大,越来越多的新型网络应用不断涌现.用户对不同类型应用的通信需求也呈现出多样化和个性化等特点^[1].用户越来越关注于服务体验,即使对同一类型网络应用的通信需求也并非一成不变,比如在不同的心理因素(紧张、放松等)、行为因素(开车、散步等)和地理因素(单位、居室等)等多维状态下,其需求特性也各有侧重^[2].这需要网络能够在应用的通信路径上提供多种多样的路由功能^[3],为差异化的通信需求提供合适的数据分组处理操作,例如提高安全性(使用数据加密功能和访问控制功能等)、保证可靠性(使用故障恢复功能和差错控制功能等)和改善服务质量(quality of service,简称 QoS)(使用分组调度功能和拥塞控制功能等).然而在当前网络环境中,上述数据分组处理功能往往运行于专用物理设备上.面向用户对各类应用的通信需求愈加复杂和多变的挑战,网络服务提供商(Internet service provider,简称 ISP)通常只能是以持续地购买、部署和运行新的专用物理设备的方式来解决,这样做不仅会导致高额的和运维成本^[4],而且随着不断产生和变化的新需求而被动开发和部署新型设备,往往会有一定的滞后性.此外,现有物理设备可能并没有被充分使用就面临淘汰,这会导致大量的资源浪费,多种类型甚至多种厂商私有化的设备及复杂的部署方式还给进一步的服务维护和优化带来困难和挑战.对此,本文从基于软件的角度^[5]考虑,以多种多样实例化的路由功能能够运行于标准的通用物理设备^[6]上的方式,对多样化的功能进行灵活统一地管控,在应用的通信路径上动态地选择合适的功能,合成具有不同特性的路由服务,从而满足用户独特且差异化的需求并优化其服务体验.

ISP 为用户在应用端到端通信路径上提供定制化的路由服务,需要从网络全局角度出发,对多样化的路由功能进行自适应地管控,实现路由服务定制的灵活性、厂商无关性、可编程性和视图全局性等.网络功能虚拟化(network function virtualization,简称 NFV)^[7]和软件定义网络(software defined networking,简称 SDN)^[8]两种网络范型的出现,对本文提出的自适应路由服务合成机制有很大启发.NFV 把基于软件的功能服务从专用的物理网络设备中解耦,通过虚拟化屏蔽底层差异^[9],可以实现路由功能的构件化、接口标准化和可组装化;同时,NFV 通过在底层部署通用网络设备,便于新路由功能的添加和旧路由功能的改进、替换及删除,可以支持以服务链^[10]的形式合成路由服务.SDN 解耦控制平面和数据平面,以逻辑上集中的控制平面提供全局性视图和可编程能力,可以对基于 NFV 的路由功能及服务从全局角度进行抽象和集中管控,促进路由服务合成模型的优化和创新.基于以上分析,本文提出基于软件定义的网络功能虚拟化(software defined network function virtualization,简称 SDNFV),构建自适应路由服务合成机制.

虽然网络环境中多样化的路由功能为定制不同属性的路由服务来满足用户差异化的需求提供了丰富的可选元素,但是这也使得如何选择合适的路由功能进行服务合成更加复杂.如果 ISP 每次定制服务时都要从大量能够实现各路由功能的相关协议及算法中逐个查找、匹配及组合,则不仅占用过多的计算资源,而且会因耗时过多而延长对用户请求的响应时间.例如,以用户对 QoS 的需求为约束^[11,12],从大量的功能中进行功能选择合成端到端的路由服务,就是一个典型的 NP 难问题^[13],需要指数时间对选择过程进行简化和优化^[14].特别地,当可供候选的功能数量很多时,比如,文献[15]中给出一个企业中面向 8 种不同类型的需求有超过 600 种功能,其选择进行组合的可能性超过 2^{45} .对此,本文提出基于软件产品线^[13]的思想,依据不同类型应用的需求领域知识,运用软件产品线属性模型构建方法对多种多样的路由功能进行特性归类及划分,建立路由服务产品线,把路由功能作为可选的能够组装成软件产品的组件,把完整的路由服务作为软件产品,促进路由服务定制化.

用户多样化的通信需求(如服务响应时间、时延容忍度、服务安全等级、服务可靠程度等)及其可能的不同组合方式,要求 ISP 提供路由服务时应该更加关注用户的服务体验质量,从而优化用户对所获服务的满意程

度^[16]。然而,用户对应用的通信需求与合适的路由功能选择是一种非线性可分的映射关系,即:难以简单地依据用户的若干需求及其组合情况,线性地将其映射到若干确定的功能及组合^[14],且无法保证由此合成的路由服务能够优化用户的服务体验。对于每项路由功能,可以有很多可选的实现其协议及算法,虽然它们都可以实现某类分组处理操作,但不同算法的侧重点往往不同,因而可能更适合某种应用或用户的某种需求,这就为进一步优化用户的服务体验提供了更细粒度的可选性。当前,规模巨大的用户通过互联网利用各种应用进行通信与交流,持续产生大量的应用通信相关信息(如用户的多项需求及组合、ISP 提供的路由服务和用户的服务体验反馈等)。

鉴于此,本文考虑结合机器学习的思想,提出两阶段学习模式:离线学习模式和在线学习模式,分别由积累的历史通信信息和持续产生的新的通信信息进行训练和学习。离线学习模式和在线学习模式不是由两种孤立的学习方法分别完成,而是进阶关系,即:离线学习模式作为在线学习模式的基础和起点,在线学习模式作为离线学习模式的延续,进一步地实现长期且持续的优化操作。在当前众多机器学习方法(如逻辑回归、支持向量机、遗传算法、朴素贝叶斯和神经网络等)中,相较而言,逻辑回归和支持向量机对非线性可分的问题缺少通用化方法,遗传算法过程较为复杂而不利于实现快速反馈及优化,朴素贝叶斯不擅长处理分类性问题,而神经网络方法具有较好的非线性映射能力,通过训练能够反映出多项需求和多项被选择功能之间的内在相关关系,其分布式处理机制使其具备较强的学习能力,学习及优化过程有较好的延续性,通过离线学习模式训练输入和输出之间的合理规则,然后进一步依据在线学习模式的实时反馈持续且快速地优化细粒度的功能选择及组合方式,而且其定量及定性的信息存储于多个神经元中,使其具备鲁棒性和容错性。在基于 SDNFV 的框架模型下,神经网络的训练和优化等计算过程主要集中于控制平面,离线学习模式的训练过程不对数据平面造成开销,并不会影响其数据通信活动;在线学习模式训练只需要交换机每次服务结束后向控制平面反馈用户的服务体验信息,不会在该服务进行过程中产生额外开销,并且其上传的服务体验信息相关的数据量较小,只需使用控制平面与数据平面之间的南向连接,不会影响到数据平面东西向连接的带宽资源。

本文融合机器学习思想,基于路由服务产品线,利用多层前馈神经网络构建路由服务离线模式和在线模式两阶段学习模型,其中:离线模式依据 ISP 积累的历史经验信息(如支持各类应用通信的通用服务配置),训练并获得面向通用路由服务的离线模式神经网络权值配置,实现通用路由功能选择;在线模式基于训练完成后的离线模式神经网络权值设定情况,由在线模式神经网络依据用户差异化的个性化需求和每次对所获路由服务的体验反馈情况进行学习和训练,进一步持续优化不同应用情形下更合适的专用路由功能选择及路由服务合成能力,实现路由服务定制化,从而提高用户服务体验。

本文的主要贡献如下:(1) 提出基于 SDNFV 的路由服务合成机制,为不同类型应用合成及提供定制化的路由服务,满足用户差异化的通信需求;(2) 结合软件产品线的思想构建路由服务产品线,实现对多种多样路由功能的特性划分,作为路由服务学习的依据和训练的基础;(3) 融合机器学习思想,提出基于多层前馈神经网络的路由服务学习模型;(4) 提出路由服务离线学习模式,依据 ISP 历史经验训练神经网络,获得支持各类应用基本通信所必需的通用功能选择及组合方式,作为路由服务在线学习模式的基础;(5) 提出路由服务在线学习模式,在离线模式训练完成的神经网络基础上,依据用户个性化的需求情形及其对所获服务的反馈体验来训练和优化专用功能选择,从而实现路由服务定制化目标。

1 相关工作

近年来,已有一些研究工作基于路由功能模块,通过协作方式来实现动态路由服务的配置。文献[17]提出了一种端到端的路由服务配置框架,通过准入控制和端到端带宽预留机制保证业务流的资源需求,并且采用动态带宽配置机制适应网络负载变化。文献[18]提出了结合任务控制模型和模糊控制模型的中间件控制结构,通过动态控制内部参数和重组相关功能来配置路由服务,从而提高路由服务决策的有效性。文献[19]提出以服务为驱动的路由配置方案,通过在每个节点上配置一组服务来改善通信路径的传输能力,优化 QoS。文献[20]提出了一种基于智能构件的路由服务发现和选择机制,利用网络服务本体语言和领域本体知识查找路由服务,并通过 QoS 信息对备选服务进行排序,提高路由服务配置效率。文献[21]提出了一种集成了仿生机制的路由配置方法,

通过服务管理层提供有效的管理机制来改善用户体验,其基础设施层对服务管理层进行支持和协作,实现复杂和频繁的服务合作行为.文献[22]提出了一种避免拥塞的路由配置算法,通过组合本地 QoS 路由和控制机制来优化本地路由服务的生成决策.虽然以上研究工作通过组合已有的路由相关功能模块来生成和部署路由服务,实现不同的路由配置目的,但这些工作中提出的路由合成模型及路由模块选择机制相对固定,可扩展能力不足,难以实现从全局角度灵活且准确地选择及调用多样化的路由相关功能.同时,上述工作尚未考虑用户服务体验质量,难以提升用户对路由服务的满意度.相比之下,本文提出的模型可以定制化地合成路由服务,基于 SDNFV 实现对多样化路由功能的统一调控,支持用户服务体验的改善.

