

面向 5G 通信网络的 NFV 内存资源管理方法



苏 畅 张定权 谢显中 谭 娅

重庆邮电大学重庆市计算机网络与通信技术重点实验室 重庆 400065

(changsu@cqupt.edu.cn)

摘 要 随着 5G 研究的深入和商用的推进,出现了各式各样的挑战,其中,5G 通信系统的资源管理对于 5G 网络的研究来说是一个关键性的挑战。网络功能虚拟化技术为 5G 的实现提供了关键支撑,同时也为 5G 的资源管理问题引入了新的研究方向,但是网络功能虚拟化场景中的资源管理是一个比较复杂问题。特别地,虚拟网络功能的不同放置位置会为其性能带来不同的影响。文中首先对网络功能虚拟化的资源分配方法及放置对性能的影响进行了分析和研究,在此基础上,主要根据知识定义网络所提出的范例,探讨了将机器学习技术应用于虚拟网络功能内存资源管理的研究,构建神经网络学习模型,预测内存资源消耗。其次,重点对输入流量的特征进行提取,流量主要由一组特征表示,这些特征代表了从数据链路层到传输层的小批次信息,其中的内存消耗是从虚拟机管理程序的性能监测工具上得出的批量的平均内存消耗。最后,利用神经网络模型预测内存资源消耗,从而达到对内存资源进行管理的目的。

关键词: 5G 通信网络; 资源管理; 网络功能虚拟化; 机器学习; 内存消耗

中图法分类号 TP183

NFV Memory Resource Management in 5G Communication Network

SU Chang, ZHANG Ding-quan, XIE Xian-zhong and TAN Ya

Chongqing Key Laboratory of Computer Network and Communication Technology, Chongqing University of Posts and Telecommunications, Chongqing 400000, China

Abstract With the deepening of 5G research and the advancement of commercialization, it also brings various challenges. Among them, the resource management of 5G communication system is a key challenge for the research of 5G network. Network Function Virtualization (NFV) technology provides key support for 5G implementation, and it also introduces new research directions for 5G resource management issues. However, resource management in network function virtualization scenarios is a more complex issue. In particular, different placements of virtual network functions have different effects on their performance. Firstly, this paper analyzed and studied the impact of NFV resource allocation methods and NFV placement on performance. On this basis, this paper mainly discussed machine learning based on the example proposed by Knowledge Definition Network (KDN). The technology is applied to the study of virtual network function memory resource management, constructing a neural network learning model, and predicting memory resource consumption. Secondly, the focus of this paper is on the extraction of the characteristics of the input traffic. The traffic is mainly represented by a set of features, which represent small batches of information from the data link layer to the transport layer, where the memory consumption is from the hypervisor. The average memory consumption of the batch is obtained on the performance monitoring tool. Finally, this paper aimed to manage memory resources by using neural networks to predict memory resource consumption.

Keywords 5G Communication network, Resource management, Network function virtualization, Machine learning, Memory consumption

1 介绍

1.1 引言

下一代移动通信网络(Next Generation Mobile Network, NGMN)联盟指出:“5G 是一个端到端的生态系统,可以实现

一个完全移动和互联的社会。它通过现有和新兴的用例,为客户和合作伙伴提供价值创造和一致的经验,并通过可持续的商业模式实现”^[1]。从 5G 的功能来看,5G 与之前的通信网络最大的不同在于,它能够灵活地为不同的设备提供方便。为了实现对这些设备更好的支持,在延迟、安全性、数据速率、

到稿日期: 2019-08-02 返修日期: 2019-11-02 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目: 重庆市教委科学技术研究重点项目(KJZD-K201800603)

This work was supported by the Scientific and Technological Research Program of Chongqing Municipal Education Commission(KJZD-K201800603).

