

深度学习在软件定义网络研究中的应用综述*

杨洋¹, 吕光宏¹, 赵会¹, 李鹏飞¹



¹(四川大学 计算机学院, 四川 成都 610065)

通讯作者: 杨洋, E-mail: 2017223040002@stu.scu.edu.cn

摘要: 数据转发与控制分离的软件定义网络(Software Defined Networking, 简称 SDN)是对传统网络架构的彻底颠覆,为网络各方面的研究引入新的机遇和挑战.随着传统网络研究方法在 SDN 中遭遇瓶颈,基于深度学习的方法被引入到 SDN 的研究中,在实现实时智能的网络管控上成果颇丰,推动了 SDN 研究的深入发展.调查了深度学习开发平台,训练数据集,智能 SDN 架构等深度学习引入 SDN 的促进因素;对智能路由,入侵检测,流量感知和其他应用等 SDN 研究领域中的深度学习应用进行系统的介绍,深入分析了现有深度学习应用的特点和不足;最后展望了 SDN 未来的研究方向与趋势.

关键词: 软件定义网络;深度学习;深度强化学习;促进因素;应用调查

中图法分类号: TP311

中文引用格式: 杨洋, 吕光宏, 赵会, 李鹏飞. 深度学习在软件定义网络研究中的应用综述. 软件学报, 2020. <http://www.jos.org.cn/1000-9825/6039.htm>

英文引用格式: Yang Y, Lv GH, Zhao H, Li PF. Survey on Deep learning Applications in Software Defined Networking Research. Ruan Jian Xue Bao/Journal of Software, 2020 (in Chinese). <http://www.jos.org.cn/1000-9825/6039.htm>

Survey on Deep Learning Applicatons in Software Defined Networking Research

YANG Yang¹, LV Guang-Hong¹, ZHAO Hui¹, LI Peng-Fei¹

¹(School of Computer Computer, Sichuan University, Chengdu 610065, China)

Abstract: Software Defined Networking (SDN), which separates data forwarding from control, is a complete overthrow of traditional network architecture, introducing new opportunities and challenges for all aspects of network research. With the traditional network research methods encountering bottlenecks in SDN, deep learning based methods have been introduced into the research of SDN, resulting in plenty of achievements in real-time intelligent network management and control, which promotes the further development of SDN research. This paper investigates the promoting factors of introducing deep learning into SDN, such as deep learning development platform, training datasets and intelligent SDN architectures; introduces the deep learning applications in SDN research fields such as intelligent routing, intrusion detection, traffic perception and other applications systematically, and analyzes the features and shortcomings of those deep learning applications in detail; Finally, prospects the future research direction and trend of SDN.

Key words: Software-defined networking; deep learning; deep reinforcement learning; promoting factors; applications investigation

由于历史原因,分层,分布式的传统网络结构复杂且难以管理,数据转发和控制功能绑定于特定网络设备,设备因为内置过多的协议而变得臃肿不堪,使得网络的维护,控制,管理,扩张,创新服务的部署变得极为困难,无法承载日新月异的网络需求^[1].随着物联网,云计算,人工智能的发展,网络流量增长迅速,各种新型应用和服务层出不穷,网络策略也更加灵活多变,传统 IP 网络已经无法有效应对这种变化,提供令人满意的数据传输服务.Mckeown 等人继承并发展了控制和转发解耦,可编程网络等思想,提出一种全新的网络架构——SDN^[2].

* 基金项目: 国家自然科学基金(61373091)

Foundation item: National Natural Science Foundation of China (61373091)

收稿时间: 2019-01-01; 修改时间: 2020-02-04, 2020-03-13; 采用时间: 2020-03-23; jos 在线出版时间: 2020-04-19

由开放网络基金会(Open Networking Foundation,简称 ONF))最早提出,并且持续发展的 SDN 参考架构得到了普遍认可,成为了事实上的参考架构,并在 2016 年 2 月发布了最新版本 SDN Architecture 1.1^[3].该架构基于解耦网络转发和控制,逻辑集中控制和网络服务可编程的原则,采用开放接口的定义,通过层次化递归的网络服务模式,强调接口处的流量隔离,信息隐藏,安全以及策略的执行,将网络技术的优化和功能软件的更新升级分离,方便网络管控,降低成本,提升用户体验.McKeown 等人所提出的 OpenFlow^[4]协议对数据包的转发方式进行了革新,在数据平面和控制平面之间配置基于流的数据转发,并成为事实上的数据-控制平面接口标准协议.最新的 Openflow 1.5.1 版本^[5]不仅支持流表的流水线处理,本地环回,非 OpenFlow 转发等功能,还可以通过组表功能实现更复杂的转发语义.过去十年,学术界和产业界围绕 SDN 进行了大量的基础性研究,并在校园网,数据中心等场景中进行了应用部署,研究人员 zhang 等人^[2]和 Kreutz 等人^[6]对这些早期工作进行了详尽的调查.

基于 OpenFlow 的 SDN 为传统网络的创新发展注入活力,技术标准,理论研究和小规模应用不断出现,但在可扩展性,安全性等方面与生产环境的需求之间存在差距,大规模部署存在巨大挑战^[7],SDN 研究成果少有大规模技术落地实例,相关研究陷入低谷^[8].近年来,研究人员开始尝试将 SDN 技术与其他技术领域进行融合,这一时期的 SDN 研究呈现两个明显特点:1)探索方法上的突破.在传统研究方法遭遇性能瓶颈后,研究人员引入了工业控制,群体智能,深度学习等先进工具,持续改善 SDN 研究的各项性能,解决大规模部署所面临的问题.2)SDN 的应用场景拓展.将 SDN 作为一种先进的网络设计理念,与其他应用领域进行融合,创造出价值巨大的实际应用场景,如软件定义光网络(SDON),软件定义物联网(SDN-IoT),软件定义传感器网络(SDSNs)等.

在持续推进 SDN 实际部署的研究过程中,研究人员开始引入新兴的深度学习技术,并取得了显著成效,成为目前 SDN 研究中最具潜力的方向之一.与传统方法相比,深度学习适用于处理不规则,大规模的非线性问题,在许多复杂问题上表现出无可比拟的优势^[9],为解决 SDN 研究中的难题提供了新的启示和借鉴.在智能路由,流量感知,入侵检测,信道分配等 SDN 问题的研究中,人工智能方法的应用都为相关研究带来了巨大进步,推动 SDN 的进一步发展,这些研究分散在各个领域,深度学习还没有得到 SDN 研究人员的全面关注.因此,本文尝试对上述研究内容进行系统梳理,总结深度学习在 SDN 研究中的应用,探究在 SDN 中引入深度学习的挑战和机遇.

本文第 1 节首先介绍了深度学习和深度学习在 SDN 研究中的引入,第 2 节归纳了在 SDN 中引入深度学习的促进因素.第 3 节系统梳理了深度学习在 SDN 各个细分领域的应用案例.第 4,5,6,7 节分别详细介绍了深度学习在 SDN 智能路由,入侵检测,流量感知,其他方面等研究领域的应用案例,并进行了深入的对比分析.第 8 节总结现有研究存在的问题,并针对 SDN 未来可能的发展方向提出见解.

1 深度学习的引入

深度学习^[10],也被称为深度神经网络(Deep Neural Networks,简称 DNN),是近年来人工智能领域发展形式最好,最能体现机器智能的一个分支.依靠深层结构和强大的特征学习机制,性能卓越的深度学习系列算法不仅在数字图像处理,语音识别,自然语言处理等计算机科学方面表现出色,还极大的促进了其他科学领域的研究^[11].与此同时研究人员也开始引入深度学习来提升网络流量控制^[12],并将其引入 SDN 的研究之中,使 SDN 在满足日益复杂的网络需求的同时变得更智能,成为 SDN 潜在的研究方向之一.

1.1 从神经网络到深度学习

机器学习作为实现人工智能的一种方式,对人类智能形成的过程进行建模,通过数据训练能完成复杂任务的建模,发展出众多形态各异的机器学习方法.其中对人类神经网络的深入研究和模拟催生了神经网络.神经网络能进行简单的特征学习,能够学到给定任务数据集上的特征,寻找到任务数据的内在结构,输出任务解决方案.然而传统浅层神经网络由于参数和超参数较少,对复杂任务的学习能力有限,不能学习到复杂输入的特征表示,泛化能力有限,难以满足任务需求,激发了利用深层网络对复杂函数建模的动机^[13].后来研究人员发现增加网络深度可以提升神经网络对复杂数据的表征能力,提高准确性,但因为梯度消失,泛化能力差,计算资源不足等原因而难以训练.2006 年 Hinton 等^[14]在实践中采用逐层调整和微调的方法成功训练了深度信念网络,证明

DNN 是可以训练的,此外,其他研究人员也提出 ReLU 和 dropout 等方案解决 DNN 过拟合的问题,提升模型的泛化能力,DNN 的学习机制进一步完善。

深度学习通过多层的前馈或者循环网络结构,实现复杂的函数逼近,以发现数据的分布式特征,并组合低层特征形成更加抽象的高层表示,展现了强大的从少数样本集中学习数据集本质特征的能力^[9]。此外,深度学习能够有效地从低级原始数据中学得低级特征,存储在网络前部的结构中,并通过不同的后部结构完成特征提取,分类,结果输出等任务。SDN 研究中使用到的主流深度学习模型,包括卷积神经网络(CNN),循环神经网络(RNN),深度信念网络(DBN),堆叠自编码器(SAE)等,以及在交互式控制任务中表现出色的深度强化学习(DRL)。

1.2 SDN中引入深度学习

深度学习在最近十年取得了巨大成功,在众多领域取得重大成果。在 ImageNet 图像识别大赛中,He 等人^[15]提交的深度学习方法以超过人类的正确率取得第一名,而 Google 基于深度学习和深度强化学习的 AlphaGo 机器人^[16]击败围棋世界冠军李世石,引起全球轰动。深度学习在众多复杂问题求解上表现出了优异的性能,网络研究人员也对深度学习产生了浓厚的兴趣^[12]。在认知无线网络^[17],无线传感器网络^[18],无线网络^[19],物联网^[20],网络安全^[21]等研究中,使用深度学习可以对复杂的网络环境进行特征抽象,为灵活的网络管理提供更好的决策,加快网络服务的部署,改善网络服务质量(QoS)和体验质量(QoE)。

近几年,研究人员尝试将深度学习引入 SDN 研究中,并取得显著成效。与传统 IP 网络相比,在 SDN 中引入深度学习具有如下优势:

- (1) 训练数据收集。深度学习模型需要大量数据进行特征学习。传统网络中数据收集需要部署额外的协议和设备,数据收集困难。集中控制的 SDN 架构能系统,全面地收集网络和流量数据,提供全局视图。
- (2) 计算资源。转发控制分离的架构,使得逻辑集中控制的控制器成为一个独立而强大的网络实体,相比一般交换机,控制器拥有较为丰富的计算资源用于深度学习模型的运行。
- (3) 灵活部署。在 SDN 架构中,控制器将下层资源进行抽象和编排,对应用层采用开放接口的可编程模式提供服务,深度学习可以作为应用层 APP 部署在 SDN 的应用平面,方便快捷。
- (4) 环境交互。网络控制实体能与网络环境进行互动,动态地调整网络策略是实现智能网络管控的重要标志,SDN 架构中存在的反馈控制循环则有助于这一目标的实现。如图 1 所示,SDN 控制器作为反馈控制中的活动实体,面对网络环境的动态服务请求,会根据最优化策略评估期望状态与实际状态的差异,不断调整资源状态为客户服务,如果期望状态和实际状态在策略的范围内不能调和,则控制器会拒绝服务请求或抛出异常。

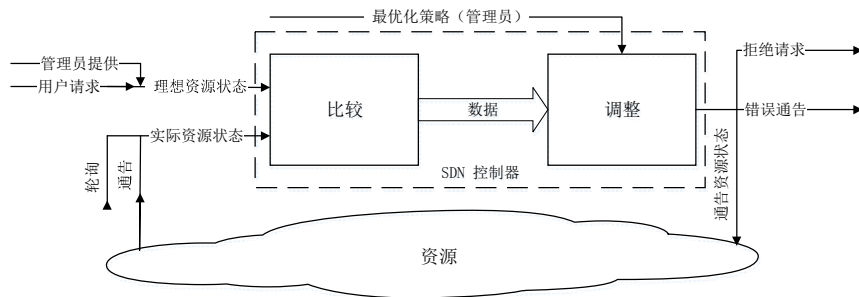


Fig.1 Feedback Control Loop in SDN

图 1 SDN 中的反馈控制闭环

对 SDN 来说,深度学习能提供灵活智能的网络管控,便于部署网络创新应用和服务。深度学习具有从复杂原始数据中学习抽象特征的能力,这些特征对应了复杂网络环境和服务需求之间的深层次联系^[9],而传统研究方法要么无法发现这种深层结构,要么计算存储开销巨大,无法满足实际部署需求。深度学习提供了一个解决复

杂网络问题的可行思路,扩展了 SDN 的性能边界,有助于 SDN 应对实际问题的考验.此外上述 SDN 中存在的闭环控制系统给深度学习提供一种与网络环境进行互动的机制,通过深度学习这个“智能大脑”与网络环境进行互动,SDN 可以实现智能、动态、交互式的网络管控.将深度学习引入 SDN 的研究中将会给 SDN 研究带来巨大影响,这种影响在可预见的将来都是积极的.