已有一些研究工作利用 SDN 和 NFV 以服务链进行功能选择和服务合成,实现已有功能的可重用化.比如,文献[23]提出了一种优化组合模型,把动态功能合成定义为多维多选择背包问题(multi-dimension multi-choice knapsack problem,简称 MMKP),并且利用马尔科夫近似方法,提出了一种分布式算法加以解决.文献[24]利用网络虚拟化机制和可编程流量控制机制,提出了一个网络感知服务合成和交付模型.文献[25]提出了一个有效的服务链实例化框架,对网络功能进行抽象化描述,并以此构建服务链模型.还有一些研究工作融合了功能组装的思想来进行服务的整体设计和合成,实现了多样化服务的快速提供.文献[26]基于可重构的服务构件,提出了一种组合决策流程来实现服务合成,并且利用多目标进化算法提高合成效率.文献[27]为实现网络即服务(network as a service,简称 NaaS),提出了一个服务合成框架,通过动态地组合分布式功能组件,提供定制化的网络服务.文献[28]提出了一种支持服务链即服务(service chain as a service,简称 SCaaS)的开放式平台,利用 SDN 和 NFV 的优点来实现服务链策略,进行功能选择以合成服务.文献[29]提出了一种基于软件产品线的服务选择方案,通过发现不同服务所包含的相同功能,实现快速匹配来合成服务,以满足用户偏好.文献[30]结合聚类和关系挖掘,提出了一种服务合成技术,用来构建基于粒度计算的多租户服务定制方案.虽然上述工作基于 SDN 和 NFV 进行服务合成,然而它们并没有考虑以功能组装形式合成的服务的自适应演化能力,不能根据每轮服务过程中积累的反馈信息优化其功能组成及合成方式,而且上述工作关注的是通用网络服务,没有充分考虑应用通信路径上路由服务合成的特殊性.相比之下,本文工作专门针对网络路由服务的要求,提出合成机制,既可以自适应地对功能选择及服务合成进行持续地学习及优化,又有助于改善用户对路由服务的体验质量.

2 路由服务合成机制

2.1 系统框架

面向网络路由,本文基于 SDNFV 构建路由服务合成机制,通过 NFV 把基于软件的路由功能从底层网络基础设施中解耦,构建基于 NFV 的路由服务编排中心;通过 SDN 把控制逻辑从数据转发中解耦,构建基于 SDN 的路由服务控制中心.该机制的系统框架结构如图 1 所示.

本文假设网络基础设施由大量互联且支持 NFV 的通用数据转发设备(如交换机)构成,对应于数据平面.数据转发设备是可编程的,不仅包含路由服务匹配规则,用于匹配各类应用通信请求,从而高效地为其提供路由服务,而且包含可被编程写入的路由功能,实现对分组的差异化处理及转发操作,还包含支持同上层平面进行交互的通信模块(例如接收路由服务匹配规则、规则匹配失败时请求新规则、请求嵌入必需的路由功能以及反馈用户的服务体验信息等).其中,路由服务匹配规则的具体示例如图 2 所示.

基于 NFV 的路由服务编排中心对底层网络基础设施进行虚拟抽象并屏蔽底层差异,把数据平面映射到虚拟平面,用于向上呈现网络业务和抽象网络模型.虚拟平面包含功能池和虚拟化网络(由逻辑节点和逻辑链路组成)、计算资源及存储资源.在功能池中,有多样化的路由功能(如路由相关的各种协议及算法等),按构件化和接口标准化实现,从而支持可重用、可扩展和可组装等特点.不同的路由功能对分组做不同的处理,通过组合适当的路由功能在应用的通信路径上合成路由服务,可以提供满足应用通信需求的定制化的分组处理及转发操作.网络和资源的虚拟化便于上层平面从全局视图上对其进行统一的调度和分配.

基于 SDN 的路由服务控制中心生成控制平面,作为整个路由服务合成机制的逻辑控制中心.控制平面主要包含应用领域知识集合、路由服务产品线、路由服务学习模块和路由服务组装模块.应用领域知识集合中有不

同类型应用的通信需求领域知识,用于构建针对不同类型应用的路由服务产品线.依据不同的路由服务产品线,在路由服务学习模块中运用不同的神经网络适应用户差异化的需求,神经网络由离线模式学习及训练后,再由在线模式依据每次用户的个性化需求和对服务体验的反馈信息进行持续学习及优化.路由服务组装模块依据路由服务学习模块中相应的神经网络生成及更新路由服务匹配规则,并且下发相应的规则到数据平面.

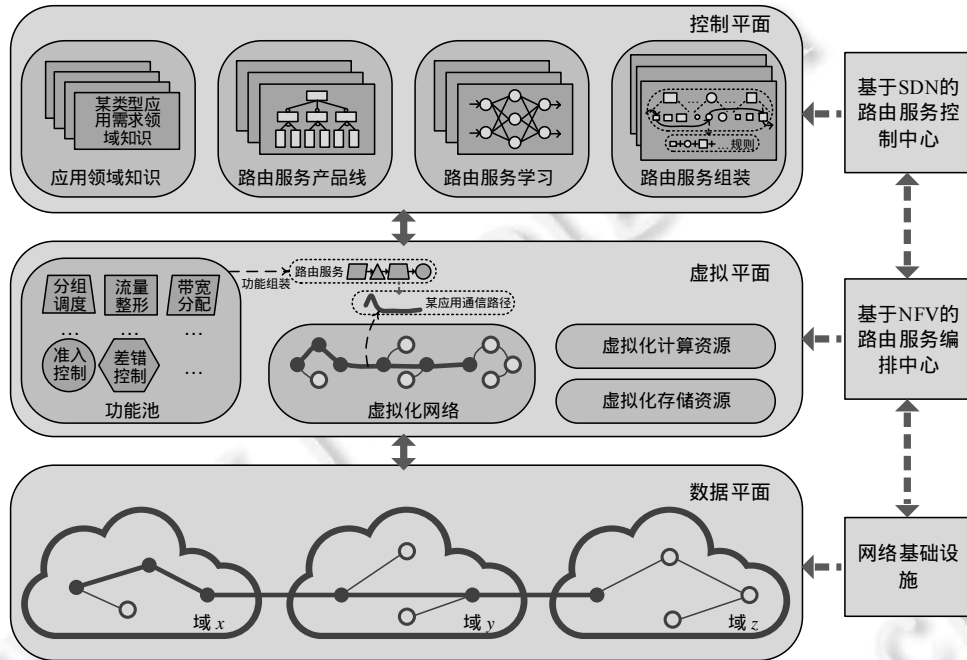


Fig.1 Software-Defined NNFV based routing service composition mechanism

图 1 基于 SDNFV 的路由服务合成机制

匹配域	指令域	计数器			
分组处理动作集合		功能标识集合			
入端口	流量类型	源IP地址	目的IP地址	流标签	需求项

Fig.2 Routing service matching rule

图 2 路由服务匹配规则

2.2 路由服务产品线

面向用户对不同类型应用的多样化和个性化的通信需求,在多种多样能够实现对分组不同的处理及转发操作的路由功能中,ISP 需要具备高效且准确区分及定位各路由功能的能力,从而快速地选择合适的路由功能以合成具有不同特性的路由服务,实现路由服务的定制化目标,进而优化用户的服务体验.对此,本文运用软件产品线的属性模型分析方法^[31,32],依据不同类型应用的通信需求领域知识来构建多样化的路由服务产品线.软件产品线的属性分析方法是针对该产品线能够生产的所有软件产品的外部可见特征(如构成软件产品的各功能)进行识别分类,并把它们组合成相应的属性模型.本文通过构建路由服务产品线,把每个定制化的路由服务作为一个软件产品,把所有可能被选择的路由功能作为合成软件产品的功能组件,以这种方式,面向不同类型应用差异化的通信需求,选择不同的路由功能合成不同的路由服务.

根据不同类型应用的领域知识,即 ISP 积累的应用通信相关信息,建立由属性到功能的 3 层路由服务产品

线,粒度逐层变细,作为从离线学习模式到在线学习模式来优化路由功能选择及服务合成的基础.在路由服务产品线中定义固定点和可变点,其中,固定点为强制特性或功能,即,由该产品线合成的路由服务必须具有的基本属性或功能,可变点为可供选择的特性或功能,即,由产品线在可变点处选择不同的特性或功能.可变点的存在使得合成的路由服务可以具有不同的属性和功能,这也是定制多样化和个性化路由服务的关键.

本文提出的路由服务产品线包括服务属性层、通用功能层和专用功能层,如图 3 所示.

- 服务属性层是该产品线定制的路由服务可能具备的特性集合.例如:连接特性是强制特性,即,路由服务要么是面向连接的,要么是无连接的;QoS 特性是可选特性,例如,视频点播类应用需要支持 QoS 的路由服务,电子邮件类应用无需 QoS 支持;
- 通用功能层是为实现路由服务特性所需的功能分类及集合.例如,为保证视频点播类应用对 QoS 特性的需求,分组调度、拥塞控制、流量整形、带宽分配和缓冲处理等功能中的一个或多个可被选为合成该路由服务的功能构件;
- 专用功能层是对应于各通用功能的多样化专用功能(如各种具体的协议及算法)的分类及集合,各分类中的专用化功能都能实现其对应通用功能对分组处理的目的,而且各分类中的不同的专用化功能还具备某些专有功能(针对的需求因素不同或优化的侧重点不同等).例如,对于缓冲处理功能分类下的完全划分策略和完全共享策略,两种专用功能都能实现对分组的缓冲处理目的.若选择完全划分策略,则应用的分组能够独立使用其被分配的缓冲资源从而降低被丢弃的概率,但成本可能较高;若选择完全共享策略,则应用的分组可能因为缓冲资源被其他应用的分组占用而被丢弃的概率增大,但成本可能较低.因此,在细粒度的专用功能层中,通过进一步对多种多样独特的专用功能进行选择并合成定制化的路由服务,可以满足用户多样化和个性化的通信需求,从而优化其服务体验.