通信作者: 谢显中(xiexzh@cqupt.edu.cn)

可靠性等方面的研究很重要,而本文主要关注的是内存资源管理。

未来网络发展的趋势是智能化,这必定会与机器学习相结合,从而更加灵活地控制和操作网络^[2]。5G 网络不仅需要支持更多的数据,同时还需要提供更好的体验质量(Quality of Experience, QoE)^[3],这便要求 5G 通信系统能够进行良好的内存资源管理。从这方面来看,软件定义网络(Software-Defined Networking, SDN)和网络功能虚拟化(Network Functional Virtualization, NFV)为 5G 的实现提供了方便。NFV 是 5G 蜂窝系统^[4]中的一个重大突破,它将物理硬件和底层网络分离开来,让网络功能运行在通用云服务器上,从而在可扩展性和灵活性方面具有极大的优势^[5]。在这种情况下,对 5G 通信系统起着重大作用的 NFV 技术引入了新的研究方向——NFV 场景中的资源管理问题。

NFV 场景中的资源管理是一个复杂的问题,尤其是虚拟功能在物理网络中的实际位置会影响虚拟化网络的性能。针对这一问题,Mestres 等^[6]在知识定义网络(Knowledge-Defined Networking, KDN)的背景下,将知识平面(Knowledge Plane, KP)建模运用于 NFV 场景,从而解决了 NFV 中的复杂性问题。

1.2 相关工作

在网络资源管理方面,研究者们研究了 NFV 的资源分配、管理以及布局问题。Nguyen 等^[7]重点研究了 NFV 的资源管理和布局,并根据不同的场景提出并分析了 3 种启发式方法,但是在实际情况下并没有考虑网络拥塞的问题。在 NFV 这种新范例尚未推出之前,Moens 等^[8]已经提出了 NFV 环境中资源分配的正式模型——VNF-P 模型,模拟并评估了虚拟网络功能放置对服务的影响。后来,Cohen 等^[9]针对该问题提出了一种近似算法,对虚拟功能在物理网络中的实际位置进行了深入的研究,引入了新的优化问题,同时讨论了不同版本下对应的近似因子,并对算法进行了性能评估。针对虚拟机(Virtual Machine, VM)放置的问题,Meng 等^[10]提出了一种使用流量感知虚拟机布局来提高数据中心网络的可扩展方法,考虑了 VM 资源、可用性和通信资源 3 种限制。Mao 等^[11]提出了一种将资源管理与深度强化学习相结合的机制,即 DeepRM 方案;在合成数据集上使用 DeepRM 方案进行模拟实验并加以评估。但是这种机制并没有应用于实际复杂的环境中,其是否能够成为一个启发式的替代方案还有待研究。Ghaznavi 等^[12]设计了一种算法来优化 VNF 实例的放置,以响应按需工作负载,所提出的模型考虑了主机资源消耗、弹性开销和带宽之间的权衡。Kulkarni 等^[13]提出了一种网络功能资源调度框架来优化系统资源管理,以此合理调度 CPU 资源以及提升网络功能的性能。Subramanya 等^[14]根据客户流量需求进行预测,通过仿真实验,利用一种在线学习技术来预测 VNF 的部署。从以往的研究来看,研究人员对 NFV 资源分配技术的探索比较全面,但 NFV 所体现的特征总是较为复杂并且是非线性的。

基于以上研究现状,本文将 NFV 与机器学习相结合,针对 NFV 场景中的资源管理问题进行研究。通过神经网络

模型预测资源消耗,使得网络资源管理变得更加智能化。

本文的主要工作有以下几点:

(1)通过在同一虚拟机管理程序所管理的两台虚拟机之间建立虚拟网络功能仿真实验,对内存消耗资源管理方法进行评估。这是为了预测内存资源消耗的情况,从而对虚拟网络功能内存资源的管理进行更好的控制。

(2)提取流量特征,以此作为神经网络的输入。由于流量是由一组特征来表示的,因此需要对流量特征进行提取,从而对内存资源消耗的情况进行预测。

(3)通过神经网络对这种关系模式进行学习,用一组流量特征表示流量,挖掘出流量特征与内存性能之间的联系,从而能够准确地对内存消耗进行预测。

2 数据特征介绍和分析

2.1 特征介绍

在网络流量模型的描述中,流量特性是一组描述包序列属性的计数器,主要分为两个种类:一种是根据网络变化行为而实时改变的特征,另外一种是可以直接从流量中进行提取的特征。例如,我们可以直接从捕获的流量中获取一些信息,如流量数据包的长度,传输的字节数、数据包的协议、源和目标端口、源和目标地址等。这些基本特征比较详细地描述了网络流量的运行状态,通过对这些流量特征的分析,利用神经网络学习流量特征与内存消耗之间的关系,可以达到对其进行预测的目的。