2 深度学习促进因素

一方面,深度学习在计算机网络,特别是在 SDN 中的引入较晚,还处于探索阶段,面临许多挑战.另一方面,研究人员也意识到在 SDN 中部署深度学习算法的诸多优势.SDN 集中控制的可编程网络管控使得深度学习的数据获取,算法部署和模型更改更加方便,其闭环的反馈控制能与强化学习方式完美结合,这在传统网络架构下是难以想象的.此外,成熟的深度学习平台可以促进 SDN 中深度学习模型的快速开发.在计算机网络研究领域,也能看到很多促进深度学习部署的因素,如训练数据获取,智能 SDN 架构等方面,本节将讨论这些促进因素.

2.1 深度学习开发平台

为了提供一个高效、简洁、易用的深度学习开发环境,提高开发效率,不少优秀的深度学习平台在近几年纷纷出现,还有更高级别的库可以在这些平台上运行,极大的促进了深度学习在其他领域的快速开发部署.在 SDN 网络中部署深度学习时,有效利用这些平台,能快速创建所设计的深度学习模型.表 1 对大多数研究人员使用的深度学习平台进行了总结,Shi 等人^[22]做了主流深度学习平台的性能测试,指出在 GPU 上进行运算,所有平台都实现了非常高的加速,但是在具体的 CPU/GPU 型号方面,又会因不同的任务而有不同表现,在面对复杂的网络问题时,研究人员需要根据实际情况灵活选取开发平台.

虽然 SDN 中引入深度学习可以极大地提升网络管控的水平,但却对 SDN 中的计算资源提出了严峻挑战.深度学习计算资源消耗巨大,过长的训练时间将导致应用受限,特别是在一些资源紧张,并且对实时性要求较高的网络环境中.基础计算能力,包括软硬件层面的提升将促进深度学习在 SDN 研究中的引入. Sze 等人^[23]在最近的工作中对深度学习中的软硬件加速设计进行了详尽的调查总结,对 SDN 场景下的深度学习应用提供了有益参考.而在 SDN 领域,随着交换机结构,流表查询优化,交换机查询机制,多核 CPU/GPU 加速等方面的推进,出现了性能卓越的软件定义路由器(SDR)^[24].其通用性强,交换性能大幅提升,能有效支持深度学习的部署.

Table 1 Deep Learning Platforms

表 1 深度学习平台

平台	开发者	主要支持语言	支持系统
TensorFlow	Google	Java,C++,Go,Python	Linux,macOS,Windows,Android
Theano	Montreal University	Python	Cross-platform
Caffe/Caffe2	BVLC	C++,Python,Matlab	Linux,macOS,Windows
Keras	Francois Chollet	Python,C++	Linux,macOS,Windows
Torch/PyTorch	—	LuaJIT/Python	Linux,macOS,Android
CNTK	Microsoft	Python,C#,C++	Linux,Windows
DL4J	SkyMind	Java,Scala,Clojure	Unix,Windows
WILL	Prevision	C,Python, assembly language	Windows,Unix, Embedded system

2.2 训练数据集

深度学习模型依赖海量数据对模型的参数和超参数进行调节,并输出为高层次的抽象表示,数据集的重要性不言而喻.数据构成了深度学习部署的基础,选择恰当的数据集是进行相关 SDN 研究的先决条件,数据集的大小也会影响模型的训练效果.使用公开网络数据集可以快速获取研究所需的各种数据,节省数据收集时间,提高研究效率,然而 SDN 公开数据集获取困难,多数情况下研究人员选择用传统 IP 网络数据集替代.在过去二十年中,网络研究机构和组织收集了大量真实环境中的网络数据用于科学研究,典型的如表 3 所示.

在计算机网络研究中,安全领域对数据集的突出需求导致很多数据集都是入侵检测数据集.其中 KDD 和 NSL-KDD 数据集已经很古老,并不是现有网络的完美代表,但仍然可以作为研究人员比较不同入侵检测方法有效性的基准数据集,Meena 等^[26]对此进行了调查分析.在网络创新研究和深度学习引入的情况下,许多研究人员

则积极采用 KDN^[26],ICIDS2017^[27]等最新的网络数据集进行深度学习的研究.上述数据集对深度学习的支持有限,为了使研究更加贴近实际运行的创新型网络,部分研究人员选择在 SDN 架构中实时收集网络数据用于深度学习模型的训练,SDN 架构转发控制分离,逻辑集中控制的特点也便于网络数据的获取.

Table 2 Computer Network Datasets

表 2 计算机网络数据集

数据集	时间	收集者	内容
DARPA	1998	MIT Lincoln Laboratory	1998,1999,2000 年入侵检测数据集
KDD99	1999	UCI Machine Learning Archive	1999 年中为期 9 周的真实网络数据
NSL-KDD	2000	—	对 KDD99 数据集的改进分为 KDDTrai+和 KDDTest+
CICIDS2017	2017	UNB Canadian Institute for Cybersecurity	2017 年中 5 天的网络流量信息和深度学习的配置文件
KDN	2016	Unviersitat Politècnica de Catalunya	包含支持 VNF,神经网络和深度学习的六个子数据集

2.3 智能SDN架构

在 SDN 研究中,研究人员结合数据挖掘,人工智能方法,提出了许多智能 SDN 网络架构,如数据驱动网络架构(DDN),知识定义网络架构(KDN),NetworkAI 架构等,旨在通过 SDN 集中控制的优势获取网络信息,利用数据挖掘/深度学习的智能决策解决复杂的网络控制和管理问题.作为在 SDN 中引入深度学习的智能架构,DDN 和 KDN 架构在 SDN 中引入自动化决策,NetworkAI 架构则采用 DRL 实现网络的实时智能控制,可用于大规模网络的自动化控制.智能 SDN 架构对 SDN 中具体问题的研究具有很高的参考价值,推动了深度学习在 SDN 研究中的深度参与.

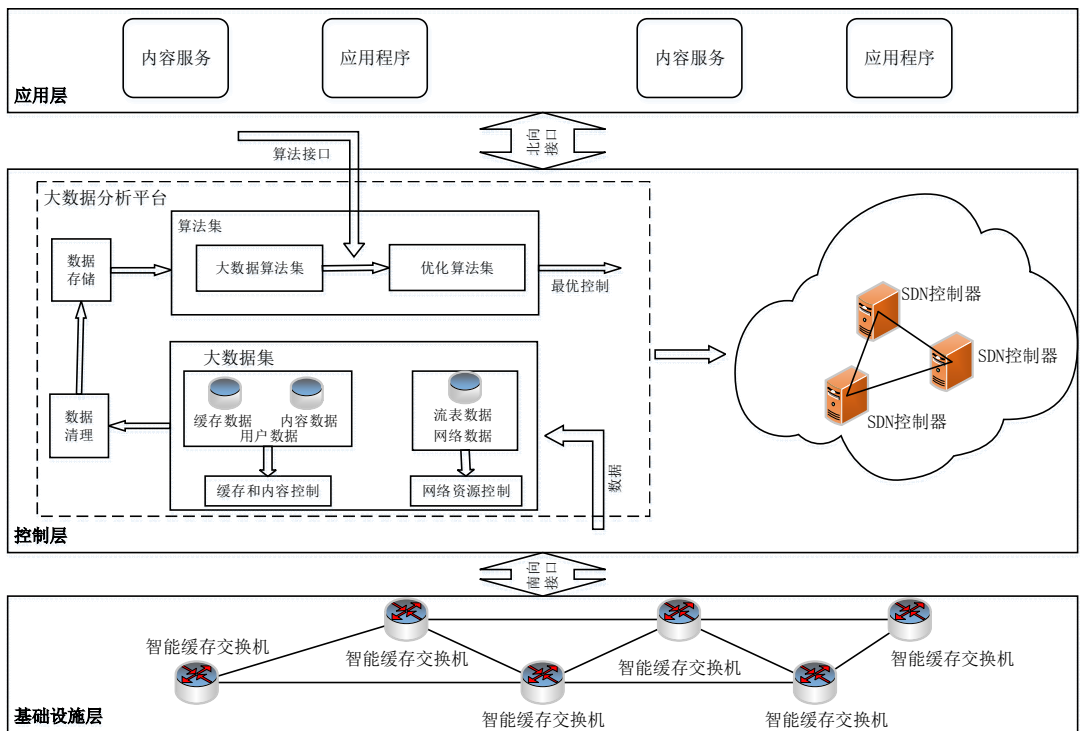


Fig.2 Data-Driven Networking

图 2 数据驱动网络

作为一种新颖的网络框架,DDN^[28]将 SDN ,内容中心网络^[29]和大数据分析范式整合在一起,探寻新型网络架构和大数据分析方法对智能网络管理带来的好处,如图 2 所示. DDN 架构在 SDN 交换机中嵌入了内容缓存,为用户提供内容,收集网络数据,并通过南向接口将它们发送到控制层的大数据分析模块. 利用大数据分析从

大量数据中提取知识,以帮助控制器做出决策并通过 SDN 提供的集中控制能力发送知识来控制整个网络,实现最优的资源分配,高效的内容分发和灵活的网络配置.Jiang 等人^[30]也提出了同名的 DDN 网络架构概念,使网络系统的设计和管理可以通过数据驱动范例得到改善,两者都是利用大数据分析能力来实现网络自动化,甚至智能化控制和管理,以满足网络日趋复杂的应用需求,并且大数据分析算法与机器学习算法一脉相承,可以采用更先进的深度学习算法替代,对 SDN 中深度学习的引入具有指导意义..