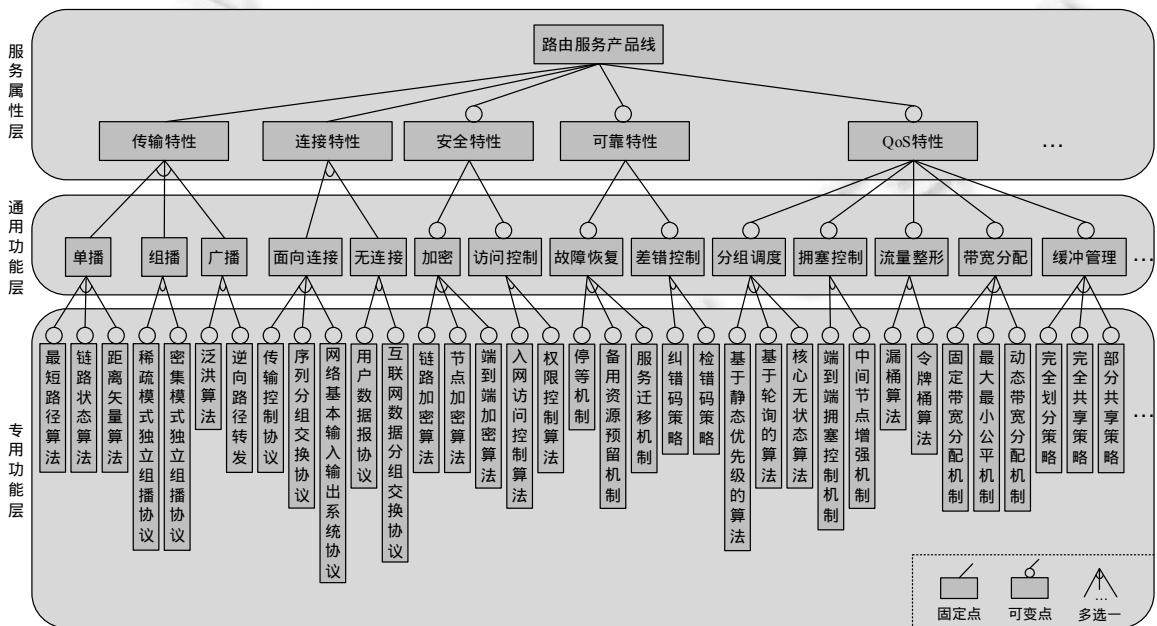


Fig.3 Routing service product line

图 3 路由服务产品线

2.3 路由服务组装

依据路由服务产品线,通过路由服务离线学习模式的训练,系统获得通用功能层中面向不同类型应用的通用功能选择及组合情况,再通过在线学习模式的优化,获得专用功能层中针对用户个性化需求情形下的专用功

能选择及组合情况(详见第3节),路由服务组装模块基于路由服务学习模块的路由功能选择结果,组装相应的路由功能及资源合成路由服务,并且生成或更新对应的路由服务匹配规则。

定义 1. 路由功能定义为一个 3 元组 $\langle rf_{id}, P, CI \rangle$,其中, rf_{id} 是该路由功能的唯一标识; $P = \{p_1, p_2, \dots, p_a | a \in N_+\}$ 是该路由功能的端口集合; $CI = \{pull, push\}$ 是该路由功能的操作方法集合,用于支持分组在各功能之间的迁移,包括 $pull$ 和 $push$,其中:前者是拉操作,支持其把等待处理的分组从对端拉到己方对其处理;后者是推操作,支持其把处理完毕的分组推到对端。

定义 2. 路由服务定义为一个 5 元组 $\langle rs_{id}, Pac, cr, sr, RF \rangle$,其中, rs_{id} 是该路由服务的唯一标识, $Pac = \{pac_1, pac_2, \dots, pac_b | b \in N_+\}$ 是被该路由服务处理和转发的分组集合, cr 和 sr 是该路由服务运行所需的计算和缓存资源, $RF = \{rf_1, rf_2, \dots, rf_c | c \in N_+\}$ 是构成该路由服务的路由功能集合。

定义 3. 操作符 $\oplus(rf_i, rs_j)$ 定义为把路由功能 rf_i 加入到路由服务 rs_j 中, $i, j \in N_+$ 。

定义 4. 操作符 $\otimes(rf_i, rs_j)$ 定义为把路由功能 rf_i 从路由服务 rs_j 中删除, $i, j \in N_+$ 。

推论 1. 替换操作可以由一次 \oplus 操作和一次 \otimes 操作实现。

推论 2. 路由服务的初始组装过程可以由 x 次 \oplus 操作实现, $x \in N_+$ 。

推论 3. 已建立的路由服务可以由 x 次 \oplus 操作和 y 次 \otimes 操作进行改变, $x, y \in N_+$ 。

推论 4. 路由服务对分组的处理和转发可以通过构成其的路由功能进行 x 次 $pull$ 操作和 y 次 $push$ 操作实现, $x, y \in N_+$ 。

本文把路由服务抽象为服务链结构,其中,构成路由服务的各路由功能作为服务链的节点,用于对分组进行处理,并利用 $pull$ 和 $push$ 两个操作对分组进行迁移,直到分组被处理完毕从而被路由服务转发出去。路由服务抽象模型如图 4 所示。

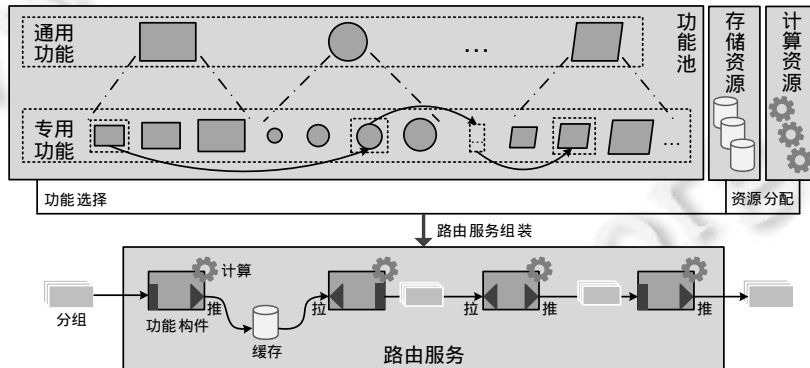


Fig.4 Routing service abstraction model

图 4 路由服务抽象模型

3 路由服务学习及优化

对路由服务的某项特性需求往往难以简单地直接由该特性对应分类的路由功能独立满足,通常还可能需其他分类的路由功能以组合或协同的方式共同实现.例如:从粗粒度角度看,对 QoS 特性的需求可能还需要连接特性(面向连接)和可靠特性(差错控制)等的支持;从细粒度角度看,拥塞控制往往还需要实现分组调度和缓冲管理的相关算法等提供支持.特别是在路由服务同时需要满足多项不同特性时,选择合适的路由功能进行所需的组合更加复杂.本文基于机器学习,使用多层前馈神经网络进行学习,通过训练和优化获得针对不同需求情形的路由功能选择及组合,从而实现路由服务的定制。

在本文提出的路由服务产品线中,路由服务离线学习模式和在线学习模式分别对应于通用功能层和专用功能层.其中:离线学习模式是指 ISP 依据其为不同类型应用配置路由服务的经验样本(即,支持各类应用通常所

必需的通用功能,例如综合服务模型或区分服务模型中对各类应用的路由服务配置情况),训练面向不同类型应用的离线模式神经网络,从而获得相应的离线模式神经网络权值设置;在线模式是指基于训练完成后的离线模式神经网络权值设置情况,依据用户个性化的需求和用户对其所获路由服务的体验反馈,对相应的在线模式神经网络进行调整和优化,获得针对用户各种个性化需求下专用功能的选择及组合,从而提供定制化的路由服务.由于互联网环境中的用户规模十分庞大,而且用户对应用的新的通信需求不断产生,因此在线学习模式对神经网络在不同个性化需求下的调整是持续的,通过不断优化专用功能选择及组合来提升用户的服务体验.路由服务离线学习模式与在线学习模式的关系如图 5 所示.




Fig.5 Relationship between the offline learning mode and the online learning mode

图 5 离线学习模式和在线学习模式关系

3.1 离线学习模式

在离线学习模式中,ISP 根据各类应用对路由服务通常的特性需求和为各类应用提供通用化路由服务的配置经验(通常支持各类应用通信所必需的功能配置)来训练相应的离线模式神经网络.基于上述建立的路由服务产品线,服务属性层各特性作为神经网络输入层各神经元,通用功能层各功能作为神经网络输出层各神经元,输入信息(如应用对各特性的需求情况)经神经网络的隐层和输出层处理加工后,由输出层各神经元输出结果.通过对比该输出结果与训练样例,利用逆误差传播算法训练和调整相应神经网络的各权值设置情况.对于某类型的应用,训练其通用路由服务的神经网络(离线学习模式)的定义如下:

定义 5. 离线模式神经网络定义为一个 6 元组 $\langle ofn_{id}, X, H, Y, XH, HY \rangle$, 其中: ofn_{id} 是该离线模式神经网络的唯一标识; $X = \{X_1, \dots, X_i, \dots, X_n | i, n \in N_+\}$ 是输入层神经元集合; $H = \{H_1, \dots, H_j, \dots, H_q | j, q \in N_+\}$ 是隐层神经元集合; $Y = \{Y_1, \dots, Y_l, \dots, Y_m | l, m \in N_+\}$ 是输出层神经元集合; $XH = \{XH_{11}, \dots, XH_{ij}, \dots, XH_{nq} | i, j, n, q \in N_+\}$ 是输入各层神经元与隐层各神经元之间的权值集合, XH_{ij} 为 X_i 与 H_j 的连接权值; $HY = \{HY_{11}, \dots, HY_{jl}, \dots, HY_{qm} | j, l, q, m \in N_+\}$ 是隐层各神经元与输出层各神经元之间的权值集合, HY_{jl} 为 H_j 与 Y_l 的连接权值.