2.2 特征分析

本文将对内存的性能进行分析,因此所选取的流量特征非常关键。本文需要找到一组简单且计算成本较低,同时又能够对预测内存消耗起到作用的流量特性。过于具体的流量特性能够准确地对内存进行预测,但是可能导致更大的计算成本。因此,本文的目标是在保证处理成本可以接受的情况下找到一些特性来满足本文的研究需求。在进行批量处理时,除了数据包数和传输的字节数之外,本文还为每个批次的流量建立了其他的特征计数器,每次处理流量时,这些计数器都会更新,并将其中的数据保存在文件中。流量的特征集合考虑了一个或多个数据包里面的头字段,即源 IP 和目的 IP 地址、源端口号和目的端口号以及协议号等。

在统计特征信息的方法上,可以根据 IP 的版本号统计 IPv4 和 IPv6 数据包的数量,还可以根据协议编号统计出所处理的批量流量数据包中的 ICMP 包的数量、TCP 包的数量以及 UDP 包的数量。

流量特性的数量可能对预测精度有比较重要的影响力。由于本文的方法始于一个猜想,所以刚开始并不知道哪些流量特性对于预测内存消耗来说是比较好的预测因子。因此,本文将提取的所有流量特征包含在训练神经网络的数据集中。对于从 pcap 数据包中获取的有用信息,本文将批量处理的每一个批次中的信息以及表 1 所列的信息作为流量特征集。

表 1 用于描述流量的特征集

Table 1 Feature set for describing traffic

Batch number	TimeStamp (in μ s) of the last packet
Transmitted bytes	Number of packets
Number of TCP packets	Number of UDP packets
Average length of the packets	Number of IPv4 packets
Number of IPv6 packets	Num. of the ICMP packets over IPv4
Num. of the ICMP packets over IPv6	Num. of SYN-TCP packets
Average inter-arrival time between consecutive packets	Num. of different source ports in TCP packets
Num. of different destination ports in TCP packets	Num. of different source ports in UDP packets
Num. of different source ports in TCP packets	Num. of different IP source addresses
Num. of different IP destination addresses	Standard deviation of the length of the packets
Num. of different IP source addresses mask 1,2	Num. of different IP destination addresses mask 1,2,3

在批量处理中,传输字节数量、每一批的数据包总数、IPv4 数据包总数、IPv6 数据包总数、TCP 数据包总数、UDP 数据包总数等特征描述了在小批次中从数据链路层到传输层的特征属性。

为了得出流量与内存消耗之间的关系,本文利用神经网络模型进行流量特征的提取。本文的原始流量数据是以 pcap 文件存储的,pcap 文件是一种在对流量进行分析时常用的按照特定格式存储数据包的文件。

3 方法

3.1 预测方法

在 5G 通信系统中,资源分配问题面临着各种各样的挑战。但是 KDN^[6]这种新范例的提出为网络领域的研究注入了新的活力,利用 SDN、网络分析和人工智能也给解决网络问题带来了新的思考方式。另外,近年来,基于意图的网络(Intent-Based Networking,IBN)^[15]在世界范围内被广泛热议,它能够进行网络规划、网络优化、网络配置、预测以及预警等,而最关键的一个特征便是进行预测。IBN 可以提供洞察力,在预测事情发展的情况下,实现网络自愈;它能够通过机器学习相关技术和大数据达到其预测的目的。机器学习模型可以进行模式识别并学习如何应对网络的变化,因此本文利用机器学习进行预测分析。

KDN 通过引入 KP 的遥测技术^[16]和网络分析扩展了 SDN^[17],同时也为解决网络中的复杂性问题提供了方便。针对目前 5G 通信系统资源管理的问题,本文通过实验验证了一种基于人工神经网络(Artificial Neural Network,ANN)的 NFV 内存资源管理方法。ANN 通过建立资源消耗的流量行为模型,根据流量参数预测资源消耗的情况。本文主要采用 KP 建模的方式对 VNF 的资源问题进行研究,利用预测的内存消耗情况进行内存资源的分配。