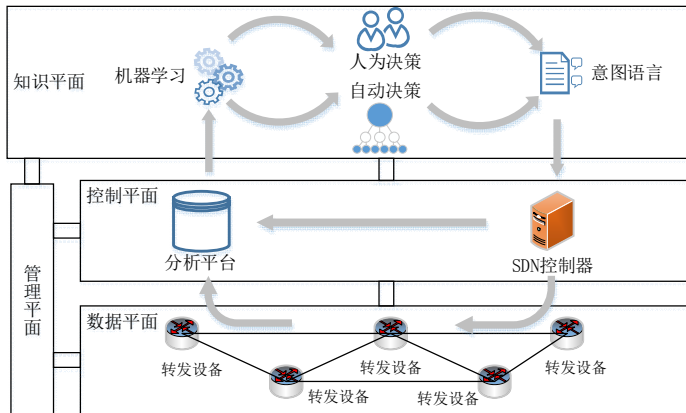


Fig.3 Knowledge Defined Networking

图3 知识定义网络

Clark 等人^[31]早在 2003 年就提出过在网络中加入知识平面,利用机器学习及其他认知技术实现网络控制和管理的自动化和智能化.Cabellos 等人整合 SDN 的集中控制,网络遥测^[32],网络分析技术^[33]和知识平面的概念,在 SDN 架构中引入知识平面和管理平面,提出了 KDN 架构^[34],如图 3 所示.KDN 主要由数据平面,控制平面,管理平面和知识平面组成,是各种机器学习/深度学习方法应用于 SDN 的一种通用架构,旨在通过闭环控制,在 SDN 中提供网络控制和管理的自动化,智能化等功能.控制平面中的分析平台实时监控数据平面,获取细粒度的流量信息,查询 SDN 控制器获取控制和管理状态,以提供全局视图.知识平面是 KDN 的核心,部署机器学习/深度学习算法,利用分析平台提供的网络视图信息,从网络中学习并产生有用的知识,通过意图语言从北向接口向控制器下发.管理平面垂直于控制平面和数据平面,定义网络拓扑,收集并处理网络设备提供的信息,监控分析网络,以确保网络长期的正常配置和操作.




Fig.4 (a) Framework of NetworkAI (b) DRL Closed-loop Control

图4 (a)NetworkAI 架构(b)DRL 闭环控制

SDN 架构中,控制平面引入大数据分析或者机器学习功能,能帮助做出智能的网络决策并快速部署,但很大

程度上依赖于配置策略的手动部署,为解决这个问题,Yao 等人^[35]提出了 SDN 中自主学习控制策略的智能网络架构 NetworkAI,如图 4(a)所示.转发平面负责给网络分析平台提供流量和网络状态的监控,控制平面对底层分布式的转发平面进行抽象,逻辑集中的控制使得 AI 层智能生成的策略可以快速部署到网络中.AI 层面负责动态控制策略的生成,利用带内遥测技术提供的全局视图和控制,网络分析平台提供的大数据存储和计算能力,与网络环境进行互动,通过深度学习动态地生成策略,达到网络管控的自动优化.

如图 4(b)所示,在 NetworkAI 的设计中,核心是将深度学习与 SDN 中的环形控制深度结合,通过网络状态上传链路和决策下发链路形成网络的闭环控制,动态生成最优管控策略.其中网络分析平台采用了 DRL 方法,可以在不改变数学模型的情况下,对动作和奖励函数空间中的不同任务和决策目标进行优化.

3 深度学习引入 SDN

实现灵活智能的网络管理一直是网络研究人员的目标^[12].过去因为各种原因,网络的创新和进步跟不上日益复杂的网络服务需求.深度学习能够从大量高维输入数据中进行特征学习,输出复杂任务的抽象表征,极大地提升了应对复杂网络任务的能力,与之相关的智能 SDN 架构,深度学习开发平台,网络软硬件基础设施也取得巨大进步,使得在 SDN 环境中部署深度学习成为一种可行的方向.

3.1 SDN 中的深度学习应用

近三年来,研究人员将深度学习用于 SDN 环境中某些复杂问题的求解,取得了不错效果.将深度学习和 SDN 的优势有机结合,充分利用深度学习和网络领域的有利因素,对不同的 SDN 研究内容进行探索,在可见的未来,成为灵活智能网络管理研究中的新兴领域.本文对 SDN 中的深度学习应用做了全面的调查,如图 5 所示,首先确定了 SDN 研究中应用了深度学习的领域,如智能路由,入侵检测,流量感知,控制器和交换机等,然后对上述领域,简要评论了现有研究成果的特点,对比相关的深度学习应用,提供了有关深度学习在该领域应用特点的总结,分析 SDN 网络环境中引入深度学习存在的优势和不利因素.

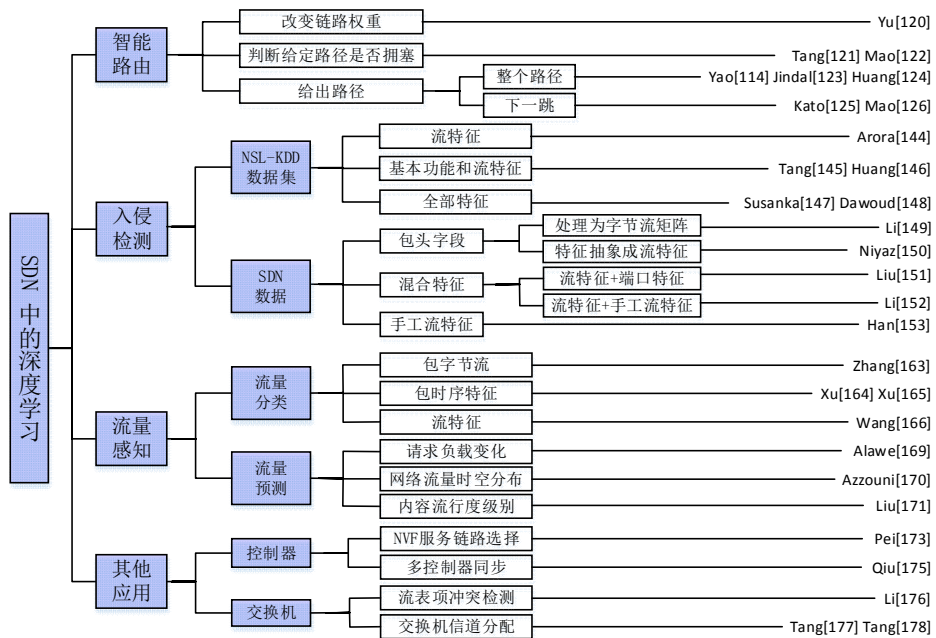


Fig.5 Deep Learning Application in SDN

图 5 SDN 中的深度学习应用

3.2 应用模式

在 SDN 研究中恰当地引入深度学习,将有效推动网络管控的自动化、智能化.虽然所要研究的具体问题不尽相同,但是在 SDN 环境中引入深度学习的方式却是可迹可循的.一般来说 SDN 中的深度学习应用遵循以下范式:将事先设计好的网络环境数据作为非监督深度学习模型的输入,通过逐层特征学习,得到待研究问题的抽象表示,最后对学得的任务抽象表示,采用监督学习的方法完成任务输出.若是需要与网络环境进行交互,则采用 DRL 机制,形成抽象表示学习的闭环.

另一方面,经典的深度学习模型各有其特点和善于处理的问题,不同 SDN 研究领域所面临的任務也不尽相同.如入侵检测领域需要发现网络数据的时空分布,多采用 CNN,RNN 等模型进行分类;需要输出实际操作的智能路由和控制器同步等问题则更宜采用 DRL 来与网络环境进行交互.因此在 SDN 中应用深度学习算法时,模型和任务的匹配至关重要.若没有完全合适的深度学习模型能解决所研究的网络问题,就需要研究者对模型进行重新设计,无论这种设计是问题表示本身,还是深度学习模型的结构和训练机制.如此才能将深度学习与 SDN 研究有机结合,以期深度学习模型在任务上有更好表现的同时,模型的复杂度和计算需求不至于超出可承受的范围.

4 智能路由

路由机制的研究一直是 SDN 中活跃的领域,在网络流量迅速增长,网络规模持续扩大的情况下,传统路由算法无法适应复杂多变的路由需求,出现了仿生的路由机制,通过对自然界各种行之有效优化机制的模仿,解决了数据传输 QoS 保障,链路负载均衡等问题.基于机器学习^[36,37]的路由在传统网络中已有研究,SDN 中采用强化学习^[38],支持向量机,概率图等机器学习方法的路由机制也引起了研究人员的兴趣.然而,上述路由是一种相对静态的路由,基于固定规则,在选择路径时会重复做出错误的选择,已被证明会引起拥塞,导致不必要的网络性能恶化.面对网络环境突变,面对复杂多样的网络资源分配需求时,传统路由机制仍然会显得灵活性和智能化程度不足^[39],因此,设计能够从以前的经验中学习并适应变化的智能路由策略^[40]非常重要,研究人员尝试将深度学习引入 SDN 路由研究中,并取得许多成果.按深度学习的应用方式的不同,可将 SDN 中基于深度学习的智能路由分为三类:更改链路权重,路径拥塞判定和直接路由决策.其中直接路由决策可细分为给出整个路径和给出下一跳路由.

4.1 更改链路权重

在引入深度学习实现 SDN 智能路由时,部分学者使用深度学习模型来自动调整网络链路的权重,从而优化用现有路由算法给出的路由,通过这种间接参与路由决策的方式简化深度学习模型的设计.为了实现通用和可定制化的路由优化机制,Yu 等人^[41]将 DRL 和基于策略的强化学习结合起来提出了 DRDM,其内部代理可以获得网络的流量矩阵作为系统状态,然后采取行动:通过不断学习,自动调整网络链路的权重,以最小化网络的反馈奖励.DRDM 具有良好的收敛性和有效性,可提供比现有解决方案更好的路由配置,提高网络性能,相比传统路由方法,通过连续黑盒优化改善网络性能,简化网络运营和维护.

4.2 拥塞判定

除此之外,部分学者选择拥塞判定的方式在 SDN 智能路由中引入深度学习:由传统路由算法给出某路径,随后由深度学习模型自动判断该路径是否会拥塞,辅助路由决策,降低深度学习与 SDN 路由研究适配的难度.

深度学习在无线网络中的网络流量控制是一个相对较新的领域.Tang 等人^[42]提出了基于深度学习的智能网络流量控制方法用于无线 mesh 网络(WMN)中的路由优化问题,采用传统路由方法给出路由策略,使用 CNN 通过拥塞判定的方式作出路由选择.与现有路由方法相比,实现了明显更低的平均延迟和丢包率,并且该方法与现有路由协议是完全独立的,这使其成为未来有线/无线网络中智能路由协议的潜在候选者.

考虑到软件定义无线网络(SDWN)中控制器配置的高计算资源,Mao 等人^[43]提出了一种在 SDN 控制器中运行的深度学习路由策略,利用 CNN 分析网络流量模式并做出路由决策.该方案中采用传统路由方法计算多条

路由,并为每条路由构建一个 CNN 判断该路由是否拥塞,并选择不会拥塞的路由构建流表并下发给交换机.该方法会实时收集数据,标记后重新训练深度学习模型,不仅可以从以前的经验中学习,主动更新路径,还可以调整和改进自身以适应新的流量模式.

4.3 直接路由决策

除了以上两种深度学习辅助做出智能路由决策的方式,还可以使用深度学习模型直接制定路由决策,不需要传统路由算法的参与,充分利用深度学习强大的特征提取和决策能力.但是模型设计的难度也随之加大,需要研究人员在模型选择,输入输出设计等方面进行深入探索.

Yao 等人^[35]提出了 NetworkAI 架构,并且给出了一个基于 QoS 的智能路由案例,采用深度 Q 学习(DQN)算法,通过与环境交互选出基于 QoS 的最佳路由以最小化网络的时延.该方案以链路延迟和节点处理延时作为系统状态,从源节点到目的节点的完整路径作为采取的动作,奖励为源节点到目的节点的时延,非常适合大规模网络的实时控制,在获得路由决策的闭环控制的同时,大大加提升了路由决策的自动化程度.

而为了解决现代车载网络物理系统(VCPS)场景中的网络流量管理问题,Jindal 等人^[44]提出了一种名为 SeDaTiVe 的路由方案,使用 CNN 学习流量数据中的隐藏模式,并根据学习的特征创建最佳路径,为数据分组分配最佳路由,从而控制 VCPS 环境中网络的传入流量.该方案中网络性能指标也将被收集,用来评估 CNN 路由的好坏,并周期性的再次训练 CNN 以获得新的路由模式.