定义 6. 输入层神经元定义为一个 2 元组 $\langle X_{id}, IX_{id} \rangle$, 其中: $X_{id} (X_{id} \in X)$ 是该神经元的唯一标识, 对应于路由服务产品线服务属性层中的一个特性, 即, X 中各元素分别对应于服务属性层中各特性, 并作为相应特性的标识; IX_{id} 是 X_{id} 的输入.

定义 7. 隐层神经元定义为一个 4 元组 $\langle H_{id}, IH_{id}, OH_{id}, f \rangle$. 其中: $H_{id} (H_{id} \in H)$ 是该神经元的唯一标识, IH_{id} 是 H_{id} 的输入, OH_{id} 是 H_{id} 的输出, f 是神经元激活函数.

定义 8. 离线模式神经网络的输出层神经元定义为一个 4 元组 $\langle Y_{id}, IY_{id}, OY_{id}, f \rangle$, 其中: $Y_{id} (Y_{id} \in Y)$ 是该神经元的唯一标识, 对应于路由服务产品线通用功能层中的一个通用功能, 即, Y 中各元素分别对应于通用功能层中各通用功能, 并作为相应通用功能的标识; IY_{id} 是 Y_{id} 的输入; OY_{id} 是 Y_{id} 的输出, 其数值表示 Y_{id} 在一个路由服务中的被选概率; f 是神经元激活函数.

定义 9. 离线模式神经网络的训练样例定义为一个 2 元组 $\langle A, Z \rangle$, 其中: $A \in \mathbb{R}^n$ 为样本的输入示例, $A = \{A_1, \dots, A_i, \dots, A_n\}$, A_i 对应于 IX_{i_s} , 是 X_i 的输入, 即, A 由该类应用对 X 中 n 个特性的需求情况来描述; $Z \in \mathbb{R}^m$ 为样本的输出示例, $Z = \{Z_1, \dots, Z_l, \dots, Z_m\}$, 即, 输出 m 个被选择的通用功能, 若某通用功能被选择, 则 Z 中相应元素值为 1, 否则为 0.

离线模式神经网络具体结构如图 6 所示.

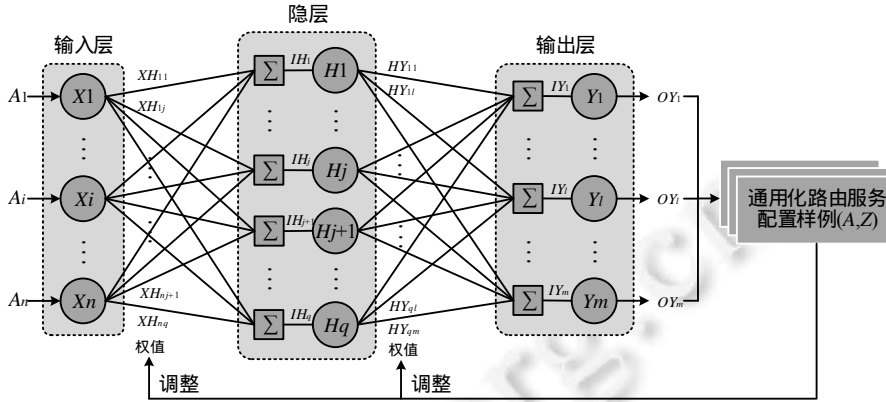


Fig.6 Offline learning mode neural network

图 6 离线学习模式神经网络

以训练样例(A,Z)的输入示例 A 作为输入层 X 中各神经元的输入,即,IX=A_i 作为 X_i 的输入,表示对 X_i 所对应的特性的需求情况,则 IH_j 和 IY_l 分别如下所示:

$$IH_j = \sum_{i=1}^n A_i \cdot XH_{ij} \tag{1}$$

$$IY_l = \sum_{j=1}^q OH_j \cdot HY_{jl} \tag{2}$$

隐层和输出层神经元的激活函数 f 采用典型的 Sigmoid 函数^[33],如下所示:

$$f(x) = \frac{1}{1 + e^{-x}} \tag{3}$$

该函数具有如下性质:

$$f(x) = f(x)(1 - f(x)) \tag{4}$$

因此,OH_j 和 OY_l 分别如下所示:

$$OH_j = f(IH_j) \tag{5}$$

$$OY_l = f(IY_l) \tag{6}$$

显然,有 0 < OH_j < 1 和 0 < OY_l < 1,其中,OY_l 为 Y_l 对应的通用功能被选择的概率,即,Y_l 作为组装通用路由服务的一个功能的可能性。

假设对于上述训练样例(A,Z)中的 A,该离线模式神经网络的输出集合为 OY(OY_l ∈ OY),记为(A,OY),则输出 OY 与 Z 之间的均方差 E 如下所示:

$$E = \frac{1}{2} \sum_{l=1}^m (OY_l - Z_l)^2 \tag{7}$$

依据逆误差传播算法,以给定的训练样例为目标,从负阶梯方向对离线模式神经网络各权值进行调整^[34].隐层中 H_j 与输出层中 Y_l 之间的连接权值 HY_{jl} 的学习及调整方式如下:

$$HY_{jl} \leftarrow HY_{jl} + \Delta HY_{jl} \tag{8}$$

$$\Delta HY_{jl} = -\beta \cdot \frac{\partial E}{\partial HY_{jl}} \tag{9}$$

其中,β(β ∈ (0,1))为学习率.依据链式法则,表达式(9)可以做如下变化:

$$\Delta HY_{jl} = -\beta \cdot \frac{\partial E}{\partial OY_l} \cdot \frac{\partial OY_l}{\partial IY_l} \cdot \frac{\partial IY_l}{\partial HY_{jl}} \tag{10}$$

由表达式(2)~表达式(4)、表达式(6)和表达式(7),可得:

$$\begin{cases} \frac{\partial Y_l}{\partial H_j} = OH_j \\ \frac{\partial E}{\partial OY_l} = (OY_l - Z_l) = M_l \\ \frac{\partial OY_l}{\partial Y_l} = f'(IY_l) = OY_l \cdot (1 - OY_l) \end{cases} \quad (11)$$

将上述表达式带入式(10),可得 ΔHY_{jl} 的最终表达式如下:

$$\Delta HY_{jl} = \beta \cdot OH_j \cdot OY_l \cdot (OY_l - 1) \cdot M_l \quad (12)$$

同理,输入层中 X_i 与隐层中 H_j 之间的连接权值 XH_{ij} 的学习及调整方式如下:

$$XH_{ij} \leftarrow XH_{ij} + \Delta XH_{ij} \quad (13)$$

$$\Delta XH_{ij} = -\beta \cdot \frac{\partial E}{\partial XH_{ij}} = \beta \cdot A_i \cdot \left(\frac{\partial E}{\partial OH_j} \cdot \frac{\partial OH_j}{\partial IH_j} \right) \quad (14)$$

依据表达式(11)的推导过程,可得:

$$\begin{cases} \frac{\partial OH_j}{\partial IH_j} = f'(IH_j) \\ \frac{\partial E}{\partial OH_j} = \sum_{l=1}^m \frac{\partial E}{\partial OY_l} \cdot \frac{\partial OY_l}{\partial OH_j} \end{cases} \quad (15)$$

$$\begin{cases} \frac{\partial Y_l}{\partial H_j} = HY_{jl} \\ \frac{\partial E}{\partial Y_l} = \frac{\partial E}{\partial OY_l} \cdot \frac{\partial OY_l}{\partial Y_l} = G_l \end{cases} \quad (16)$$

将上述表达式带入式(14),可得 ΔXH_{ij} 的最终表达式如下:

$$\Delta XH_{ij} = \beta \cdot A_i \cdot f'(IH_j) \cdot \sum_{l=1}^m (HY_{jl} \cdot G_l) \quad (17)$$

由表达式(11)可知, $G_l = (OY_l - Z_l) \cdot OY_l \cdot (1 - OY_l)$.