在这个过程中,首先假设在已经部署好网络监控应用程序的情况下,通过网络监控应用程序收集实时的流量信息,并在对流量信息进行处理后获取有用的特征信息。然后,利用这些流量信息预测内存资源的消耗;为了更好地对内存资源进行管理,我们给定一个内存消耗的阈值,VNF 将围绕该阈值进行调整。例如,在多个 VNF 工作的情况下,通过预测 VNF 的内存资源消耗的情况,可以使用某种机制,在达到其阈值之前,处理 VNF 的工作任务;或者通过神经网络模型预

测所得出的结果,发现在当前 VNF 所需的内存资源不满足条件的情况,对目前无用的 VNF 作出减载。

如图 1 所示,在能够准确预测的情况下,我们可以给内存设定一个阈值,当内存达到该阈值时,对 VNF 做出减载。




图 1 VNF 减载图

Fig. 1 VNF load shedding diagram

NFV 的内存资源消耗是本文的研究重点,图 2 和图 3 总结了本文将要解决的问题。图 2 给出了在真实世界中模拟的 VNF,VNF 的不同配置会导致 VNF 的不同行为,文中假设其为常量。另外,为了得到预测的结果,本文选择神经网络来进行训练。图 3 展示了本文对 VNF 性能进行建模后的神经网络,即预测内存消耗的神经网络模型。本文的目标是通过输入流量进行预测,神经网络可以在输入流量的情况下对内存消耗的性能进行预测。




图 2 虚拟网络功能建模

Fig. 2 Virtual network function modeling




图 3 内存消耗神经网络模型

Fig. 3 Memory consumption neural network model

在 KDN 中,KDN 范例通过控制循环来进行操作,以提供自动化、推荐、优化、验证和估计。在定义 KDN 这个概念时,本文还借鉴了其他领域的许多思想,特别是黑箱优化^[18],该思想为本文的研究带来了便利。

本文假设 VNF 为一个黑盒子,并不考虑其内部构造,它位于被抽象出来的虚拟化的结构中。流量在进入这个黑盒子到离开这个黑盒子的过程中会改变黑盒子的资源消耗。本文的资源管理方案的基本原理是,通过得到一组表示输入数据的流量特性,对执行 VNF 功能所需的资源消耗进行建模。本文只关注内存消耗情况,训练所用的算法是莱文贝格-马夸特(Levenberg-Marquardt,LM)算法,并选择均方误差来进行误差度量。

3.2 LM 算法

LM 算法是一种比较著名的最小二乘算法。众所周知,LM 方法在反向传播(Back Propagation, BP)训练过程中表现出最有效的收敛性,该算法是收敛稳定但缓慢的一阶优化方法和与之特性相反的二阶优化方法的折衷。因此,LM 可以看作梯度下降算法和高斯-牛顿算法的一种结合体。LM 算法结合了两种算法的优点,既继承了牛顿算法的速度,又有梯度下降算法的优秀收敛能力。它特别适用于以均方误差计算神经网络的性能指标,被列为中小型模式神经网络的最有效的训练算法之一^[19]。

LM 算法不仅可以计算梯度,而且还可以计算雅可比矩阵,误差指标函数为:

$$E(w) = \frac{1}{2} \sum_{i=1}^p |Y_i - Y_i'|^2 = \frac{1}{2} \sum_{i=1}^p e_i^2(w) \quad (1)$$

其中, Y_i' 表示期望的网络输出向量; Y_i 表示实际的神经网络输出向量; p 表示样本数目; w 表示网络权值和阈值所组成的向量; $e_i^2(w)$ 表示误差。

假设 w_k 表示第 k 次迭代之后权值和阈值所组成的向量,那么新的权值和阈值组合的向量为 $w_{k+1} = w_k + \Delta w$, 计算公式如下:

$$\Delta w = [J^T(w)J(w) + \mu I]^{-1} J^T(w)e(w) \quad (2)$$

其中, I 表示单位矩阵; μ 表示自行定义的学习率; $J(w)$ 表示 Jacobian 矩阵,即:

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_n} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(w)}{\partial w_1} & \frac{\partial e_N(w)}{\partial w_2} & \dots & \frac{\partial e_N(w)}{\partial w_n} \end{bmatrix} \quad (3)$$

4 实验及结果分析

4.1 实验设置

本文主要通过真实世界对 VNF 实现建模,将网络中数据包流量特征作为神经网络的输入来预估 VNF 的内存消耗情况。训练神经网络最关键的问题是获取内存消耗信息和网络流量,并提取流量特征。本实验在受控环境中重现 VNF 的处理流量过程,此流量在 VNF 中持续被处理,同时以 20s 的时间间隔测量平均内存消耗。与此同时,流量的特征也在相同的 20s 的批次中进行处理。本实验在由同一虚拟机管理程序 ESXi5.5 主机管理的两台不同的真实 VM 中实现。本实验主要根据网络流量预测 VNF 的内存消耗, VNF 建模图如图 2 所示。

本文实验用追踪的实际流量测试了 Snort VNF, 这些流量来自于 WIDE 骨干的数据包^[20]。这里使用了两个 5min 的流量跟踪,而流量是在另一台 Ubuntu 虚拟机中生成的。在测试环境中复制流量,从一台 Ubuntu 虚拟机中通过 tcpreplay 将流量回放到了部署了 Snort VNF 的虚拟机中。由于链路速度太快,因此将 tcpreplay 回放的速率设置为 2000 包/s。

4.2 结果分析

本文通过上述方法得到数据集,并用该数据集训练神经网络,该神经网络可以学习流量特性和内存消耗之间的复杂

关系。本文采用了一种特殊的前馈网络,即 fitting networks。同时,利用随机交叉验证技术将数据集分为了 3 个组,即用于训练预测模型的数据集样本,占 90%;用于验证的数据集样本,占 5%;用于测试神经网络模型的数据集样本,占 5%。在训练集对模型训练完毕后,验证集对模型进行测试,除了测试模型是否准确之外,还需要评估模型的泛化能力。本文使用 MATLAB 建立神经网络模型,神经网络的隐藏层神经元设置为 15 个,采用交叉验证技术对预测效果进行评估。

在训练的过程中,神经网络学习并发现流量特性与内存消耗之间的关系。其中的一些流量特征可能与 VNF 表现出很相关、稍微相关或者完全无关等状态,图 4 显示了将神经网络用于训练单个流量特征的平均误差,用绝对内存消耗归一化的百分比表示。




图 4 单个特征的训练误差

Fig. 4 Training error for a single feature

从图 4 可以观察到,当用一部分流量特征来预测内存消耗时,误差较小;而用另一部分特征进行预测时,误差稍大。机器学习技术能够发现相关特性与内存消耗之间的关系,并且忽略无关的流量特征。也就是说,通过神经网络训练可以选择误差较小的流量特征,以此作为神经网络的输入,从而忽略相关性较小的流量特性。

在单个流量特征所建立的训练模型误差较大的情况下,本文训练具有全部 25 个流量特性的神经网络模型,可以相对较好地进行预测。图 5 给出了将实际的内存消耗作为输入时的预测内存消耗之间的线性回归关系,图中的离散点越接近对角线,表示预测的效果越好。可以看出,预测的结果较好。




图 5 交叉验证模式下内存消耗的预测效果

Fig. 5 Prediction of memory consumption in cross-validated mode

本文采用线性回归分析,相关系数 R 用来度量两个变量之间的线性关系,具体计算方法如下:

$$R(X,Y)=\frac{Cov(X,Y)}{\sqrt{Var[X]Var[Y]}}$$

(4)

其中, $Cov(X,Y)$ 表示 X 与 Y 的协方差; $Var[X]$ 表示 X 的方差; $Var[Y]$ 表示 Y 的方差。

本文通过相关系数 R 来体现内存消耗的预测效果,即相关系数 R 值越大,说明回归方程的效果越显著。作为对比,并为了使实验结果更加明显,本文选取的数据集划分较小,所以图 5(b)和图 5(c)的数据点比较稀疏。从图 5 中可以看出,相关系数 R 的值最高达到 82%。这说明实际的内存消耗与预测的内存消耗之间的拟合效果相对较好;其中,如果提升相关系数的值,预测内存消耗的效果就会更好。