Huang 等人^[45]提出了一种智能网络流量控制架构用于 SDN 中的流量控制,以分配的带宽,延迟,抖动和流的丢包率等作为系统状态,采用 DDPG 模型为流请求分配特定的路由路径和带宽,并以 QoE 作为奖励以学习流量控制机制,借助 DNN 将网络和网络应用的参数映射到平均意见得分(MOS)以反映 QoE.所提出的架构可实现无模型流量控制,能够直接从经验中学习并快速做出决策,可以显著提高多媒体流量的 QoE.

除此之外,也有研究在应用深度学习做出智能路由决策时,采用了输出下一跳路由的方式,不断地输出下一跳路由构成整个数据传输的路径. Kato 等人^[46]提出了一个有监督的 DNN 系统用于异构网络中的智能路由问题,使用异构网络中路由器的流量模式作为输入,下一跳路由作为输出,并将训练好的 DNN 部署到路由器.该系统的性能明显好于基准路由算法,成为第一个采用深度学习来改进异构网络流量控制的工作,但是需要在路由器间传递流量模式,以获知全局视图,将会引入额外的通信开销.

Mao 等人^[47]提出了一个基于 GPU 加速的深度信念架构(DBA)^[48],采用有监督的深度学习系统来构建路由表,并将所提出的方法与可编程路由器集成到 SDR 中,采用每个路由器的流量模式作为输入,下一跳节点作为输出训练 DBA,利用 DBA 计算下一个节点. DBA 将计算需求从基于规则的路由计算转移到基于深度学习的路由估计,以实现高吞吐量数据包处理,可以大大改善骨干网络控制.

4.4 智能路由分析

传统机器学习方法在网络流量控制中会存在计算效率和可扩展性方面的问题,而深度学习和计算技术的进步,促使许多研究工作将深度学习与 SDN 中的网络流量控制结合起来,智能路由研究获得新的突破,如表 3 所示.

通过对表中相关研究工作所提出的智能路由进行性能分析比较,可发现不同的应用场景中,都是以深度学习作为智能路由算法的基础,其中有监督的深度学习模型需要传统路由算法提供标记数据集,另一部分研究则采用环境互动性能更好的 DRL 模型,以实现网络流量的实时智能控制.采用深度学习算法与传统路由算法相比,具有更低的网络延迟,更少的网络开销,更高的网络吞吐量.其原因可归结于以下几点:1)深度学习具备经验学习的能力,当同样的拥塞再次发生时,能够避免选择重复的路径,选择拥塞度较低的路径,从而规避拥塞风险;2)深度学习具备更强的特征学习能力,借助深层结构抽取复杂网络中的隐藏特征,制定最优的路由策略,以此适应网络的实时变化.

尽管智能路由算法比传统路由算法具有更优的性能优势,但是大部分研究都仅限于模拟仿真或者小型网络,并未进行大规模真实网络环境性能测试,那么其在真实网络环境中的性能分析有待进一步研究.

Table 3 Intelligent Routing

表 3 智能路由

文献	问题描述	预期目标	模型	开发平台	数据	对比算法	对比指标	评估结果
[41]	路由算法性能不足	实现连续时间可定制化路由	DRL	Keras TensorFlow	模拟生成	OSPF RR	时延 吞吐量	本方案性能更优
[42]	路由策略缺乏学习经验	提高路由决策准确性避免拥塞	CNN	WILL	传统路由	RIP OSPF	信令开销 延迟/丢包率	本方案性能更优
[43]	减轻网络流量负担	选择流量转发的最佳路径组合	CNN	---	传统路由	SP	请求开销/成功传输率/时延/QoS	本方案性能更优
[35]	需要手动配置转发策略	动态生成最优转发策略	DRL	Karas gym	KDN	SP	稳定性 平均传输时间	本方案 稳定性更优
[44]	网络流量管理	自动分配最佳路由提高 QoE	CNN	NS-2SUNO	---	TCP/IP	延迟/吞吐量 传输率/网络负载	本方案 具有更优的性能
[45]	优化多媒体 QoE	最优控制策略最大化积累 QoE	DRL	Keras	模拟生成	---	吞吐量 网络效用函数	在资源配置上 本方案更优
[46]	网络动态变化,流量增长	改善网络流量控制	DNN	WILL	模拟生成	OSPF	平均没跳延迟 信令开销/吞吐量	本方案 具有更优的性能
[47]	核心网络性能硬件优化	改善骨干网络的流量控制	DBN	WILL	传统路由	OSPF	平均没跳延迟 信令开销/吞吐量	不同负载及信令 间隔下性能更优

5 入侵检测

近年来,网络安全问题受到前所未有的重视,SDN 安全^[49]也不例外.SDN 中的入侵检测高效而脆弱,基于 OpenFlow 的 SDN 使用流的概念来识别网络流量,并通过计数器记录其信息.集中控制的 SDN 使得流量的异常监控相比传统 IP 网络更高效,SDN 的功能如基于软件的流量分析,逻辑集中控制,网络的全局视图以及转发规则的动态更新等,使得检测和响应网络攻击变得容易,但控制和数据的分离会引入了新的攻击机会,因此 SDN 本身可能成为某些攻击的目标^[50].SDN 中对入侵流量的检测,常见的有机器学习方法,如多层感知机^[51],支持向量机^[52,53],受限玻尔兹曼机^[54],自组织映射^[55],多近邻结合图论^[56],神经网络^[57]等,此外还有基于 IP 地址熵变化^[58,59]的信息论方法,以及基于模糊推理^[60],DDoS 阻塞^[60],OpenFlow and sFlow^[62],混合方法^[63]等其他方法,而大部分机器学习方法在入侵检测中面临一些固有挑战^[64].最近深度学习取得巨大进展,能够对大规模数据进行特征提取和高级抽象,已被广泛用于语音,自然语言和图像识别等多个领域,是 SDN 中下一代入侵检测有前途的方法,研究人员将其引入入侵检测领域,取得一定成效.按照深度学习模型训练数据集的不同,可以将这些案例分为基于 NSL-KDD 数据集的入侵检测应用和基于 SDN 数据的入侵检测应用.

5.1 NSL-KDD数据集

NSL-KDD 数据集很古老,不是现有网络的完美代表,但是这并不妨碍它作为入侵检测的基准数据集,以帮助研究人员比较不同的入侵检测方法.现有的 SDN 数据集并不完备,所以即使是对 SDN 中入侵检测的研究,也会在 NSL-KDD 数据集中选择一些能在 SDN 环境中轻松获取的特征,用以构建深度学习模型执行入侵检测,然而不同研究工作对特征的选取却不尽相同.

Arora 等人^[65]通过研究发现学习率变化的 DNN 被证明是最好的分类器,并构建了学习率变换的 DNN,实现了较好的入侵检测精度.该深度学习模型选择了 NSL-KDD 数据集中的 10 个特征作为输入,这 10 个特征对于 SDN 是必不可少的,是基于流的功能,可在 SDN 环境中轻松获取.

Tang 等人^[66]提出了一种 SDN 中基于流的异常检测系统,构建了一个简单的 DNN,从 NSL-KDD 数据集中选择六个特征用于入侵检测,达到了 75.75%的准确率.该方法可以用少量特征推广和抽象正常和异常流量的特征,但是精度过低,尚不足以有任何商业应用.

GRU-RNN 是一种强大的深度学习模型,可以表示当前事件和先前事件之间的关系,提高异常检测概率.在后续工作中,Tang 等人^[67]采用 GRU-RNN 来构建入侵检测模型,该模型作为 SDN 控制器上的应用程序实现,使用 NSL-KDD 数据集中六个原始特征达到 89%的准确率,并且所提出的模型不会显著降低网络性能,在 SDN 环境中具有一定的入侵检测潜力.然而受限于数据集的表征水平和特征选择,上述研究只能是实验性质的,不能产

生有效的经济效益。

Sasanka 等人^[68]提出了一个利用加速平台的 DNN 模型用于网络中的入侵检测,使用 NSL-KDD 的全部 41 个特征,并利用了 DNN 的并行计算功能,在多核加速器平台上训练该模型。该方案训练时间和不同攻击类型的检测准确率等均表现出色,对深度学习在 SDN 入侵检测研究中的模型训练有一定参考意义。

Dawoud 等人^[69]展示了无监督深度学习增强 SDN 安全性的潜力,提出一种基于 SAE 的入侵检测框架,使用 SAE 计算网络流量记录的重建错误,并在重建错误的基础上应用 K-means 算法进行聚类,实现入侵检测。该模型利用很少的特征能达到很高的准确率,开销非常低,在 SDN 环境中具有显著的实时异常检测潜力。

5.2 SDN数据

另一些研究工作在 SDN 入侵检测方面取得了更进一步的开拓,没有采取在传统数据集中选取部分特征代替 SDN 网络中流量特征的方式,而是直接基于 SDN 网络收集原始数据,并对这些数据加以选择用以构建深度学习网络,部署入侵检测应用。

Li 等人^[70]提出了一种基于双向 LSTM-RNN 的 DDoS 攻击检测模型和防御系统。该模型可以从网络流量序列中学习,并以历史记录的方式跟踪网络攻击活动,可以有效地清除 SDN 中的 DDoS 攻击流量。与传统的机器学习方式相比,该模型具有更好的性能,降低了对环境的依赖程度,简化了检测系统的实时更新,从而降低了升级或改变检测策略的难度。

Niyaz 等人^[71]采用深度学习模型 SAE 用以解决 SDN 中的多矢量 DDoS 攻击问题。该 SAE 可以在 SDN 的控制器中部署,检测数据平面或者控制平面的 DDoS 攻击。作者将真实家庭无线网络(HWN)的正常网络数据和自建实验网络中模拟的 DDoS 攻击数据进行混合,并从网络数据包头部中抽取大量特征,然后用无监督学习的方式进行学习,并在真实的私人网络上实现了 95.65%的准确率。

Liu 等人^[72]则应用 DDPG 模型,有效地缓解了 SDN 环境中的 DDoS 攻击。为了使环境代理能够全面了解整个网络,作者利用 OpenFlow 协议定期收集网络信息,用来训练代理学习如何保护受害者服务器免于过载,并使良性请求得到充分服务,生成主机的最大带宽向量。DDPG 算法提高了该方案的可扩展性和数据效率,能够对攻击流量进行阈值处理并及时转发良性流量,从而使服务在短时间内重新上线,可以有效地缓解针对不同协议的 DDoS 泛洪攻击。

Li 等人^[73]针对 SDN 中外部 DDoS 攻击的问题进行了研究,提出了一种基于 CNN 和 SAE 的混合深度学习模型 DCNN-DSAE 用于入侵检测。该方法在构建深度学习模型时,输入特征除了从数据平面提取的部分特征字段外,还设计了能够区分流类型的 5 个手工流表特征,具有较高的精确度,优于传统的支持向量机和 DNN 方法,同时还可以缩短分类检测的处理时间。

Han 等人^[74]提出了跨平台的 DDoS 攻击防御框架 OverWatch,由数据平面上的粗粒度流监控算法和控制平面上的基于细粒度机器学习的攻击分类算法组成,利用数据平面和控制平面之间的智能协作,具有较高的防御效率,降低 SDN 南向接口上的通信开销,可用于跨控制器和交换机动态部署防御应用程序,实现快速的攻击反应和精确的僵尸网络定位。