离线学习模式的目的是根据不同类型应用对路由服务通常的特性需求,由对应的神经网络运算后获得通用功能的选择及组合结果,然后以迭代的方式对神经网络的各连接权值进行训练,以减小输出结果 OY 和训练样例 Z 之间的误差.因此,对应于 OY_l 和 Z_l ,随着离线模式神经网络的学习和调整, OY_l 的值会越来越接近 Z_l .若 Y_l 在样例中为被选择的通用功能,则 OY_l 的值会越来越接近1;否则, OY_l 的值会越来越接近0.然而,本文离线学习模式的训练目的是以通过减小 OY 与 Z 之间的误差,达到使神经网络能满足该类应用基本通信所必要的通用功能被选择而不必要的通用功能不被选择的目的,作为下一步在线学习模式实现细粒度专用功能选择来定制个性化路由服务的基础,而不是以最小化 OY 和 Z 之间的误差为目标.考虑到采用这种方式,在训练集存在偏差的条件下,其训练结果可能会出现过拟合现象,使训练获得的神经网络只适合于当前测试用例,失去进一步提高训练效果的可能.对此,本文引入正则化方法对神经网络的训练进行优化,使其能够有效抵消由存在个别偏差的训练集所可能导致某些权值变化过大而影响神经网络训练主方向的不利结果,从而使神经网络局部上有所偏离的变化因素(即,某些权值的变化)不会影响到离线学习模式的整体训练目标.对表达式(7)加入正则项,如下所示:

$$E' = \frac{1}{2} \sum_{l=1}^m (OY_l - Z_l)^2 + \frac{\lambda}{2u} \sum_{HY_{jl} \in HY} HY_{jl}^2 \quad (18)$$

其中, $\lambda (\lambda \in (0, 1))$ 为正则系数, u 为进行迭代训练的次数.因此,由 E' 替换 E 并代入表达式(12)和表达式(17),获得每次迭代训练各相关权值的调整优化值.由于训练目标并不需要使误差 E' 最小化,本文设定阈值 TL 和 TH , $0 < TL < TH < 1$,当 $OY_l < TL$ 时,对应的 Y_l 不被选择;当 $OY_l > TH$ 时,对应的 Y_l 被选择.取最近连续的 t 次迭代训练,若满足如下表达式(假设前一次为第 t 次训练):

$$\forall OY_i \in OY, \forall OY_k \in OY, OY_i \neq OY_k, 1 < h < t : \begin{cases} (TH < OY_i(t)) \wedge (OY_i(h-1) < OY_i(h)) = 1 \\ (TL < OY_k(t)) \wedge (OY_k(h-1) < OY_k(h)) = 1 \\ E'(h-1) < E'(h) \end{cases} \quad (19)$$

其中, $OY_i(h)$ 为第 h 次迭代训练 Y_i 的输出, $E'(h)$ 为第 h 次迭代训练均方差. 依据训练样例, 在最近连续 t 次迭代训练中, 所有需要被选择的通用功能对应的输出都大于等于前次迭代训练的输出值, 且其输出结果已大于等于 TH ; 所有无需被选择的功能对应的输出都小于等于前次迭代训练的输出值, 且其输出结果已小于等于 TL , 并且满足神经网络的迭代训练面向均方差减小方向.

3.2 在线学习模式

对各类应用相应的离线模式神经网络训练结束后, 面向某类应用通常的通信需求(即, 对路由服务通用的特性需求), 通过对应的离线模式神经网络就可以获得通用功能被选择的情况. 然而, 即使是使用同一类型的应用, 不同用户亦有多样化和个性化的通信需求, 例如对 QoS 特性的需求, 不同级别的 QoS 带给用户的服务体验有明显差异. 仅依靠离线学习模式获得的通用功能选择结果来合成路由服务往往是不够的, 因为用户通常不会仅满足于应用基本的通信需求. 对此, 本文进一步提出路由服务学习的在线模式, 从更细粒度上选择专用功能(即, 路由服务产品线专用功能层)并对选择结果进行持续优化. 在线学习模式以训练结束的离线模式神经网络为基础, 建立在线模式神经网络, 依据用户对通信特性个性化的需求及组合情况和用户对所获路由服务的体验反馈, 对相应的在线模式神经网络进行训练, 不断优化针对用户不同需求下的专用功能的选择及组合, 实现定制使用户体验最优的路由服务的目标.

在线模式神经网络建立在训练完成后的离线模式神经网络基础上, 进一步对输出层各神经元进行拓展, 在更细粒度上对合成路由服务的路由功能进行多样化和个性化的选择(由通用功能到专用功能). 在线模式神经网络结构如图 7 所示.




Fig.7 Online learning mode neural network

图 7 在线学习模式神经网络

定义 10. 在线模式神经网络定义为一个 7 元组 $(onnn_{id}, X, H, XH, SY, YC, HSY)$, 由相应的离线模式神经网络(定义 5)进行初始化设置. 其中, $onnn_{id}$ 是该在线模式神经网络的唯一标识; X, H 和 XH 含义见定义 5, XH 中各元素的值由训练结束后离线模式神经网络相对应连接的权值赋予; $SY = \{SY_1, \dots, SY_k, \dots, SY_p | k, p \in N_+\}$ 是该神经网络输出层神经元集合, 其各元素对应于路由服务产品线专用功能层中各专用功能, 并作为各专用功能的标识; $YC = \{YC_1, \dots, YC_l, \dots, YC_m | l, m \in N_+\}$ 是依据图 3 中各通用功能和各专用功能之间的关系对各专用功能分类的集合, YC_l 对应于 Y_l (定义 5), 如图 7 所示, $SY_1, SY_2 \in YC_1, SY_k, SY_{k+1}, SY_{k+2} \in YC_l, SY_p \in YC_m, YC_1, YC_l, YC_m \subset SY; HSY = \{HSY_{11}, \dots, HSY_{jk}, \dots, HSY_{qp} | j, k, q, p \in N_+\}$ 是该神经网络隐层各神经元与输出层各神经元之间的权值集合, HSY_{jk} 为 H_j 与 SY_k 的连接权值, 依据训练结束后离线模式神经网络的 HY 中各元素的值对 HSY 中各元素进行初始化赋值, 当 $SY_k \in YC_l$ 时, $HSY_{jk} = HSY_{jl}$, 即: 若 $SY_k, SY_{k+1}, SY_{k+2} \in YC_l$, 则 $HSY_{jk} = HSY_{jk+1} = HSY_{jk+2} = HSY_{jl}$.

定义 11. 在线模式神经网络的输出层神经元定义为一个 4 元组 $(SY_{id}, ISY_{id}, OSY_{id}, f)$. $SY_{id}(SY_{id} \in SY)$ 是该神经元的唯一标识; ISY_{id} 是 SY_{id} 的输入; OSY_{id} 是 SY_{id} 的输出, 其数值表示 SY_{id} 在一个路由服务中的被选择概率; f 是神经元激活函数.

在线模式神经网络的输入集合 $SA = \{SA_1, \dots, SA_i, \dots, SA_n\}$ 和离线模式神经网络的输入集合 A 之间的关系描述如下.

在离线学习模式中, 训练样例的输入为应用通常的通信需求(对各特性的基本需求情况), 即: 应用如果需求某特性 X_i , 则该特性对应的输入 $A_i = 1$; 否则, $A_i = 0$. 在线模式中, X_i 对应的输入为 SA_i , 若 $A_i = 1$, 则有 $SA_i \geq 1$ (表示用户对该特性的个性化需求一定不低于最基本的需求 A_i); 若 $A_i = 0$, 则有 $SA_i = A_i = 0$ (表示该应用本质上不需要该特性, 因此用户也不需要). 对于离线模式输入 A 和在线模式输入 SA , 若离线模式的输出有 $OY_l > TH$, 则对应的在线模式输出有 $OSY_k, OSY_{k+1}, OSY_{k+2} > TH$; 若离线模式的输出有 $OY_l < TL$, 则对应的在线模式输出有 $OSY_k, OSY_{k+1}, OSY_{k+2} < TL$, 即: 在线模式神经网络由训练完成后的离线模式神经网络初始化及相应赋值后, 依据用户个性化的特性需求及其组合, 可以保证必需的功能被选择且不需要的功能不被选择. 具体验证过程见验证 1.

验证 1

条件:

离线模式神经网络的输入为 A , 对路由服务的某特性 X_i , 若应用需求该特性, 记 $A_i = 1$; 否则, 记 $A_i = 0$. 假设离线模式神经网络的初始权值全部设置为 0. 结束训练后的离线模式神经网络输出通用功能被选择的结果(可以支持应用的基本通信), 若 Y_l 被选择, 则 $OY_l > TH$; 否则, $OY_l < TL$.

$$OY_l = f(IY_l) = f\left(\sum_{j=1}^q (HY_{jl} \cdot OH_j)\right) = f\left(\sum_{j=1}^q (HY_{jl} \cdot f(IH_j))\right) = f\left(\sum_{j=1}^q \left(HY_{jl} \cdot f\left(\sum_{i=1}^n (A_i \cdot XH_{ij})\right)\right)\right) \quad (20)$$

推导 1:

当 $OY_l > TH$ 时, 由表达式(12)和表达式(17)可知, $\Delta HY_{jl}, \Delta XH_{ij} > 0$, 则 $HY_{jl}, XH_{ij} > 0$. 依据 f 函数的性质(见表达式(4)), 表达式(20)在该情形下为增函数(其导数大于 0).

结论 1:

当应用需求某特性, 即 $\forall A_i: A_i = 1$ 时, 用户对该特性的个性化需求 $SA_i \geq A_i$ (表示用户对该特性的需求等级一定高于或等于应用本身对该特性的最基本需求等级), 则依据推导 1, 有 $SOY_k > TH$, 其中, SOY_k 为 SY_k 的输出值, $SY_k \in YC_l$.

推导 2:

当 $OY_l < TL$ 时, 由表达式(12)和表达式(17)可知, $\Delta HY_{jl}, \Delta XH_{ij} < 0$, 则 $HY_{jl}, XH_{ij} < 0$. 依据 f 函数性质(见表达式(4)), 表达式(20)在该情形下为减函数(其导数小于 0).

结论 2:

当应用不需求某特性, 即 $\forall A_i: A_i = 0$ 时, 用户对该特性的需求 $SA_i = A_i = 0$ (表示应用本身不需要该特性, 因此用户也无需它), 则依据推导 2, 有 $SOY_k < TL$, 其中, SOY_k 为 SY_k 的输出值, $SY_k \in YC_l$.