在内存资源管理的过程中,会假设一个内存消耗的阈值,当用神经网络预测出内存资源消耗的情况之后,可以通过主动减载的方式进行资源管理。也就是说,通过减载当前无用的 VNF 来降低内存资源的消耗,从而提升系统的性能。本文主要是研究神经网络预测内存资源消耗的情况,以此作为内存资源管理的基础。阈值的设定和减载 VNF 是未来研究的主要内容,除了神经网络的预测效果之外,系统性能的提升效果也需要考虑其他因素,如网络拥塞等。

4.3 模型评估

在已经训练好神经网络的情况下,对模型的误差进行评估,具体评估方法如下:

(1)计算模型在训练集、验证集以及测试集上的误差,画出随着迭代次数增加的均方误差 (Mean-Square Error, MSE) 曲线;

(2)计算误差绝对值的累积分布函数 (Cumulative Distribution Function, CDF) 百分比,得到 CDF 图;

(3)绘制误差直方图,显示预测误差效果。

均方误差曲线主要是预测的内存数据和原始内存数据对应点误差的平方和的均值,计算公式如下:

$$MSE=E[e]\approx\frac{1}{n}\sum_{k=1}^n(t_k-a_k)^2$$

(5)

其中, n 表示输出单元数; a_k 表示第 k 个输出单元的实际值; t_k 表示第 k 个输出单元的期望值。

图 6 显示了在采用交叉验证技术情况下,训练集、验证集以及测试集的均方误差。一般来说,较高的 MSE 误差意味着平均内存消耗较高或者预测的结果较差。




图 6 训练集、验证集和测试集的 MSE 曲线

Fig. 6 MSE curves for training set, validation set, and test set

从图 6 可以看出, MSE 值较大,说明平均内存消耗较高,也就存在神经网络预测的结果比较差的情况。但是,本文所建立的神经网络学习模型的均方误差随着训练次数的增加不断下降;在最终的结果中,验证集和测试集的均方误差的变化趋势几乎相同。另外,还可以看出训练结束的条件,所提方法在训练 17 次之后达到了最好的效果。

误差分布直方图有一个很大的优点,即直方图体现的频率分布可以大致估计总体的分布情况。利用这种直方图的显示结果,可以很直观地观察到预测误差的分布效果。从图 7 中可以看出,训练集、验证集和测试集的误差集中分布在零误差附近,因此,神经网络模型的性能比较好。




图 7 训练集、验证集和测试集的误差分布直方图

Fig. 7 Error distribution histogram of training set, validation set and test set

图 8 是以误差的 CDF 作为误差百分比函数所绘制的误差绝对值的 CDF 百分比图。从图中可以看出,一半的观测误差小于 4%, 大约有 90% 的观测误差小于 10%, 几乎所有的误差最终控制在 16% 以内。因此,该神经网络是可以预测内存消耗的。




图 8 误差绝对值的 CDF 百分比图

Fig. 8 CDF percentage plot of absolute error

结束语 本文对 VNF 的内存资源管理方法进行了分析与研究,利用神经网络模型预测资源消耗的情况,并通过主动减载的方式来控制 VNF 的资源使用。本文主要的创新点是 VNF 建模,并将 VNF 视为具有资源消耗的黑箱;然后通过监测程序获取内存数据,利用神经网络对内存消耗进行预测,达到智能资源管理优化的目的。这意味着在 5G 通信系统中,只要提高预测内存消耗的准确性,就可以通过设定一个阈值对 VNF 进行减载,即只要内存消耗到达阈值,就可以对 VNF 进行减载。另外,本文的挑战是对流量特征的提取,这直接影响了神经网络模型的训练结果。今后的工作将会继续完善描述流量的相关特征,并建立多个虚拟网络功能的内存消耗模型进行研究。