5.3 入侵检测分析

网络安全一直是 SDN 的重点研究方向。深度学习方法的引入为 SDN 中入侵检测的研究注入新的活力。这些基于深度学习的入侵检测研究对比分析如表 4 所示。

相比于其他应用,入侵检测对准确率的要求更高,因此大多数入侵检测研究都致力采用特征优化,多级检测等方法提高入侵检测的准确率,而对模型带来的计算资源消耗,控制通道拥塞等负面影响尽可能忍受,少有分析。输入特征的选择是入侵检测成功与否的关键,但是各个研究中特征选择方式各不相同,没有可供遵循的模式。此外是否要对数据进行预处理也很重要,数据预处理可以提高模型的准确率,但是增加了额外的工作量和计算开销。许多案例都通过实验证明了浅层模型的有效性,并不是模型越深,神经元节点越多越好,深层模型可以带来准确率的微小提升,但是会出现收敛困难,训练时间长,资源消耗大等问题,因此多数基于深度学习的入侵

检测研究都采用浅层模型。

早期的研究多采用过时的 NSL-KDD 数据集训练基于深度学习的入侵检测系统,因为特征有限,功能单一,并不适合深度学习模型,后来的研究多采用更新的数据集,或者从真实 SDN 网络中收集网络数据,从而使得基于深度学习的入侵检测研究能更加深入,实验内容也更加全面,得出的结论也更适应现实 SDN 网络的情况。

Table 4 Intrusion Detection

表 4 入侵检测

文献	模型/层	特征	开发平台	数据集	结果	准确率	优点	缺点
[65]	DNN/4	原始特征 10	Weka	NSL-KDD	1 正常 1 异常	98%	探究了学习率 对模型性能的影响	未与其他方法 进行性能比较
[66]	DNN/5	原始特征 6	---	NSL-KDD	1 正常 1 异常	75.8%	只用少数特征 达到较高的准确率	准确率太低 导致无法实际应用
[67]	RNN/5	原始特征 6	Keras Scikit-learn	NSL-KDD	1 正常 1 异常	89%	运行开销低 可实时检测	准确率偏低
[68]	SAE/5	原始特征 41	---	NSL-KDD	1 正常 4 异常	97.7%	探究了并行 CPU 的加速作用	无法提高 罕见攻击检测率
[69]	SAE/-	原始特征 41	Tensorflow	NSL-KDD	8 聚类	99.2%	通过模型之后的 聚类提高准确率	未充分分析 模型性能
[70]	RNN/14	头部字段 20	Karas	ISCX2012	1 正常 1 异常	98%	准确率较高 环境依赖性较低	未充分分析 模型性能
[71]	SAE/-	头部 字段 7-14	Matlab	收集的 网络流量	8 分类 2 分类	95.7% 99.8%	较高的准确率	需要大量数据 预处理工作
[72]	DRL/-	流表特征 8	Tensorflow	模拟生成	流量 迁移	85%	快速迁移异常流量 保证服务运行	从全局考虑进行迁 移,用户正常率偏低
[73]	CNN/9 SAE/5	流表特征 21 手工特征 5	Tensorflow	收集的 网络流量	1 正常 1 异常	98.5%	采用两级检测模型, 准确率高	未对检测时间和资 源消耗进行分析
[74]	SAE/4	SAE/4	---	收集的 网络流量	6 异常	96%	跨平面联动, 入侵检测高效	需要对数据平面 进行改造

6 流量感知

网络流是一系列具有相似特征或者同一规范的数据包集合的统称,具有数据量,持续时间,速率和突发性等属性,并且根据数据量的大小分为大象流和老鼠流。SDN 中的数据转发是基于网络流的,对流量的智能感知为诸如 QoE 路由,负载均衡,流量工程应用奠定了基础。对 SDN 流量做出精准的分类和预测后,能根据流量的时空特点作出流量转发/处理决策,最大化网络系统转发效率的同时,提升用户体验。SDN 流量感知研究中,基于规则匹配和机器学习的流量感知方案对加密流量和应用层流量的感知正确率偏低,无法对流量的动态变化做出反应,随后深度学习方法被引入。现有的深度学习流量感知研究主要分为流量分类和流量预测两大类。

6.1 流量分类

传统网络中细粒度的流量分类^[75],需要特定设备的支持,可以应用于多个领域^[76,77]。灵活多变的网络应用承载的流量类型多种多样,对网络服务质量的要求也不尽相同,因此对网络流量进行正确的识别和分类,能提高路由策略的针对性和适应性^[78],成为 SDN 的热门研究领域之一。SDN 通过转发控制分离和集中控制得到全局视图,便于开展网络流量分类,因此 SDN 中的流量分类研究早已开展,主要有基于深度包检测(DPI)^[79]的方法和机器学习的方法,如 C5.0 决策树^[80,81],支持向量机^[82],图,混合方法^[83]等。这些方法在分类性能上已经非常优秀,但是在细粒度和应用适应性上还达不到灵活多变的应用需求。近年来研究人员尝试将深度学习引入 SDN 的流量分类研究中,扩展其解决实际复杂网络流量分类问题的能力。

针对 SDN 中现有应用分类方法很难准确识别和分类网络应用的问题,Zhang 等人^[84]提出了一种基于 SAE 的应用分类方法,利用逻辑集中控制和强大的计算能力,SDN 控制器可以收集网络流统计信息用于训练 SAE。该方案无需手动选择特征即可实现较高分类精度。

Xu 等人^[85,86]采用 DNN 对基于 SDN 的物联网(SDN-IoT)流量进行分类,包含 DNN 模型的 VNF 采用数据包时序特征进行模型训练,并创新性地部署在侦听指定物理端口的数据平面上,识别发送到端口的流量。该模型可

以对加密数据包实现较高的分类准确率,并且样本分类数据可以通过交换机直接转发到 VNF,而不占用控制信道,VNF 的崩溃不会影响网络的主要功能,网络架构可以更加健壮和智能。

为了解决深度包检测不能为加密数据流量提供实时应用感知的问题,Wang 等人^[87]设计开发了基于深度学习的流量分类框架 DataNets,分别开发了基于多层感知器(MLP),SAE 和 CNN 的分类模型,通过对 SDN-HGW 数据流量进行分类来实现分布式应用感知.该方案分类准确,计算效率高,可用于智能家庭网络中不同应用的实时处理,有助于进一步发展高层网络应用,而不会影响服务提供商或用户的安全/隐私。

6.2 流量预测

流量预测对于 SDN 中路由决策,拥塞控制,负载均衡等服务的开展具有重大促进作用,是一个基础性的研究领域.早已有研究将稀疏编码^[88],SAE^[89]等深度学习方法用于网络流量预测.SDN 流量预测研究中深度学习引入较晚,相关研究资料较少,分散在不同的具体领域,预测的内容除了传统的流量矩阵,还有 5G 核心网络负载,内容中心网络内容流行度等。

Alawe 等人^[90]提出了一种新的机制来分配 5G 核心网络(5G-CN)的网络资源,通过深度学习来预测工作负载变化,优化网络访问和移动性管理功能(AMF).作者使用 DNN 来预测下一时段的负载类别,再使用 LSTM-RNN 来预测即将到来的一段时间的平均负载,使托管 AMF 的 VNF 可以动态地增删资源,在保证 QoE 的同时,提高系统资源利用率。

流量矩阵(TM)预测被定义为在现有网络流量数据的基础上估计未来网络流量矩阵的问题,广泛用于网络规划,资源管理和网络安全.Azzouni 等人^[91]提出了 NeuTM,一种基于 LSTM-RNN 的 TM 预测框架,用于预测大型网络中的 TM,并将其部署在欧洲 GEANT 科研网中,使用真实数据集进行训练,该方案比传统的方案更能准确地模拟网络流量序列的长距离依赖性,实现了极高的预测准确率。

Liu 等人^[92]采用 SAE 模型来解决基于 SDN 的内容中心网络^[93](SDN-ICN)内容流行度预测的问题,并取得良好效果.作者构建了分布式深度学习网络 DLCPP,并将神经元部署到相应的交换机上,利用整个交换机体系来完成深度学习网络的功能.为了将 DLCPP 部署到交换机上,作者在每个节点(交换机)中构建一个神经 OpenFlow 转发表,用于节点与其他节点进行通信,采用 SDN 控制器来部署和管理 DLCPP 神经网络,并设计了神经元之间的同步方案,用以消除神经元间消息传递的延迟。

6.3 流量感知分析

Table 5 Traffic Perception

表 5 流量感知

文献	目标	模型/层	开发平台	数据集	准确率	优点	缺点	创新点
[84]	SDN 应用快速分类	SAE/7	Weka Matlab	Moore Dataset	91.2%	直接采用原始特征	小规模模拟,未经实际环境检验	只用少量有标记数据训练
[85] [86]	SDN-IoT 应用分类	DNN/4	Tensorflow	—	87%	分类后路由性能提升巨大	小规模模拟,未经过实际环境检验	分类模块部署到单独服务器
[87]	SDN-HGW 应用分类	MLP/4 SAE/5 CNN/7	Keras Tensorflow	ISCX VPN-nonVPN	95%	能分类加密应用,计算消耗少	复杂的数据前期处理	SDN 核心控制下沉到接入网
[90]	5G-CN 负载预测	DNN/- RNN/-	Tensorflow Simpy	MI Dataset	90%	更智能的资源动态增删	需要根据具体环境选用具体模型	使用负载预测动态增删资源
[91]	SDN 流量矩阵预测	RNN/6	Keras Tensorflow	GEANT Dataset	99.9%	极高的预测准确率	未充分分析模型性能	使用真实网络数据集训练
[92]	内容流行度预测	SAE/3	—	模拟生成	78.1%	能预测全网流行度时空分布	分布式部署增加部署/沟通开销	SAE 分布式部署到数据平面

基于 SDN 的流量感知研究中,深度学习方法的引入为传统的流量感知带来了新的改变,这些研究工作各有特点,如表 5 所示.考虑到流量感知模型的输入特征维度,以及大规模网络中快速感知的需求,相关研究中的深度学习模型很小,隐藏层通常在 7 层一下,隐藏层的节点数也较少.较浅的模型对流量的感知能力有限,故除了文献 [91],其他工作的准确率都比较低,是在感知效率和准确率之间折中的结果。

可以看到,SDN 流量感知的研究已转向复杂条件下的智能流量分类和预测.此外,研究人员也在研究 5G 核心网络,接入网,内容中心网络,物联网等场景下,将 SDN 集中控制和深度学习出色的感知能力结合,在上述新型场景下解决更具体的感知问题.为了深度学习模型能在更苛刻的 SDN 场景中部署,研究人员尝试了一些新的机制,如将模型部署在单独的服务器,监听交换机网络信息,并通过 openflow 协议与控制器进行通信;或者将模型分布式部署到数据平面的交换设备上,利用交换设备上少量的计算能力完成模型的运行,减少控制器的压力,并且控制器可以通过 openflow 协议的可编程特性完成模型在交换机上的动态部署,更改等.

7 其他应用

除了上述 SDN 中深度学习应用较多的领域,还有诸如信道分配,网络功能虚拟化(NFV)选择,控制器同步,流表冲突检测等领域也零星分布有深度学习的应用,这些应用可以松散地分类为控制器相关和交换机相关两大类.相比较智能路由,入侵检测,流量感知等研究方向,深度学习在上述领域的应用成果很少,一方面是因为 SDN 中的深度学习应用还处于探索阶段,上述领域还未全面将深度学习引入到相关研究中,另一方面也要看到,随着深度学习的参与,上述领域本身的特点特使得深度学习的引入较为困难,相关领域应用较少.

7.1 控制器

SDN 中 NFV 的研究由来已久,Pei 等人^[94]提出了一种基于 DBN 的深度学习方法来解决 VNF 选择和链接问题^[95],并在 SDN 网络中设计高性能路由策略,这是用深度学习技术研究 VNF 选择和链接问题的第一次尝试.该方案时间效率很高,端到端延迟小,服务功能链请求(SFCR)接受率高,证明深度学习技术可以解决高性能网络的 VNF 选择和链接问题.