本文对在线模式神经网络的学习过程主要是训练其隐层各神经元到输出层各神经元之间的权值, 来优化

针对不同需求的专用功能选择及组合结果.在定制化的路由服务中,属于同一个分类的多个专用功能,最多只能有一个被选择,例如,一个路由服务只能执行一种特定的带宽分配算法.在线模式神经网络被初始化后,其起始训练状态能够保证输出层中属于同一分类的各专用功能有相同的输入,例如,对 $SY_k, SY_{k+1}, SY_{k+2} \in YC_l$, 有 $ISY_{jk} = ISY_{jk+1} = ISY_{jk+2}$.这样,在进一步的在线学习过程中,通过不断训练 H 和 SY 之间各连接权值,优化专用功能选择及组合结果.

用户通常难以(且无必要)确知所获路由服务各功能的构成细节(如每个具体的专用功能被选择的情况),同时,用户也难以对所获服务从专业角度进行评估(如延迟、抖动和出错率等数据),往往只能从服务外部可得的主观感受(如可视电话的画面清晰度、语音的辨识度及画面和语音的同步性等)对所获得的路由服务进行评价和反馈.然而,用户可以主动表述的某项主观感受(如对画面清晰度的感受)通常并不能单独地由某个功能独立地支持,而是需要多个功能以协作的方式共同作用,尤其当用户对服务有多种主观感受的需求时,更需要从整体上合理地选择多个可搭配的功能,使这些功能以组合协同的方式来满足多种需求.若依据用户反馈的某项具体的主观感受对单个功能被选择的概率进行独立优化的效果并不理想,不仅可能会使下次被选择的多个功能因搭配不合理导致该主观感受还不如之前,还可能会给其他主观感受带来消极影响.因此,本文考虑不针对用户单项的主观感受独立地对单个功能被选择的概率进行优化,而是对用户的各项主观感受进行综合考虑,并由此获取用户对路由服务的整体满意度评估情况,这样,从合成路由服务的多个专用功能的组合及搭配的角度,对多个专用功能被选择及组合的方式进行训练和优化.假设用户对所获路由服务的各项主观感受满意度集合为 $PSD = \{PSD_1, PSD_2, \dots, PSD_v\}$, 则用户对服务的整体满意度 ASD 可以表示为

$$ASD = \sum_{PSD_i \in PSD} \omega_i \cdot PSD_i \tag{21}$$

其中, ω_i 表示用户对各主观感受的重视程度(即权重),可由相对比较法获得各权重值,同时满足 $0 < \omega_i < 1$ 且 $\sum_{i=1}^v \omega_i = 1$.由验证 1 可知,刚初始化后的在线模式神经网络输出的功能选择结果至少能保证最基本的应用通信.定义用户对最基本服务的满意度为其最低满意度,记作 LSD .定义用户期望获得的服务满意度为 ESD .定义用户最高的服务满意度为 HSD (即,满意度为 1 的情况).显然, $LSD < ESD < HSD$, 且 $LSD < ASD < HSD$.本文通过奖励方式对 HSY 中各元素值进行调整和优化,定义奖励量 CE 为

$$CE = \begin{cases} \frac{(HSD-ASD)^2}{(ASD-ESD)^2}, & ESD < ASD < HSD \\ \varepsilon, & ASD = ESD \\ 0, & LSD < ASD < ESD \end{cases} \tag{22}$$

其中, $0 < \varepsilon < 1$.当 $ESD < ASD < HSD$ 时,用户对所获路由服务的实际满意度高于其期望值,越接近最高满意度,奖励量越大;越接近期望满意度,奖励量越小.当 $ASD = ESD$ 时,用户所获的路由服务刚好满足其期望值,只给一个很小的奖励量.当 $LSD < ASD < ESD$ 时,用户所获路由服务仅能满足其最基本的通信,达不到用户期望,则不给予奖励.

每次获得相同需求下用户对所获路由服务的反馈后,对 HSY 中各元素值进行调整.对于 HSY_{jk} ,其调整方式同理于表达式(8),定义如下:

$$HSY_{jk} \leftarrow HSY_{jk} + \Delta HSY_{jk} \tag{23}$$

在一个定制化的路由服务中,属于同一个分类的多个专用功能最多只有一个可被选择.定义在一个路由服务中,被选择的专用功能集合为 $SSY, SSY \subset SY$.当 $ESD < ASD < HSD$ 时, ΔHSY_{jk} 的计算过程如下:

$$\Delta HSY_{jk} = \begin{cases} \beta \cdot CE \cdot OH_j, & SY_k \in SSY \\ 0, & SY_k \notin SSY \end{cases} \tag{24}$$

表达式(24)表明:用户对所获路由服务的满意度大于或等于其期望值时,对此服务中所有被选择的专用功能对应的权值做奖励处理,其他没被选择的专用功能对应权值不变.

当 $LSD < ASD < ESD$ 时, ΔHSY_{jk} 计算过程如下:

$$\Delta HSY_{jk} = \begin{cases} 0, & SY_k \in SSY, SY_k \in YC_l \\ \beta \cdot \varepsilon \cdot OH_j, & SY_k \notin SSY, SY_k \in YC_l \end{cases} \quad (25)$$

表达式(25)表明:用户对所获路由服务的满意度小于其期望值时,不对此时被选择的专用功能对应的权值做奖励,而对那些与被选择专用功能属于同一分类但没被选择的专用功能对应的权值做小的增量处理.以这种方式,可以持续地优化该个性化需求下专用功能选择及组合,从而实现路由服务的定制化目标,改善用户的服务体验.

4 仿真实现和性能评价

4.1 仿真实验配置

为实现本文提出的基于 SDNFV 的路由服务合成机制(routing service composition mechanism,简称 RSCM),本文在 Linux 平台(Intel core i5 3.3GHz,16GB DDR3 RAM)上搭建仿真系统.仿真实验中,选用 Floodlight^[35]作为模型的控制,负责计算和优化路由服务定制方案,并下发路由服务匹配规则.转发设备选用 OpenFlowClick^[36]进行仿真实现.OpenFlowClick 是一种基于 Click Modular Router^[37]的可扩展可编程的软件路由器,其内部由一系列负责处理数据分组的功能组成,各功能可依据相应的服务合成方案被独立地调用和组装,构成完整的路由服务,实现对不同类型数据分组差异化的处理,而且其内部的 OpenFlowClick 模块支持转发设备接收和部署控制器下发的服务匹配规则,以及支持多个转发设备被控制器统一地集中管理和控制.

仿真实验中,依据弹性/非弹性和交互/非交互特性选择 4 种典型的网络应用,见表 1.离线模式神经网络的训练样例选用集成服务机制(integrated service mechanism,简称 IntServM)^[38],来训练对每种类型应用通用的路由服务配置.本文主要面向应用对 QoS 特性的需求进行路由服务定制,在应用的通信路径上,可供 ISP 选择构成路由服务的功能包括准入控制、资源预留、带宽分配、分组调度、分组转发、差错控制、流量整形和缓存处理.用户对所获服务的 QoS 满意度评估由带宽、延迟、抖动和丢失率参数依据文献[39]中的方法计算,其中,各参数对 4 种类型应用的重要程度(权值)依据 ITU-T Y. 1541^[40]和 ITU-T E.802^[41]由文献[42]中方法计算获得,具体设置见表 2.仿真时,本文选用两种实际的网络拓扑,分别为中国教育科研计算机网 CERNET^[43]和美国下一代互联网 INTERNET2^[44],拓扑结构如图 8 所示.为评价本文提出的 RSCM 机制的性能,本文选用典型的 IntServM 和相关工作中另一种基于 SDN 和 NFV 的服务合成模型——服务链即服务机制(SCaaS)^[28]进行对比.这 3 种机制在两种网络拓扑下,在不同网络负载(轻载、中载和重载)情形和不同候选功能数量情形下,分别对路由服务的性能和用户的服务体验进行对比评价.在仿真实验中,轻载是指网络中所有链路带宽的平均利用率低于 30%的情况,重载是指网络中所有链路带宽的平均利用率高于 70%的情况,介于两者之间为中载.

Table 1 Typical network applications

表 1 典型网络应用

	非交互	交互
弹性	文件下载	网页浏览
非弹性	视频点播	可视电话

Table 2 Weight setting

表 2 权值设置

	带宽	延迟	抖动	丢失率
文件下载	0.52	0.08	0.08	0.34
网页浏览	0.26	0.35	0.04	0.35
视频点播	0.43	0.06	0.22	0.29
可视电话	0.16	0.35	0.35	0.14




Fig.8 Network topologies

图 8 网络拓扑

4.2 性能评价

4.2.1 接入成功率

接入成功率是指被成功接入的应用个数对请求接入的应用总数的比例.在 3 种网络负载情形下,3 种机制对应用的接入成功率比较结果如图 9 和图 10 所示.




Fig.9 Access success ratio over CERNET

图 9 CERNET 下接入成功率




Fig.10 Access success ratio over INTERNET2

图 10 INTERNET2 下接入成功率

RSCM,SCaaS 和 IntServM 这 3 种机制都能够提供端到端的保证型服务,即:只有在能为应用通信分配资源并提供满足要求的路由服务时,才允许接入该应用.但是随着网络负载增大,三者的接入成功率都有所下降.

RSCM 和 SCaaSM 两种机制在两种拓扑下接入成功率的下降程度都明显低于 IntServM 机制,尤其是当网络负载达到重载之后,这是因为 RSCM 和 SCaaSM 都基于 SDN 的全局化网络视图和 NFV 灵活的功能及资源调用,当网络负载发生变化时,都能够从全局视图上更好地规划路由服务的路径和功能部署(如选择能够避开资源不足链路的路由算法和拥塞控制机制),从而降低接入失败率.此外,由于 RSCM 还能够通过接入失败的情形进行学习改进,提高重载下资源及功能分配的效用,因而进一步提高了接入成功率.