参 考 文 献

- [1] NGMN A. 5G White Paper [OL]. NGMN Industry Conference and Exhibition. <https://www.ngmn.org/work-programme/5g-white-paper.html>.
- [2] GARNER J, MESTRES A, ALARCON E, et al. Machine learning-based network modeling: An artificial neural network model vs a theoretical inspired model[C]// Ninth International Conference on Ubiquitous & Future Networks. IEEE, 2017: 522-524.
- [3] LIOTOU E, ELSHAER H, SCHATZ R, et al. Shaping QoE in the 5G ecosystem[C]// 7th International Workshop on Quality of Multimedia Experience (IEEE QoMEX). IEEE, 2015: 1-6.
- [4] ZHANG X X, WU C, LI Z P, et al. Proactive VNF Provisioning with Multi-timescale Cloud Resources: Fusing Online Learning and Online Optimization[C]// IEEE Conference on Computer Communications. IEEE, 2017.
- [5] AKYILDIZ I F, NIE S, LIN S C, et al. 5G Roadmap: 10 Key Enabling Technologies[J]. Computer Networks, 2016, 106: 17-48.
- [6] MESTRES A, HIBBETT M J, ESTRADA G, et al. Knowledge-Defined Networking[J]. ACM SIGCOMM Computer Communication Review, 2017, 47(3): 2-10.
- [7] NGUYEN T M, FDIDA S, PHAM T M. A comprehensive resource management and placement for network function virtualization[C]// Network Softwarization. IEEE, 2017: 1-9.
- [8] MOENS H, TURCK F D. VNF-P: A model for efficient placement of virtualized network functions[C]// 2014 10th International Conference on Network and Service Management (CNSM). IEEE Computer Society, 2014: 418-423.
- [9] COHEN R, LEWIN-EYTAN L, NAOR J S, et al. Near optimal placement of virtual network functions[C]// IEEE Conference on Computer Communications. IEEE, 2015: 1346-1354.
- [10] MENG X, PAPPAS V, ZHANG L. Improving the Scalability of Data Center Networks with Traffic-aware Virtual Machine Placement[C]// 2010 Proceedings IEEE on INFOCOM. IEEE, 2010: 1154-1162.
- [11] MAO H, ALIZADEH M, ISHAIMENACHE, et al. Resource Management with Deep Reinforcement Learning [C] // 15th ACM Workshop. ACM, 2016: 50-56.
- [12] GHAZNAVI M, KHAN A, SHAHRIAR N, et al. Elastic virtual network function placement[C]// IEEE International Conference on Cloud Networking. IEEE, 2015: 255-260.
- [13] KULKARNI S G, ZHANG W, HWANG J H, et al. NFVnice: Dynamic Backpressure and Scheduling for NFV Service Chains [C] // the Conference of the ACM Special Interest Group. ACM, 2015: 71-84.
- [14] SUBRAMANYA T, RIGGIO R, RASHEED T. Intent-based mobile backhauling for 5G networks[C]// International Conference on Network & Service Management. IEEE, 2017: 348-352.
- [15] TSUZAKI Y, OKABE Y. Reactive configuration updating for Intent-Based Networking [C] // 2017 International Conference on Information Networking (ICOIN). IEEE, 2017: 97-102.
- [16] HYUN J, HONG J. Knowledge-defined networking using in-band network telemetry[C]// Asia-Pacific Network Operations and Management Symposium (APNOMS). 2017: 54-57.
- [17] RUELAS A M R, ROTHENBERG C E. A Load Balancing Method based on Artificial Neural Networks for Knowledge-defined Data Center Networking[C]// ACM Press the 10th Latin America Networking Conference. ACM, 2018: 106-109.
- [18] RIOS L M, SAHINIDIS N V. Derivative-free optimization: a review of algorithms and comparison of software implementations [J]. Journal of Global Optimization, 2013, 56(3): 1247-1293.
- [19] NAWI N M, KHAN A, REHMAN M Z. A New Levenberg Marquardt based Back Propagation Algorithm Trained with Cuckoo Search[J]. Procedia Technology, 2013, 11: 18-23.
- [20] CHO K, MITSUYA K, KATO A. Traffic data repository at the WIDE Project[C]// Project Usenix Freenix Track. 2000: 263-270.



SU Chang, born in 1979, Ph.D, professor, is a member of China Computer Federation (CCF). Her main research interests include QoS prediction, resource management, recommendation and prediction in location-based social network.



XIE Xian-zhong, born in 1966, Ph.D, professor. His main research interests include cognitive radio network, interference cancellation and MIMO technology, green communication network.