针对软件定义工业物联网(SDIIoT)中的控制器同步问题,Qiu 等^[96]给出了一个基于 DRL 的区块链系统.作者综合考虑了区块链节点和控制器的信任特征,以及区块链系统的计算能力,将视图改变,访问选择和计算资源分配制定为联合优化问题.采用 DRL 方法来解决这一问题,并得到了基于 DRL 的控制器同步区块链系统.

7.2 交换机

针对 SDN 中应用的流表冲突问题,Li 等人^[97]提出了一种新的方法检测流表冲突.该方法采用第一级 CNN 模型定性判断是否存在流表冲突,并采用同样的第二级深度学习模型定位出具体冲突的流表项.当 OpenFlow 网络中存在大量的流表时,该方法在检测冲突流表上所花费的时间上远小于传统的流表冲突检测方法,非常适合于对超大规模流表进行冲突检测.

无线软件定义物联网中(SDN-IoT)交换机的信道分配问题非常重要.Tang 等人^[98]设想了预测未来网络流量负载,然后分别根据预测的流量负载自适应的分配信道的策略,并采用 CNN 模型一次性解决这两个问题.该模型分为特征抽取部分和分类部分,SDN 控制器收集整个网络的历史数据线下训练该模型用于信道分配,并在分配信道后收集实时数据更新该模型,从而实现智能地分配信道.该方法信道分配的准确率高,算法收敛时间远远小于传统算法,网络的吞吐量和时延这两个性能也有所提高.

在后来工作中,Tang 等人^[99]又提出一种新颖的智能信道分配算法,可以自动避免潜在的拥塞并在 SDN-IoT 中快速分配合适的信道.该算法包括两个部分:流量预测和信道分配,其中基于深度学习的流量负载预测算法预测网络中未来的流量负载和拥塞,而基于深度学习的部分信道分配算法被称为 DLPOCA,可以智能地将信道分配给 SDN-IoT 网络中的每个链路.在经过多次实验以后,作者选择了 CNN 作为深度学习模型,仿真结果表明该方案明显优于传统的信道分配算法,准确率接近 100%,并且收敛时间大大减少.

7.3 其他应用分析

除了重点的SDN研究领域,深度学习方法在其他SDN相关的研究中也引入,很好的促进了相关研究的发展,如表 6 所示.可以看到,在其他应用这一部分,需要解决的问题较为复杂,已经没有了成熟的研究路线和应用深度学习模式的模式,需要针对具体问题具体分析,深度学习模型更多的是作为核心步骤被引入.与此同时,面对不规则的问题,研究人员倾向于采用 CNN 进行原始特征的特征提取和高级抽象,并在模型的最后附加

softmax 分类器进行标签学习.在训练数据方面,因为所研究的问题相对较为小众和特殊,缺乏现成数据集,需要通过模拟生成的方式来获得训练数据.

另外此部分的深度学习应用机制更加复杂,需要配合其他技术联合解决问题,这有别于入侵检测,流量感知等 SDN 研究领域直接应用深度学习模型的情况.面对更细化的特定研究问题,深度学习模型的引入更加困难,需要针对具体问题详细设计和适配,这无疑给研究人员提出了更大的挑战.

Table 6 Other Application

表 6 其他应用

文献	目标	模型/层	特征	开发平台	数据集	准确率	优点	缺点
[94]	SDN 中 VNF 选择	DBN/4	资源状态	Matlab	模拟生成	100%	SFCR 映射的时效性可扩展性较好	请求增加时性能急剧下降
[96]	SDIIoT 控制器同步	DRL/-	综合特征	Tensorflow	模拟生成	---	提出基于区块链的第三方控制器同步机制	未解决信任特征的获取问题
[97]	SDN 流表冲突检测	CNN/8 CNN/4	流表字段	Keras scikit-learn	模拟生成	97.0% 99.9%	采用两级检测机制,检测时间线性增长	数据集模拟生成,无参考性
[98]	SDN-IoT 信道分配	CNN/7	历史负载	---	模拟生成	90.0%	可动态进行信道分配,提高网络吞吐量	准确率有待提高
[99]	SDN-IoT 信道分配	CNN/6	负载矩阵	WILL	模拟生成	100%	跨层联动预测,大幅提高系统性能	机制复杂,部署难度大

8 问题与展望

本文对 SDN 中的深度学习应用进行了详尽的介绍和分析,不难看出,在 SDN 中引入深度学习是一个值得研究的领域,复杂且更加强大的深度模型能深刻揭示网络环境所承载的信息,并对复杂的网络任务作出更精准的决策,将有效促进智能化的计算机网络管控.但是深度学习与 SDN 的结合是 2016 年左右才开始兴起的,还处于探索阶段,与其他成熟的深度学习应用领域相比,尚存在许多问题和不足,需要投入更多的时间和精力.在未来的工作中,可从以下几个方向入手,对深度学习的引入进行必要的基础性准备研究,更好的支持深度学习与 SDN 的深度融合,促进关键研究的深入开展,提升计算机网络的智能化水平.

(1)SDN 网络数据获取.

在 SDN 中部署深度学习,需要大量数据来训练深度学习模型,数据的轻松获取有助于促进相关研究的广泛开展.现有网络数据集对 SDN 和深度学习的支持度极其有限,需要在 SDN 网络数据获取方面进行深入研究.除了采用过时的网络数据集训练和评估模型效果外,在 SDN 中实时收集训练数据是许多现有研究的选择,然而这需要更多的资源投入和复杂的系统设计.如何设计高效便捷的网络监测和大规模网络数据收集框架,减少系统资源消耗,是一大难题.原始网络数据获取后需要进行预处理,研究大规模 SDN 网络数据的批量处理,高效存储,快速获取是引入深度学习后,顺利部署相关模型需要面对的挑战之一.此外,建立大型,公开,支持深度学习研究的标准网络数据库也将推进在 SDN 中引入深度学习的研究.

(2)深度学习模型适配.

与其他成熟领域相比,SDN 研究中深度学习的引入到目前为止还只是一种粗浅的尝试,深度学习与 SDN 研究并未完全适配.现有研究多采用成熟的深度学习模型,模型结构和训练设置并未根据 SDN 研究的特点灵活修改.此外深度学习模型输入和输出设计的好坏会直接影响到模型的训练效率和问题求解的准确性,因此对网络数据的筛选和处理就变得尤为重要.在 SDN 中,做出复杂决策的输入数据至少应包含网络本身的信息(节点+链路)和网络中流量的信息(包+流).同时还需要对模型的输出设计进行深入考量,不同的输出程式对任务解决方案的简化能力是不同的.未来应注重深度学习模型与 SDN 网络环境的深度融合,在充分理解模型特点和设计原理的基础上进行修改,以适配具体的 SDN 任务,发挥深度学习的潜力.

(3)SDN 接口协议设计

SDN 架构中,北向接口没有公认的通用协议,而南向接口普遍采用的 OpenFlow 协议也经历了多次更改,以支持不断变化的研究和部署需求,然而对深度学习机制的支持极其有限,只能实现简单的模型嵌入和消息传递,

无法支持复杂的深度学习机制和个性化部署.在未来的工作中,需要对接口协议进行重新设计,在协议内部原生支持深度学习,并保留开放接口机制,以接入不断变化的深度学习模型,增加部署的自由度和开放性,促进创新型研究的开展.

(4)SDN 实验平台设计

SDN 研究工作离不开模拟实验平台的支持.现有的 SDN 研究实验平台 Mnet,OMNet 等只能搭建简单拓扑,对小规模 SDN 场景进行模拟.在未来,随着研究场景的扩大和大型深度学习模型的引入,需要对混合场景,异形设备,自定义网络架构等复杂 SDN 环境进行模拟,因此需要开展综合实验平台的研究设计.综合实验平台需要有足够的可扩展性和自由度,支持对复杂环境自定义建模,提供深度学习的嵌入机制,更好的支持基于深度学习的复杂 SDN 场景下的研究.

(5)SDN 网络安全

随着社会生活,生产越来越依赖网络,网络安全问题日益突出,对 SDN 网络安全的研究未来将成为重点.未来 SDN 网络安全研究更为复杂多变,网络侵入,零日攻击,新型攻击等安全问题使用传统方法难以应对,需要借助深度学习强大的特征学习和决策能力,对网络攻击进行有效反应,快速处理,持续保护互联网应用和用户数据的安全.并且,SDN 架构本身也极易成为攻击的目标,特别是针对控制器资源和应用层软件漏洞的攻击,需要引入深度学习进行感知,持续保护网络架构本身的安全,保证持续提供网络服务的能力.

(6)SDN 大规模部署

实现大规模部署,促进 SDN 技术落地一直是研究人员的目标,却面临不少挑战.挑战之一便是 SDN 控制平面的可扩展性.分布式控制器可以增强 SDN 对大规模网络的管理能力,但如何使用深度学习进行多控制器视图同步以及控制权限分配尚有待深入研究.随着网络规模的扩大,网络资源的管理和服务部署变得困难,设计高效的网络管控机制,综合优化网络数据传输成为亟需解决的问题.深度学习的引入对控制器的计算资源提出了挑战.除了使用性能更强的控制器之外,另一个方向则是 SDN 中深度学习的分布式部署,对 OpenFlow 流表的结构加以扩展,将深度学习网络实现到了分布式交换机体系中,既降低了控制器的负担,也增强了网络的安全性和可扩展性.研究深度学习的分布式控制机制将成为深度学习应用于 SDN 大规模控制的关键.

(7)SDN 应用领域拓展.

深度学习在 SDN 中的应用范围较窄,集中在路由,流量感知和入侵检测等方面,这跟研究还处于探索阶段有关.未来,需要对不同应用领域的 SDN 研究进行深入分析,寻找深度学习引入的切入点,将深度学习在 SDN 中的应用范围将扩展到更为广阔的领域.与此同时,随着 SDN 的持续发展,SDN 与 5G 网,无线传感器网络,物联网等新型网络的融合成为一种趋势,借助深度学习的决策能力和 SDN 集中控制的优势,可以进行复杂网络的管理,拓展 SDN 的应用领域.SDN 与新型网络的融合需要结合 SDN 和新型架构的优点,重新设计网络架构,设计过程中如何提高架构适用性,增强对异种设备的管理,引入对深度学习机制的支持需要进一步研究.

References:

- [1] Jain R. Internet 3.0: Ten Problems with Current Internet Architecture and Solutions for the Next Generation. In: Proc. of the 2006 IEEE Military Communications conference (MILCOM). Washington DC, IEEE, 2006. 1-9.
- [2] Zhang CK, Cui Y, Tang HY, Wu JP. State-of-the-Art survey on software-defined networking (SDN). Ruan Jian Xue Bao/Journal of Software, 2015, 26(1):62-81. (in Chinese with English abstract)
- [3] SDN Architecture Issue 1.1. 2018. https://www.opennetworking.org/wp-content/uploads/2014/10/TR-521_SDN_Architecture_issue_1.1.pdf.
- [4] Mckeown N, Anderson T, Balakrishnan H, Parulkar G, Peterson L, Rexford J, Shenker S, Turner J. OpenFlow: enabling innovation in campus networks. Computer Communication Review, 2008, 38(2): 69-74.
- [5] OpenFlow Switch Specification Version 1.5.1. 2018. <https://www.opennetworking.org/wp-content/uploads/2014/10/openflow-switch-v1.5.1.pdf>.

