

图神经网络及其在通信网络领域应用综述

李硕朋^{1,2}, 齐思宇¹, 林绍福^{1,3}, 刘希亮^{1,3}, 陈华敏¹

(1. 北京工业大学信息学部, 北京 100124; 2. 北京未来网络科技高精尖创新中心, 北京 100124;
3. 北京智慧城市研究院, 北京 100124)

摘要: 近年来,图神经网络作为人工智能领域的新兴技术,受到越来越多的关注. 图神经网络凭借其处理非欧式空间数据的优良特性,已经在计算机视觉、推荐系统、知识图谱等领域获得广泛应用. 同时,通信网络也在近几年拥抱人工智能技术. 人工智能将作为未来网络的大脑,实现未来网络的全面智能化. 诸多人工智能技术已经被应用在5G、物联网、边缘计算等领域. 许多复杂的通信网络问题可以抽象为基于图的优化问题,通过图神经网络来解决,从而克服了传统方法的局限性. 简述了图神经网络的定义,分类介绍了不同类型的图神经网络,总结归纳了图神经网络在通信网络领域的应用,分析了研究现状并给出了未来的研究方向.

关键词: 人工智能; 未来网络; 图神经网络; 强化学习; 资源优化; 软件定义网络

中图分类号: TP 393

文献标志码: A

文章编号: 0254-0037(2021)08-0971-11

doi: 10.11936/bjtxb2021010003

Survey of Graph Neural Network and Its Applications in Communication Networks

LI Shuopeng^{1,2}, QI Siyu¹, LIN Shaofu^{1,3}, LIU Xiliang^{1,3}, CHEN Huamin¹

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China;

2. Beijing Advanced Innovation Center for Future Internet Technology, Beijing University of Technology, Beijing 100124, China;

3. Beijing Institute of Smart City, Beijing University of Technology, Beijing 100124, China)

Abstract: Graph neural network (GNN), as an emerging field of artificial intelligence (AI), has attracted more and more attentions recently. With its excellent characteristics of processing non-Euclidean data, GNN has been widely used in computer vision, recommendation system and knowledge graph. Communication networks are also embracing AI technologies in recent years. AI will serve as the brain of the future network and realize a comprehensive intelligence of the future network. Many AI technologies have been used in 5G, Internet of things, and edge computing. Many complex network problems can be abstracted into graph-based optimization problems and solved by GNN, thus overcoming the limitations of traditional methods. This paper briefly described the definition of GNN, introduced different types of GNN, summarized the applications of GNN in communication networks, discussed the shortcomings of existing works and gave some future research directions.

Key words: artificial intelligence (AI); future network; graph neural network; reinforcement learning; resource optimization; software defined network

人工智能作为近年来科学研究的前沿领域,引发了社会全行业的重点关注,逐渐成为社会经济发

收稿日期: 2020-12-31

基金项目: 国家重点研发计划资助项目(2020YFF0305400)

作者简介: 李硕朋(1989—),男,助理研究员,主要从事网络资源优化、深度学习方面的研究, E-mail: lishuopeng@bjut.edu.cn

展的新引擎. 人工智能已经在社会各领域中得到广泛的实践与应用^[1], 其中主要包括: 自然语言处理、计算机视觉、智能机器人、数据挖掘、认知与推理等.

随着智能手机、智能汽车和智能家居等智能设备的快速增长, 当今网络数据流量呈指数式增长. 同时, 边缘计算、虚拟化和网络切片等技术的应用, 使得网络服务变得更加多样化, 提升了用户体验, 也催生出了更加复杂的网络环境. 如何高效管理大量智能设备, 并优化大规模复杂网络环境的资源分配, 成为未来网络发展的一个重要问题.

未来网络需要全面拥抱人工智能. 人工智能作为未来网络的大脑, 用于网络的优化与决策. 同时, 网络节点算力的增强为网络带来了骨骼与肌肉, 使得智能网络的计算成为可能. 算法与算力的协同发展将使未来网络进入全新的智能化时代.

通信网络的基本结构是图. 图数据是一种典型的非欧式空间数据, 具有复杂的相关性和对象间依赖性. 传统图论的方法难以适应未来网络中复杂的

图形问题. 因此, 寻找解决复杂图数据的算法, 用以指导通信网络的资源分配、管理调度, 成为未来网络中的重要科学问题.

图神经网络作为近年来人工智能领域的新兴技术, 为处理复杂图结构数据开辟了新空间. 借助深度学习、强化学习等人工智能技术, 图神经网络能够快速挖掘图结构中的拓扑信息和复杂特征, 已经解决了计算机视觉、推荐系统、知识图谱等领域的许多重大问题. 因此, 图神经网络与未来网络的结合, 是解决网络优化问题、增强网络可靠性、提升网络资源利用率的重要途径.