4.2.2 用户满意度

用户满意度是指路由服务能满足用户个性化通信需求的程度,即,用户对所获路由服务的满意程度.本文主要针对路由服务的 QoS 特性来评估用户满意度,在不同网络负载下,用户对 3 种机制提供的路由服务的满意度比较结果如图 11 和图 12 所示.




Fig.11 User satisfaction degree over CERNET

图 11 CERNET 下用户满意度

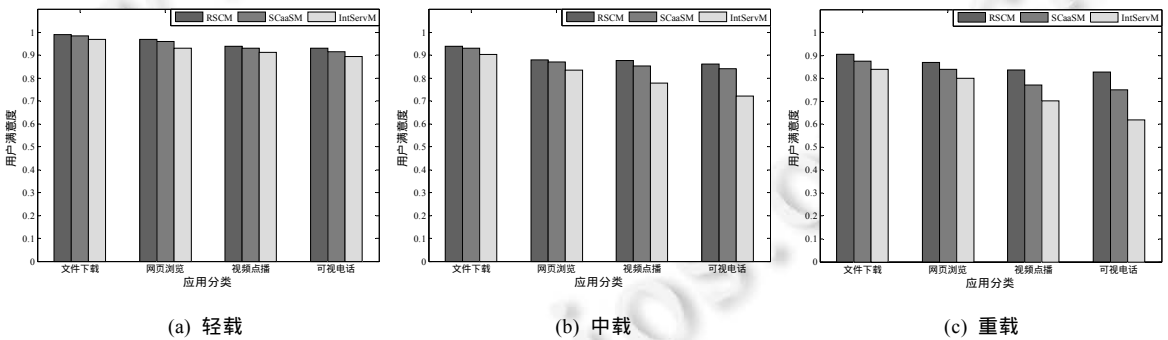


Fig.12 User satisfaction degree over INTERNET2

图 12 INTERNET2 下用户满意度

对于被成功接入的应用,RSCM 所提供路由服务的用户满意度较高且相对稳定,SCaaSM 所提供路由服务的用户满意度紧随其后,相比之下,用户对 IntServM 所提供路由服务的平均满意度随着网络负载的加重而明显下降.这是因为网络负载较低时,IntServM 可以通过预留并分配足够多的资源来提高用户满意度,但是当负载加重时,这种方式难以为继.RSCM 和 SCaaSM 因其全局视图和动态功能及资源调用,具备依据用户需求实施更合适的路由服务合成方案的能力,从而提高了用户的服务满意度.此外,RSCM 还具备自适应学习能力,能够在不同情形下,持续地训练及优化服务的定制方案,尽可能最大限度地满足用户多样化和个性化的需求,从而进一步提高了用户满意度.

4.2.3 功能利用率

功能利用率是指在多种多样候选的专用路由功能中,被选择组装路由服务的路由功能占有所有候选路由功

能的比例.随着候选功能数量的增加,3种机制的比较结果如图 13 和图 14 所示.




Fig.13 Function utilization ratio over CERNET
图 13 CERNET 下功能利用率




Fig.14 Function utilization ratio over INTERNET2
图 14 INTERNET2 下功能利用率

当候选的路由功能的数量增加时,RSCM 的功能利用率明显高于 SCaaS 和 IntServM,尤其当候选功能数量增加较多时.这是因为 IntServM 基于预先设置的标准选择功能来提供路由服务,不具备随着候选功能增加尝试选择新功能替换初始预设功能的能力,虽然候选功能增加,但其对功能的选择目标不变,因而导致功能利用率低.SCaaS 由于相对灵活的功能调用机制,能够随着候选功能的增加便捷地进行功能选择,提高了新添加的功能被选择的概率.相比之下,RSCM 为了改善用户体验,自适应地尝试多样化可行的候选功能选择及组合方案,而且通过定制化,使其具备面向不同需求及网络状态情形而合成差异化路由服务的能力,从而使其功能利用率最高.

4.2.4 服务优化率

服务优化率是指当可被选择的候选路由功能增多时,面向相同的通信需求,被优化的路由服务占有所有路由服务的比例.3种模型比较结果如图 15 和图 16 所示.




Fig.15 Service optimization ratio over CERNET
图 15 CERNET 下服务优化率




Fig.16 Service optimization ratio over INTERNET2
图 16 INTERNET2 下服务优化率

RSCM 对路由服务的优化率明显优于 SCaaS 和 IntServM,尤其是当可被选择的功能数量增加较多时.这是因为候选功能增多时,RSCM 可选的路由服务合成方案随之增多,而且 RSCM 定制路由服务时有明确的优化

目标,即优化用户的服务体验,因而更容易选择合适的功能及其组合而得到更优质的路由服务,特别是当候选功能增加时,其可以更主动地依据用户反馈情况持续优化服务的构成.相比之下,SCaaSM 和 IntServM 都不能依据用户的体验反馈情况有效地调整服务组成,但是,SCaaSM 对多样化功能调用的灵活性使其功能选择的可能组合更加丰富,因此随着候选功能增加,其提高服务优化率的能力强于 IntServM.

4.2.5 时间开销

时间开销是指从 ISP 接收到用户对应用的通信请求到 ISP 成功为用户提供路由服务所用的时间.本文对两种模型的时间开销进行对比(以最大的平均时间开销设为 1,其他为对其相对值),比较结果如图 17 和图 18 所示.




Fig.17 Service setup time for new requests

图 17 对新型请求的服务建立时间




Fig.18 Service setup time according to the established rules

图 18 依据已建立规则的服务建立时间

当 RSCM 和 SCaaSM 首次为某类请求提供路由服务时,需要系统的控制平面分析及计算如何为该请求提供服务,生成相应的服务合成规则,而且合成服务所需的路由功能需要嵌入到相关的交换机,因此路由服务的建立时间开销高于 IntServM,如图 17 所示.然而,RSCM 和 SCaaSM 再收到同样类型的请求(即,收到请求的交换机可以成功匹配该请求对应的服务匹配规则)时,这两种机制服务建立时间开销变得明显低于 IntServM,如图 18

所示.这是因为此时交换机只需使用其已有的服务合成方案,调用并组合相应路由功能来提供路由服务即可.其中,RSCM的时间开销比SCaaS稍高些,这是因为RSCM有时还需要依据反馈进行规则更新,会带来少量的时间开销.

5 总结

当前网络环境中新型应用不断涌现,而且用户对不同类型应用的通信需求越来越复杂化、多样化和个性化.本文基于NFV把功能服务从承载设备中解耦,基于SDN把控制平面从数据平面中解耦,提出了一种基于SDNFV的路由服务合成机制.该机制能够针对用户不同的通信需求定制具备不同特性的路由服务,从而优化用户的服务体验.本文运用软件产品线的思想构建路由服务产品线,实现对多样化路由功能特性的划分,作为进一步优化路由服务的基础.为实现路由功能选择及服务合成的可演化能力,进而实现路由服务的定制化.本文基于机器学习思想,提出离线和在线两阶段路由服务神经网络学习模型,根据大量用户持续进行网络活动产生的与不同类型应用通信的相关信息(差异化的需求、获得的路由服务和体验反馈等),不断调整及优化路由功能选择及服务合成,持续改善用户服务体验.

应该指出的是:与专用的网络物理设备相比,本方法基于SDN和NFV范型,以多种实例化的路由功能运行于标准的通用网络设备中,性能与专用设备相比存在一定差距,但是面向大量用户对不同类型应用的独特多变且差异多样的通信需求,以及越来越关注于整体服务体验的应用情境,需要对多种多样的路由功能进行灵活及统一地选择部署及组合搭配,从而在不同的通信路径上动态且快速地提供定制化的路由服务,本方法显现出很好的适用性.在实际应用中,控制平面对大规模网络会面临可扩展性问题,需要进一步研究对控制平面进行多控制器联动和分域管控等机制.同时,本文通过多样化路由功能的自适应选择及合成,实现路由服务定制化来改善用户服务体验.但服务的消费和生产并不完全是买方市场,因此在未来的研究工作中,可以进一步引入ISP的经济利益考量,以实现供需双方共赢的目标来定制路由服务.此外,通过原型实现,在实际网络(如CERNET)上进行验证以提高本文工作的实用性,也是今后研究与开发工作的重点.