- [6] Kreutz D, Ramos F M V, Verissimo P E, Rothenberg C E, Azodolmolky S, Uhlig S. Software-Defined Networking: A Comprehensive Survey. *Proceedings of the IEEE*, 2015, 103(1): 14-76.
- [7] Nunes B A A, Mendonca M, Nguyen X, Obraczka K, Turletti T. A Survey of Software-Defined Networking: Past, Present, and Future of Programmable Networks. *IEEE Communications Surveys & Tutorials*, 2014, 16(3): 1617-1634.
- [8] Feamster N, Rexford J, Zegura E W. The road to SDN: an intellectual history of programmable networks. *Computer Communication Review*, 2014, 44(2): 87-98.
- [9] Bengio Y, Courville A, Vincent P. Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1798-1828.
- [10] Lecun Y, Bengio Y, Hinton G E. Deep learning. *Nature*, 2015, 521(7553): 436-444.
- [11] Hatcher W G, Yu W. A Survey of Deep Learning: Platforms, Applications and Emerging Research Trends. *IEEE Access*, 2018, 6: 24411-24432.
- [12] Fadlullah Z M, Tang F, Mao B, Kato N, Akashi O, Inoue T, Mizutani K. State-of-the-Art Deep Learning: Evolving Machine Intelligence Toward Tomorrow's Intelligent Network Traffic Control Systems. *IEEE Communications Surveys & Tutorials*, 2017, 19(4): 2432-2455.
- [13] Bengio Y. Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning*, 2009, 2(1): 1-127.
- [14] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 2006, 18(7): 1527-1554.
- [15] He K, Zhang X, Ren S, Sun J. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. In: *Proc. of the 2015 IEEE International Conference on Computer Vision (ICCV)*. Santiago, IEEE, 2015. 1026-1034.
- [16] Silver D, Huang A, Maddison C J, Guez A, Sifre L, Driessche G, Schrittwieser J, Antonoglou I, Panneershelvam V, Lanctot M, Dieleman S, Grewe D, Nham K, Sutskever I, Lillicrap T, Leach M, Kavukcuoglu K, Graepel T, Hassabis D. Mastering the game of Go with deep neural networks and tree search. *Nature*, 2016, 529(7587): 484-489.
- [17] Zorzi M, Zanella A, Testolin A, Grazia M F, Zorzi M. Cognition-Based Networks: A New Perspective on Network Optimization Using Learning and Distributed Intelligence. *IEEE Access*, 2015, 3: 1512-1530.
- [18] Wang Y, Yang A, Chen X, Wang P, Wang Y, Yang H. A Deep Learning Approach for Blind Drift Calibration of Sensor Networks. *IEEE Sensors Journal*, 2017, 17(13): 4158-4171.
- [19] Mao Q, Hu F, Hao Q. Deep Learning for Intelligent Wireless Networks: A Comprehensive Survey. *IEEE Communications Surveys & Tutorials*, 2018, 20(4): 2595-2621.
- [20] Yao S, Zhao Y, Zhang A, Hu S, Shao H, Zhang C, Su L, Abdelzaher T. Deep Learning for the Internet of Things. *Computer*, 2018, 51(5): 32-41.
- [21] Xin Y, Kong L, Liu Z, Chen Y, Li Y, Zhu H, Gao M, Hou H, Wang C. Machine Learning and Deep Learning Methods for Cybersecurity. *IEEE Access*, 2018, 6: 35365-35381.
- [22] Shi S, Wang Q, Xu P, Chu X. Benchmarking State-of-the-Art Deep Learning Software Tools. In: *Proc. of the 2016 7th International Conference on Cloud Computing and Big Data (CCBD)*. Macau, IEEE, 2016. 99-104.
- [23] Sze V, Chen Y, Yang T, Emer J S. Efficient Processing of Deep Neural Networks: A Tutorial and Survey. *Proceedings of the IEEE*, 2017, 105(12): 2295-2329.
- [24] Li P, Luo Y. P4GPU: Accelerate packet processing of a P4 program with a CPU-GPU heterogeneous architecture. In: *Proc. of the 2016 ACM/IEEE Symposium on Architectures for Networking and Communications Systems (ANCS)*. Santa Clara, IEEE, 2016. 125-126.
- [25] Knowledge-Defined Networking Training Datasets. 2020. <http://knowledgedefinednetworking.org/>.
- [26] Meena G, Choudhary R R. A review paper on IDS classification using KDD 99 and NSL KDD dataset in WEKA. In: *Proc. of the 2017 International Conference on Computer, Communications and Electronics (Comptelix)*. Jaipur, IEEE, 2017. 553-558.
- [27] Sharafaldin I, Lashkari A H, Ghorbani A A. Toward Generating a New Intrusion Detection Dataset and Intrusion Traffic Characterization. In: *Proceedings of the 4th International Conference on Information Systems Security and Privacy (ICISSP)*. Funchal, ICISSP, 2018. 108-116.
- [28] Yao H, Qiu C, Fang C, Chen X, Yu F R. A Novel Framework of Data-Driven Networking. *IEEE Access*, 2016, 4: 9066-9072.

- [29] Jmal R, Fourati L C. Content-Centric Networking Management Based on Software Defined Networks: Survey. *IEEE Transactions on Network and Service Management*, 2017, 14(4): 1128-1142.
- [30] Jiang J, Sekar V, Stoica I, Zhang H. Unleashing the Potential of Data-Driven Networking. In: *Proc. of the Communication Systems and Networks - 9th International Conference (COMSNETS)*. Bengaluru, COMSNETS, 2017. 110-126.
- [31] Clark D D, Partridge C, Ramming J C, Wroclawski J T. A knowledge plane for the internet. In: *Proceedings of the ACM SIGCOMM 2003 Conference on Applications, Technologies, Architectures, and Protocols for Computer Communication*. Karlsruhe, ACM Press, 2013. 3-10.
- [32] Hyun J, Hong J W-K. Knowledge-defined networking using in-band network telemetry. In: *Proc. of the 2017 19th Asia-Pacific Network Operations and Management Symposium (APNOMS)*. Seoul, IEEE, 2017. 54-57.
- [33] Clemm A, Chandramouli M, Krishnamurthy S. DNA: An SDN framework for distributed network analytics. In: *Proc. of the IFIP/IEEE International Symposium on Integrated Network Management (IM)*. Ottawa, IFIP, 2015. 9-17.
- [34] Mestres A, Rodríguez-Natal A, Carner J, Barlet-Ros P, Alarcn E, Sol M, Munts-Mulero V, Meyer D, Barkai S, Hibbett M J, Estrada G, Maruf K, Coras F, Ermagan V, Latapie H, Cassar C, Evans J, Maino F, Walrand J, Cabellos A. Knowledge-Defined Networking. *Computer Communication Review*, 2017, 47(3): 2-10.
- [35] Yao H, Mai T, Xu X, Zhang P, Li M, Liu Y. NetworkAI: An Intelligent Network Architecture for Self-Learning Control Strategies in Software Defined Networks. *IEEE Internet of Things Journal*, 2018: 1-1.
- [36] Barbancho J, León C, Molina F J, Barbancho A. A new QoS routing algorithm based on self-organizing maps for wireless sensor networks. *Telecommunication Systems*, 2007, 36(1-3): 73-83.
- [37] Barabas M, Boanea G, Rus A B, Dobrota V, Domingo-Pascual J. Evaluation of network traffic prediction based on neural networks with multi-task learning and multiresolution decomposition. In: *Proc. of the 2011 IEEE 7th International Conference on Intelligent Computer Communication and Processing*. Cluj-Napoca, IEEE, 2011. 95-102.
- [38] Sendra S, Rego A, Lloret J, Jimenez J M, Romero O. Including artificial intelligence in a routing protocol using Software Defined Networks. In: *Proc. of the 2017 IEEE International Conference on Communications Workshops (ICC Workshops)*. Paris, IEEE, 2017. 670-674.
- [39] Akyildiz I F, Lee A, Wang P, Luo M, Chou W. Research challenges for traffic engineering in software defined networks. *IEEE Network*, 2016, 30(3): 52-58.
- [40] Lin S-C, Akyildiz I F, Wang P, Luo M. QoS-Aware Adaptive Routing in Multi-layer Hierarchical Software Defined Networks: A Reinforcement Learning Approach. In: *Proc. of the 2016 IEEE International Conference on Services Computing (SCC)*. San Francisco, IEEE, 2016. 25-33.
- [41] Yu C, Lan J, Guo Z, Hu Y. DROM: Optimizing the Routing in Software-Defined Networks With Deep Reinforcement Learning. *IEEE Access*, 2018, 6: 64533-64539.
- [42] Tang F, Mao B, Fadlullah Z M, Kato N, Akashi O, Inoue T, Mizutani K. On Removing Routing Protocol from Future Wireless Networks: A Real-time Deep Learning Approach for Intelligent Traffic Control. *IEEE Wireless Commun.* 2018, 25(1): 154-160.
- [43] Mao B, Tang F, Fadlullah Z M, Kato N, Akashi O, Inoue T, Mizutani K. A Novel Non-Supervised Deep-Learning-Based Network Traffic Control Method for Software Defined Wireless Networks. *IEEE Wireless Commun.* 2018, 25(4): 74-81.
- [44] Jindal A, Aujla G S, Kumar N, Chaudhary R, Obaidat M S, You I. SeDaTiVe: SDN-Enabled Deep Learning Architecture for Network Traffic Control in Vehicular Cyber-Physical Systems. *IEEE Network*, 2018, 32(6): 66-73.
- [45] Huang X, Yuan T, Qiao G, Ren Y. Deep Reinforcement Learning for Multimedia Traffic Control in Software Defined Networking. *IEEE Network*, 2018, 32(6): 35-41.
- [46] Kato N, Fadlullah Z M, Mao B, Tang F, Akashi O, Inoue T, Mizutani K. The Deep Learning Vision for Heterogeneous Network Traffic Control: Proposal, Challenges, and Future Perspective. *IEEE Wireless Commun.* 2017, 24(3): 146-153.
- [47] Mao B, Fadlullah Z M, Tang F, Kato N, Akashi O, Inoue T, Mizutani K. Routing or Computing? The Paradigm Shift Towards Intelligent Computer Network Packet Transmission Based on Deep Learning. *IEEE Trans. Computers*, 2017, 66(11): 1946-1960.
- [48] Huang W, Song G, Hong H, Xie K. Deep Architecture for Traffic Flow Prediction: Deep Belief Networks With Multitask Learning. *IEEE Trans. Intelligent Transportation Systems*, 2014, 15(5): 2191-2201.