本文综述了图神经网络及其在通信网络领域的应用. 表1给出了本文重复使用的术语简写形式及其含义. 本文首先介绍了图神经网络的基本模型以及几种重要的图神经网络; 其次介绍了图神经网络在通信网络各领域中的具体应用方法; 在结论部分探讨了当前的研究现状并给出了未来的研究方向.

表1 术语简写及含义

Table 1 Abbreviations and meanings of terms

简写	英文含义	中文含义
CNN	convolutional neural networks	卷积神经网络
DRL	deep reinforcement learning	深度强化学习
FF	feed forward neural networks	前馈神经网络
GAE	graph auto-encoder	图自编码器
GAT	graph attention networks	图注意力网络
GCN	graph convolutional networks	图卷积网络
GGNN	gated graph neural networks	门控图神经网络
GN	graph networks	图网络
GNN	graph neural networks	图神经网络
GRU	gated recurrent unit	门控循环单元
MPNN	message passing neural networks	信息传递神经网络
REGNN	random edge graph neural networks	随机边图神经网络
RNN	recurrent neural network	循环神经网络
SDNE	structural deep network embedding	结构深度网络嵌入
STGNN	spatial-temporal graph neural networks	时空图神经网络
VGAE	variational graph autoencoder	图自编码器
MPLS	multi-protocol label switching	多协议标签交换
NFV	network functions virtualization	网络功能虚拟化
SDN	software defined network	软件定义网络
SFC	service function chain	服务功能链
TCP	transmission control protocol	传输控制协议
VNE	virtual network embedding	虚拟网络映射
VNF	virtual network function	虚拟网络功能

1 图神经网络

图神经网络的概念由 Gori 等^[2]于 2005 年最早提出, Scarselli 等^[3]对此模型进行了更详细的阐述. Gori 等提出的图神经网络借鉴了神经网络领域的研究成果, 能够直接处理图结构数据, 其核心是局部转移函数和局部输出函数. 局部转移函数生成节点的状态向量, 该向量包含节点的邻域信息. 转移函数在所有节点间共享, 并根据输入的邻域更新节点的状态向量 \mathbf{h} , 其表达式为

$$\mathbf{h}_v = f(\mathbf{x}_v, \mathbf{x}_{vu}^e, \mathbf{h}_u, \mathbf{x}_u) \quad (1)$$

式中: \mathbf{x}_v 为节点 v 的特征; \mathbf{x}_{vu}^e 为连接节点 v 和其邻居节点 u 的特征; \mathbf{x}_u 为节点 v 邻居节点的特征. 局部输出函数生成节点新的表示, 其表达式为

$$\mathbf{o}_v = g(\mathbf{h}_v, \mathbf{x}_v) \quad (2)$$

局部转移函数和局部输出函数应用于所有节点的堆叠形式构成了 GNN 结构. 模型通过迭代最终将达到稳定状态.

早期的图神经网络存在很大的局限性, 其效率较低, 计算成本较大, 同时节点特征难以影响多次更新后的状态. 近年来, 为了更高效地处理图结构数据, 陆续有新型图神经网络及应用研究被提出.

1.1 图卷积网络

GCN 将卷积运算引入图结构, 是目前最主要的图神经网络之一, 根据特征提取方式的不同, 可划分为基于谱域的图卷积网络和基于空间域的图卷积网络.

基于谱域的图卷积网络源自于图信号处理, 引入滤波器对图卷积进行定义, 可将其理解为通过滤波器去除噪声从而得到输入信号的分类结果^[4]. Bruna 等^[5]基于谱图理论首次提出了定义谱域图卷积网络的卷积层函数. 2016 年, Kipf 等^[6]首次提出了 GCN 的概念, 此处的 GCN 为基于谱域的图卷积网络. Kipf 等将谱域图卷积定义为信号与滤波器函数的乘积, 其表达式为

$$\mathbf{g}_\theta * \mathbf{x} = \mathbf{U} \mathbf{g}_\theta \mathbf{U}^T \mathbf{x} \quad (3)$$

式中: \mathbf{g}_θ 为滤波器函数; \mathbf{x} 为图在节点上的信号; \mathbf{U} 为图归一化拉普拉斯矩阵的特征向量. \mathbf{g}_θ 可以被理解为图拉普拉斯矩阵的特征值函数, 即 $\mathbf{g}_\theta(\mathbf{A})$, \mathbf{A} 为图拉普拉斯矩阵的特征值组成的对角矩阵, θ 为函数参数. 为降低计算复杂度, 可以对 $\mathbf{g}_\theta(\mathbf{A})$ 进行近似处理, 其表达式为

$$\mathbf{g}_\theta(\mathbf{A}) \approx \sum_{k=0}^k \theta'_k T_k(\bar{\mathbf{L}}) \quad (4)$$

$$\bar{\mathbf{L}} = \frac{2}{\lambda_{\max}} \mathbf{L} - \mathbf{I}_N \quad (5)$$

$$\mathbf{L} = \mathbf{I}_N - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (6)$$