References:

- [1] Wang XW, Li J, Tan ZH, Ma LB, Li FL, Huang M. The state of the art and future tendency of "Internet+" oriented network technology. *Journal of Computer Research and Development*, 2016,53(4):729-741 (in Chinese with English abstract). [doi: 10.7544/j.issn1000-1239.2016.20151146]
- [2] Bu C, Wang XW, Li FL, Huang M. A big data driven adaptive routing service customization scheme. *Chinese Journal of Computers*, 2016,39(1):65-79 (in Chinese with English abstract). [doi: 10.11897/SP.J.1016.2016.00065]
- [3] Carpenter B. Middleboxes: Taxonomy and issues. RCF 3234, 2002.
- [4] Wu J, Zhang JF, Hong Y. Cloud radio access network (C-RAN): A primer. *IEEE Network*, 2015,29(1):35-41. [doi: 10.1109/MNET.2015.7018201]
- [5] Shanbhag S, Wolf T. Automated composition of data-path functionality in the future internet. *IEEE Network*, 2011,25(6):8-14. [doi: 10.1109/MNET.2011.6085637]
- [6] Chen L, Duan XD, Chen W, Cheng WQ. Thoughts and practices about SDN and NFV. *Telecommunications Science*, 2014,8:23-27 (in Chinese with English abstract). [doi: 10.3969/j.issn.1000-0801.2014.08.004]
- [7] Mijumbi R, Serrat J, Gorricho JL. Network function virtualization: State-of-the-Art and research challenges. *IEEE Communications Surveys & Tutorials*, 2015,18(1):236-262. [doi: 10.1109/COMST.2015.2477041]
- [8] Diego K, Fernando MVR, Paulo EV, Christian Esteve R, Siamak A, Steve U. Software-Defined networking: A comprehensive survey. *Proc. of the IEEE*, 2015,103(1):14-76. [doi: 10.1109/JPROC.2014.2371999]
- [9] Lorena IBL, Ángel LVC, Luis JGV. Trends on virtualisation with software defined networking and network function virtualization. *IET Networks*, 2015,4(5):255-263. [doi: 10.1049/iet-net.2014.0117]
- [10] Ding WF, Qi W, Wang JP. OpenSCaaS: An open service chain as a service platform toward the integration of SDN and NFV. *IEEE Network*, 2015,29(3):30-35. [doi: 10.1109/MNET.2015.7113222]

- [11] Wang XW, Cheng H, Huang M. QoS multicast routing protocol oriented to cognitive network using competitive coevolutionary algorithm. *Expert Systems with Applications*, 2014,41(10):4513–4528. [doi: 10.1016/j.eswa.2014.01.020]
- [12] Wang XW, Qu DP, Huang M, Li KQ, Das SK, Zhang JH, Yu RY. Multiple many-to-many multicast routing scheme in green multi-granularity transport networks. *Computer Networks*, 2015,93(1):225–242. [doi: 10.1016/j.comnet.2015.10.015]
- [13] Nelly B, Svein H, Eduardo SDA. A view of the dynamic software product line landscape. *Computer*, 2012,45:10. [doi: 10.1109/MC.2012.292]
- [14] Yin H, Jiang Y, Lin C, Luo Y, Liu YJ. Big data: Transforming the design philosophy of future Internet. *IEEE Network*, 2014,28(4): 14–19. [doi: 10.1109/MNET.2014.6863126]
- [15] Sekar V, Egi N, Ratnasamy S, Reiter M, Shi GY. Design and implementation of a consolidated middlebox architecture. In: *Proc. of the USENIX Conf. on Networked Systems Design and Implementation (NSDI 2012)*. 2012. 24–37.
- [16] Wang XW, Cheng H, Huang M. Multi-Robot navigation based QoS routing in self-organizing networks. *Engineering Applications of Artificial Intelligence*, 2013,26(1):262–272. [doi: 10.1016/j.engappai.2012.01.008]
- [17] Peculea A, Iancu B, Dadarlat V, Ignat I. A novel QoS framework based on admission control and self-adaptive bandwidth reconfiguration. *Int'l Journal of Computers Communications & Control*, 2010,5(5):862–870. [doi: 10.15837/ijccc.2010.5.2247]
- [18] Baochun L, Klara N. A control-based middleware framework for quality of service adaptations. *IEEE Journal of Selected Areas in Communication*, 1999,17(9):1832–1650. [doi: 10.1109/49.790486]
- [19] Abdelmounaam R, Mohamed E. μ RACER: A reliable adaptive service-driven efficient routing protocol suite for sensor-actuator networks. *IEEE Trans. on Parallel and Distributed Systems*, 2009,20(5):607–622. [doi: 10.1109/TPDS.2008.94]
- [20] Rohallah B, Ramdane M, Zaïdi S. Towards scalability of reputation and QoS based web services discovery using agents and ontologies. In: *Proc. of the Int'l Conf. on Information Integration and Web-Based Applications and Services (iiWAS 2011)*. 2011. 262–269. [doi: 10.1145/2095536.2095580]
- [21] Sasitharan B, Dmitri B, Ray C, Julien M, William D, Tadashi N, Tatsuya S. Adaptive dynamic routing supporting service management for future internet. In: *Proc. of the IEEE Global Telecommunications Conf. (GLOBECOM 2009)*. 2009. 1–7. [doi: 10.1109/GLOCOM.2009.5425353]
- [22] Abdulbaset HM, Michael EW. Localized QoS routing with admission control for congestion avoidance. In: *Proc. of the Int'l Conf. on Complex, Intelligent and Software Intensive Systems (CISIS 2010)*. 2010. 174–179. [doi: 10.1109/CISIS.2010.153]
- [23] Wang P, Lan JL, Zhang XH. Dynamic function composition for network service chain: Model and optimization. *Computer Networks*, 2015,92:408–418. [doi: 10.1016/j.comnet.2015.07.020]
- [24] Paganelli F, Ulema M, Martini B. Context-Aware service composition and delivery in NGSONs over SDN. *IEEE Communications Magazine*, 2014,52(8):97–105. [doi: 10.1109/MCOM.2014.6871676]
- [25] Cheng GZ, Chen HC, Hu HC. Enabling network function combination via service chain in-stantiation. *Computer Networks*, 2015, 92:396–407. [doi: 10.1016/j.comnet.2015.09.015]
- [26] Ma H, Bastani F, Yen IL. QoS-Driven ser-vice composition with reconfigurable services. *IEEE Trans. on Services Computing*, 2011,6(1):20–34. [doi: 10.1109/TSC.2011.21]
- [27] Ran YY, Yang EZ, Shi YK. A NaaS-enabled framework for service composition in software defined networking environment. In: *Proc. of the IEEE Globecom Workshops (GC Wkshps 2014)*. 2014. 188–193. [doi: 10.1109/GLOCOMW.2014.7063429]
- [28] Ding WF, Qi W, Wang JP, Chen B. OpenSCaaS: An open service chain as a service platform toward the integration of SDN and NFV. *IEEE Network*, 2015,29(3):30–35. [doi: 10.1109/MNET.2015.7113222]
- [29] Gamez N, Haddad JE, Fuentes L. SPL-TQSSS: A software product line approach for stateful service selection. In: *Proc. of the IEEE Int'l Conf. on Web Services (ICWS 2015)*. 2015. 73–80. [doi: 10.1109/ICWS.2015.20]
- [30] Cai HH, Cui LZ, Shi YL. Multi-Tenant service composition based on granularity computing. In: *Proc. of the 2014 IEEE Int'l Conf. on Services Computing (SCC 2014)*. 2014. 669–676. [doi: 10.1109/SCC.2014.93]
- [31] Lee J, Kotonya G, Robinson D. Engineering service-based dynamic software product lines. *Computer*, 2012,45(10):49–55. [doi: 10.1109/MC.2012.284]
- [32] Hinchey M, Park S, Schmid K. Building dynamic software product lines. *Computer*, 2012,45(10):22–26. [doi: 10.1109/MC.2012.332]

- [33] Cybenko G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, 1989,2(4): 303–314. [doi: 10.1007/BF02551274]
- [34] Han SG, Wee KN, Wan L, Vincent CSL. Privacy-Preserving gradient-descent methods. *IEEE Trans. on Knowledge and Data Engineering*, 2010,22(6):884–899. [doi: 10.1109/TKDE.2009.153]
- [35] Project floodlight. 2016. <http://www.projectfloodlight.org>
- [36] Mundada Y, Sherwood R, Feamster N. An OpenFlow switch element for click. In: *Proc. of the Symp. on Click Modular Router*. 2009.
- [37] Kohler E. The click modular router. *ACM Trans. on Computer Systems*, 2000,18(3):263–297. [doi: 10.1145/319151.319166]
- [38] Braden R, Clark D, Shenker S. Integrated Services in the Internet Architecture: an Overview. IETF RFC 1633, 1994. 1–28. <https://tools.ietf.org/html/rfc1633>
- [39] Wang XW, Cheng H, Huang M. Multi-Robot navigation based QoS routing in self-organizing networks. *Engineering Applications of Artificial Intelligence*, 2013,26(1):262–272. [doi: 10.1016/j.engappai.2012.01.008]
- [40] ITU-T Y. 1541. 2011. <http://www.itu.int/rec/T-REC-Y.1541/en>
- [41] ITU-T E. 800. 2008. <http://www.itu.int/rec/T-REC-E.800-200809-1>
- [42] Kiran A, Brahmjit S, Rajesh K. Network selection based on weight estimation of QoS parameters in heterogeneous wireless multimedia networks. *Wireless Personal Communications*, 2014,77(4):3027–3040. [doi: 10.1007/s11277-014-1692-4]
- [43] CERNET. 2016. <http://www.topology-zoo.org>
- [44] INTERNET2. 2014. <http://www.internet2.edu/media/medialibrary/2014/03/17/AboutInternet2.pdf>

附中中文参考文献:

- [1] 王兴伟,李婕,谭振华,马连博,李福亮,黄敏.面向“互联网+”的网络技术发展现状与未来趋势. *计算机研究与发展*,2016,53(4): 729–741. [doi: 10.7544/issn1000-1239.2016.20151146]
- [2] 卜超,王兴伟,李福亮,黄敏.大数据驱动的自适应路由服务定制机制. *计算机学报*,2016,39(1):65–79. [doi: 10.11897/SP.J.1016.2016.00065]
- [6] 李晨,段晓东,陈炜,程伟强.SDN 和 NFV 的思考与实践. *电信科学*,2014,8:23–27. [doi: 10.3969/j.issn.1000-0801.2014.08.004]



卜超(1987 -),男,山东枣庄人,博士生,主要研究领域为未来互联网,自适应路由服务定制机制.



黄敏(1968 -),女,博士,教授,博士生导师,主要研究领域为智能算法设计与优化,调度理论与方法.



王兴伟(1968 -),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为未来互联网,云计算,网络空间安全.