- [49] Scott-Hayward S, Natarajan S, Sezer S. A Survey of Security in Software Defined Networks. *IEEE Communications Surveys and Tutorials*, 2016, 18(1): 623-654.
- [50] Kreutz D, Ramos F M V, Verissimo P. Towards secure and dependable software-defined networks. In: *Proceedings of the Second ACM SIGCOMM Workshop on Hot Topics in Software Defined Networking (HotSDN)*. Hong Kong, ACM Press, 2013. 55-60.
- [51] Jadidi Z, Muthukkumarasamy V, Sithirasanen E, Sheikhan M. Flow-Based Anomaly Detection Using Neural Network Optimized with GSA Algorithm. In: *Proc. of the 2013 IEEE 33rd International Conference on Distributed Computing Systems Workshops*. Philadelphia, IEEE, 2013. 76-81.
- [52] Kokila R T, Selvi S T, Govindarajan K. DDoS detection and analysis in SDN-based environment using support vector machine classifier. In: *Proc. of the 2014 Sixth International Conference on Advanced Computing (ICoAC)*. Chennai, IEEE, 2014. 205-210.
- [53] Phan T V, Toan T V, Tuyen D V, Huong T T, Thanh N H. OpenFlowSIA: An optimized protection scheme for software-defined networks from flooding attacks. In: *Proc. of the 2016 IEEE Sixth International Conference on Communications and Electronics (ICCE)*. Ha Long, IEEE, 2016. 13-18.
- [54] Fiore U, Palmieri F, Castiglione A, Santis A D. Network anomaly detection with the restricted Boltzmann machine. *Neurocomputing*, 2013, 122: 13-23.
- [55] Braga R, Mota E D S, Passito A. Lightweight DDoS flooding attack detection using NOX/OpenFlow. In: *Proc. of the IEEE Local Computer Network Conference*. Denver, IEEE, 2010. 408-415.
- [56] Aleroud A, Alsmadi I. Identifying cyber-attacks on software defined networks: An inference-based intrusion detection approach. *Network and Computer Applications*, 2017, 80: 152-164.
- [57] Chen X-F, Yu S-Z. CIPA: A collaborative intrusion prevention architecture for programmable network and SDN. *Computers & Security*, 2016, 58: 1-19.
- [58] Mousavi S M, St-Hilaire M. Early detection of DDoS attacks against SDN controllers. In: *Proc. of the 2015 International Conference on Computing, Networking and Communications (ICNC)*. Garden Grove, IEEE, 2015. 77-81.
- [59] Wang R, Jia Z, Ju L. An Entropy-Based Distributed DDoS Detection Mechanism in Software-Defined Networking. In: *Proc. of the 2015 IEEE Trustcom/BigDataSE/ISPA*. Helsinki, IEEE, 2015. 310-317.
- [60] Trung P V, Huong T T, Tuyen D V, Duc D M, Thanh N H, Marshall A. A multi-criteria-based DDoS-attack prevention solution using software defined networking. In: *Proc. of the 2015 International Conference on Advanced Technologies for Communications (ATC)*. Ho Chi Minh City, IEEE, 2015. 308-313.
- [61] Lim S, Ha J, Kim H, Kim Y, Yang S. A SDN-oriented DDoS blocking scheme for botnet-based attacks. In: *Proc. of the 2014 Sixth International Conference on Ubiquitous and Future Networks (ICUFN)*. Shanghai, IEEE, 2014. 63-68.
- [62] Giotis K, Argyropoulos C, Androulidakis G, Kalogeras D, Maglaris V. Combining OpenFlow and sFlow for an effective and scalable anomaly detection and mitigation mechanism on SDN environments. *Computer Networks*, 2014, 62: 122-136.
- [63] Mehdi S A, Khalid J, Khayam S A. Revisiting Traffic Anomaly Detection Using Software Defined Networking. In: *Proc. of the Recent Advances in Intrusion Detection - 14th International Symposium (RAID)*. Menlo Park, RAID, 2011. 161-180.
- [64] Sommer R, Paxson V. Outside the Closed World: On Using Machine Learning for Network Intrusion Detection. In: *Proc. of the 2010 IEEE Symposium on Security and Privacy*. Berkeley/Oakland, IEEE, 2010. 305-316.
- [65] Arora K, Chauhan R. Improvement in the performance of deep neural network model using learning rate. In: *Proc. of the 2017 Innovations in Power and Advanced Computing Technologies (i-PACT)*. Vellore, IEEE, 2017. 1-5.
- [66] Tang T A, Mhamdi L, McLernon D C, Zaidi S A R, Ghogho M. Deep learning approach for Network Intrusion Detection in Software Defined Networking. In: *Proc. of the 2016 International Conference on Wireless Networks and Mobile Communications (WINCOM)*. Fez, IEEE, 2016. 258-263.
- [67] Tang T A, Mhamdi L, McLernon D C, Zaidi S A R, Ghogho M. Deep Recurrent Neural Network for Intrusion Detection in SDN-based Networks. In: *Proc. of the 2018 4th IEEE Conference on Network Softwarization and Workshops (NetSoft)*. Montreal, IEEE, 2018. 202-206.
- [68] Potluri S, Diedrich C. Accelerated deep neural networks for enhanced Intrusion Detection System. In: *Proc. of the 2016 IEEE 21st International Conference on Emerging Technologies and Factory Automation (ETFA)*. Berlin, IEEE, 2016. 1-8.

- [69] Dawoud A, Shahristani S, Raun C. A Deep Learning Framework to Enhance Software Defined Networks Security. In: Proc. of the 2018 32nd International Conference on Advanced Information Networking and Applications Workshops (WAINA). Krakow, IEEE, 2018. 709-714.
- [70] Li C, Wu Y, Yuan X, Sun Z, Wang W, Li X, Gong L. Detection and defense of DDoS attack-based on deep learning in OpenFlow-based SDN. *Int. J. Communication Systems*, 2018, 31(5): e3497
- [71] Niyaz Q, Sun W, Javaid A Y. A Deep Learning Based DDoS Detection System in Software-Defined Networking (SDN). *ICST Trans. Security Safety*, 2017, 4(12): e2.
- [72] Liu Y, Dong M, Ota K, Li J, Wu J. Deep Reinforcement Learning based Smart Mitigation of DDoS Flooding in Software-Defined Networks. In: Proc. of the 2018 IEEE 23rd International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD). Barcelona, IEEE, 2018. 1-6.
- [73] Li CH, Wu Y, Qian ZZ, Sun ZJ, Wang WM. DDoS attack detection and defense based on hybrid deep learning model in SDN. *Journal on Communications*, 2018, 39(07): 176-187. (in Chinese with English abstract).
- [74] Han B, Yang X, Sun Z, Huang J, Su J. OverWatch: A Cross-Plane DDoS Attack Defense Framework with Collaborative Intelligence in SDN. *Security and Communication Networks*, 2018, 2018: 9649643:1-9649643:15.
- [75] Nguyen T T T, Armitage G J. A survey of techniques for internet traffic classification using machine learning. *IEEE Communications Surveys and Tutorials*, 2008, 10(1-4): 56-76.
- [76] Grimaudo L, Mellia M, Baralis E, Keralapura R. SeLeCT: Self-Learning Classifier for Internet Traffic. *IEEE Trans. Network and Service Management*, 2014, 11(2): 144-157.
- [77] Ettiane R, Chaoub A, Elkouch R. Enhanced traffic classification design through a randomized approach for more secure 3G mobile networks. In: Proc. of the 2016 International Conference on Wireless Networks and Mobile Communications (WINCOM). Fez, IEEE, 2016.116-121.
- [78] Chabaa S, Zeroual A, Antari J. Identification and Prediction of Internet Traffic Using Artificial Neural Networks. *JILSA*, 2010, 2(3): 147-155.
- [79] Jarschel M, Wamser F, Hohn T, Zinner T, Tran-Gia P. SDN-Based Application-Aware Networking on the Example of YouTube Video Streaming. In: Proc. of the 2013 Second European Workshop on Software Defined Networks. Berlin, IEEE, 2013. 87-92.
- [80] Uddin M, Nadeem T. TrafficVision: A Case for Pushing Software Defined Networks to Wireless Edges. In: Proc. of the 2016 IEEE 13th International Conference on Mobile Ad Hoc and Sensor Systems (MASS). Brasilia, IEEE, 2016. 37-46.
- [81] Qazi Z A, Lee J, Jin T, Bellala G, Arndt M, Noubir G. Application-awareness in SDN. In: Proc. of the ACM SIGCOMM Conference 2013. Hong Kong, ACM Press, 2013. 487-488.
- [82] Wang P, Lin S-C, Luo M. A Framework for QoS-aware Traffic Classification Using Semi-supervised Machine Learning in SDNs. In: Proc. of the 2016 IEEE International Conference on Services Computing (SCC). San Francisco, IEEE, 2016. 760-765.
- [83] Li Y, Li J. MultiClassifier: A combination of DPI and ML for application-layer classification in SDN. In: Proc. of the 2014 2nd International Conference on Systems and Informatics (ICSAI 2014). Shanghai, IEEE, 2014. 682-686.
- [84] Zhang C, Wang X, Li F, He Q, Huang M. Deep learning-based network application classification for SDN. *Trans. Emerging Telecommunications Technologies*, 2018, 29(5): e3302
- [85] Xu J, Wang J, Qi Q, Sun H, He B. IARA: An Intelligent Application-Aware VNF for Network Resource Allocation with Deep Learning. In: Proc. of the 2018 15th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON). Hong Kong, IEEE, 2018. 1-3.
- [86] Xu J, Wang J, Qi Q, Sun H, He B. DEEP NEURAL NETWORKS FOR APPLICATION AWARENESS IN SDN-BASED NETWORK. In: Proc. of the 2018 IEEE 28th International Workshop on Machine Learning for Signal Processing (MLSP). Aalborg, IEEE, 2018. 1-6.
- [87] Wang P, Ye F, Chen X, Qian Y. Datanet: Deep Learning Based Encrypted Network Traffic Classification in SDN Home Gateway. *IEEE Access*, 2018, 6: 55380-55391.
- [88] Ramirez I, Sprechmann P, Sapiro G. Classification and clustering via dictionary learning with structured incoherence and shared features. In: Proc. of the 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR). San Francisco, IEEE, 2010. 3501-3508.

- [89] Oliveira T P, Barbar J S, Soares A S. Multilayer Perceptron and Stacked Autoencoder for Internet Traffic Prediction. In: Proc. of the 2014 IFIP International Conference on Network and Parallel Computing (NPC). Ilan, IFIP, 2014. 61-71.
- [90] Alawe I, Ksentini A, Hadjadj-Aoul Y, Bertin P. Improving Traffic Forecasting for 5G Core Network Scalability: A Machine Learning Approach. IEEE Network, 2018, 32(6): 42-49.
- [91] Azzouni A, Pujolle G. NeuTM: A neural network-based framework for traffic matrix prediction in SDN. In: Proc. of the 2018 IEEE/IFIP Network Operations and Management Symposium (NOMS). Taipei, IEEE, 2018. 1-5.
- [92] Liu W, Zhang J, Liang Z, Peng L, Cai J. Content Popularity Prediction and Caching for ICN: A Deep Learning Approach With SDN. IEEE Access, 2018, 6: 5075-5089.
- [93] Liu W, Yu S-Z, Tan G, Cai J. Information-centric networking with built-in network coding to achieve multisource transmission at network-layer. Computer Networks, 2017, 115: 110-128.
- [94] Pei J, Hong P, Li D. Virtual Network Function Selection and Chaining Based on Deep Learning in SDN and NFV-Enabled Networks. In: Proc. of the 2018 IEEE International Conference on Communications Workshops (ICC Workshops). Kansas City, IEEE, 2018. 1-6.
- [95] Dwaraki A, Wolf T. Adaptive Service-Chain Routing for Virtual Network Functions in Software-Defined Networks. In: Proc. of the 2016 workshop on Hot topics in Middleboxes and Network Function Virtualization (HotMiddlebox@SIGCOMM). Florianopolis, ACM Press, 2016. 32-37.
- [96] Qiu C, Yu F R, Yao H, Jiang C, Xu F, Zhao C. Blockchain-Based Software-Defined Industrial Internet of Things: A Dueling Deep Q-Learning Approach. IEEE Internet of Things Journal, 2018: 1-1.
- [97] Li CH, Cheng C, Yuan XY, Cen LJ, Wang WM. Policy conflict detection in software defined network by using deep learning. Telecommunications Science, 2017, 33(11): 27-36. (in Chinese with English abstract).
- [98] Tang F, Mao B, Fadlullah Z M, Kato N. On a Novel Deep-Learning-Based Intelligent Partially Overlapping Channel Assignment in SDN-IoT. IEEE Communications Magazine, 2018, 56(9): 80-86.
- [99] Tang F, Fadlullah Z M, Mao B, Kato N. An Intelligent Traffic Load Prediction Based Adaptive Channel Assignment Algorithm in SDN-IoT: A Deep Learning Approach. IEEE Internet of Things Journal, 2018: 1-1.

附中文参考文献:

- [2] 张朝昆, 崔勇, 唐嵩祎, 吴建平. 软件定义网络(SDN)研究进展. 软件学报, 2015, 26(1): 62-81. <http://www.jos.org.cn/1000-9825/4701.htm>
- [73] 李传煌, 吴艳, 钱正哲, 孙正君, 王伟明. SDN下基于深度学习混合模型的DDoS攻击检测与防御. 通信学报, 2018, 39(07): 176-187.
- [97] 李传煌, 程成, 袁小雍, 岑利杰, 王伟明. 基于深度学习的软件定义网络应用策略冲突检测方法. 电信科学, 2017, 33(11): 27-36.