式中: T_k 为 k 阶切比雪夫多项式; θ' 为切比雪夫系数向量; \mathbf{L} 为图拉普拉斯矩阵; λ_{\max} 为 \mathbf{L} 的最大特征值; \mathbf{I}_N 为单位矩阵; \mathbf{D} 为对角度矩阵; \mathbf{A} 为邻接矩阵. 当限制 $k=1$ 时, 卷积层可简化为

$$\mathbf{g}_\theta * \mathbf{x} \approx \theta(\mathbf{I}_N + \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}}) \mathbf{x} \quad (7)$$

令

$$\bar{\mathbf{A}} = \mathbf{A} + \mathbf{I}_N \quad (8)$$

$$\bar{\mathbf{D}}_{ii} = \sum_j \bar{\mathbf{A}}_{ij} \quad (9)$$

则图卷积网络的卷积层公式为

$$\mathbf{h}^{(l)} = \sigma(\bar{\mathbf{D}}^{-\frac{1}{2}} \bar{\mathbf{A}} \bar{\mathbf{D}}^{-\frac{1}{2}} \mathbf{h}^{(l-1)} \mathbf{W}^{(l-1)}) \quad (10)$$

式中: $\sigma(\cdot)$ 为非线性激活函数; $\mathbf{W}^{(l)}$ 为第 l 层图卷积网络的权重矩阵.

GCN 的概念被提出后, 陆续有新形式的基于谱域的图卷积网络模型被提出, 如 AGCN^[7]、CayleyNet^[8]、AGC^[9] 等. 但基于谱域的图卷积网络无法处理有向图且扩展性较差, 而基于空间域的 GCN 更加灵活与通用.

基于空间域的图卷积网络根据节点的空间关系定义图卷积. NN4G^[10] 是最早提出的基于空间域的图卷积网络, 其通过对节点邻域特征信息的直接累加实现图卷积. Gilmer 等^[11] 提出的 MPNN 可看作基于空间域的图卷积网络的通用框架. MPNN 将空间域卷积分解为信息传递和状态更新 2 个过程, 其将节点 v 的特征作为隐藏状态的初始态, 即

$$\mathbf{h}_v^{(0)} = \mathbf{x}_v \quad (11)$$

式中 \mathbf{x}_v 为节点 v 的特征. MPNN 的隐藏状态更新公式为

$$\mathbf{h}_v^{(l)} = U_l \left(\mathbf{h}_v^{(l-1)}, \sum_{u \in N(v)} M_l(\mathbf{h}_v^{(l-1)}, \mathbf{h}_u^{(l-1)}, \mathbf{x}_{vu}^e) \right) \quad (12)$$

式中: l 为层索引; $U_l(\cdot)$ 为更新函数; $M_l(\cdot)$ 为信息传递函数. 得到图中所有节点的隐藏表示后, 可通过 readout 函数生成整个图的表示.

$$\hat{\mathbf{y}} = R(\mathbf{h}_v^{(l)} | v \in G) \quad (13)$$

式中 $R(\cdot)$ 为 readout 函数. 通过定义不同形式的更新函数、信息传递函数和 readout 函数, MPNN 可以表示多种基于空间域的图卷积网络. 典型的基于空间域的图卷积网络还包括 PATCHY-SAN^[12]、GraphSage^[13] 和 DCNN^[14] 等.

基于谱域的图卷积网络方法与基于空间域的图卷积网络方法的总结与对比如表2所示,表中时间

复杂度为各方法进行图卷积计算的时间复杂度, n 为节点数, m 为边数.

表2 图卷积网络方法的比较与总结

Table 2 Comparison and summary of graph convolutional networks methods

类别	方法	是否输入边特征	输出的主要应用	时间复杂度	可扩展性
基于谱域	SpectralCNN ^[5]	否	图分类	$O(n^3)$	
	GCN ^[6]	否	节点回归或分类	$O(m)$	可扩展
	AGCN ^[7]	否	图分类	$O(n^2)$	不可扩展
	CayleyNet ^[8]	否	图分类、节点回归或分类	$O(m)$	
	AGC ^[9]	否	图分类	$O(n^2)$	可扩展
基于空间域	NN4G ^[10]	否	图分类	$O(m)$	
	PATCHY-SAN ^[12]	是	图分类		
	DCNN ^[14]	否	图分类、节点回归或分类	$O(n^2)$	不可扩展
	MPNN ^[11]	是	图分类、节点回归或分类	$O(m)$	可扩展
	GraphSage ^[13]	否	节点回归或分类		可扩展

1.2 图注意力网络

GAT在图卷积网络的基础上引入了注意力机制,使模型能够专注于和当前任务最相关的信息,从而改进模型性能.基于谱域的GCN中,滤波器函数依赖于拉普拉斯矩阵,而拉普拉斯矩阵来源于图结构,这使得在特定图上训练的模型无法直接应用于其他图结构.为解决这一问题,Velikovi等^[15]提出了一种新型的图神经网络结构,即GAT.

GAT学习图中每个节点的邻域特征的平均值,根据邻域的重要性进行稀释加权.图注意力层是GAT实现注意力机制的关键结构.图注意力层以图中节点的特征为输入,输出另一组可能具有不同基数的更高层次的节点特征.图注意力层通过注意力机制 a 得到的注意力系数实现输入与输出的转换,注意力系数表示节点 j 对于节点 i 的重要性,其表达式为

$$e_{ij} = a(\mathbf{W}\mathbf{x}_i, \mathbf{W}\mathbf{x}_j) \quad (14)$$

式中: \mathbf{W} 为应用于所有节点的权重矩阵,代表输入特征与输出特征间的关系; \mathbf{x}_i 和 \mathbf{x}_j 分别为节点 i 和节点 j 的特征.模型通过只计算节点与其邻居节点的注意力系数将注意力机制引入图结构,而不需考虑图的结构信息.为简化运算和便于比较,对注意力系数进行正则化处理,并将其用于生成输出特征

$$\mathbf{x}'_i = \sigma\left(\sum_{j \in N(i)} \alpha_{ij} \mathbf{W}\mathbf{x}_j\right) \quad (15)$$

式中: $\sigma(\cdot)$ 为非线性激活函数; α_{ij} 为正则化后的注意力系数.GAT中还引入了与Transformer架构^[16]类似的多头注意力机制,能够针对相邻节点进行并行计算,稳定学习过程.

GAT方法的复杂度较低且只关注相邻节点,无须整张图的信息,其应用于新的图结构时不需重复训练模型.针对复杂的图结构,有研究提出了新型的图注意力网络,如异构图注意力网络^[17]和动态图注意力网络^[18],这些模型能够在更加复杂、信息量更大的网络中取得更好的效果.

1.3 图自编码器

GAE是一种无监督的学习框架,能够将图结构转化为低维向量,并利用编码信息重建图结构,常用于图嵌入(graph embedding, GE)和图结构生成.

图嵌入是一种图表示学习(graph representation learning, GRL)方法,其目的是在保留节点信息的同时将图结构数据映射为低维稠密向量.图嵌入使图结构数据能够被更高效地应用于传统机器学习算法,从而在推荐、分类等任务中取得更好的结果,典型方法包括基于随机游走的图嵌入,如DeepWalk^[19]和Node2Vec^[20],以及基于矩阵分解的图嵌入,如奇异值分解(singular value decomposition, SVD)、局部线性嵌入(locally linear embedding, LLE)和非负矩阵分解(nonnegative matrix factorization, NMF).相比基于随机游走和基于矩阵分解的图嵌入,图自编码器能够应用于

高度非线性的图结构,保留图的非线性结构与复杂特征.

2014年,Tian等^[21]首次将自动编码器(autoencoder)应用于图数据,该模型将图的邻接矩阵或其变体作为原始节点特征,通过堆叠稀疏自编码器(sparse autoencoder, SAE)生成了图的非线性嵌入,即低维节点表示. SDNE^[22]是一种同样采用堆叠自动编码器结构的重要的图自编码器模型,其分别通过节点间的一阶相似性和二阶相似性保持图的局部网络结构和全局网络结构,利用多层非线性函数生成图嵌入向量. SDNE的隐藏层表达式为

$$\mathbf{h}_v^{(l)} = \sigma(\mathbf{W}^{(l)} \mathbf{x}_v + \mathbf{b}^{(l)}) \quad (16)$$

$$\mathbf{h}_v^{(l)} = \sigma(\mathbf{W}^{(l)} \mathbf{h}_v^{(l-1)} + \mathbf{b}^{(l)}) \quad (17)$$

式中 \mathbf{x}_v 为节点 v 的特征; $\mathbf{W}^{(l)}$ 为第 l 层权重矩阵; $\mathbf{b}^{(l)}$ 为第 l 层偏差. 得到最后的隐藏层输出后,可通过反编码器的计算过程获得输出表示 \mathbf{x}' . SDNE包含2个损失函数,其中第一损失函数采用拉普拉斯特征映射的思想,用以保留一阶相似性,其表达式为

$$L_{1st} = \sum_{i,j=1}^n s_{i,j} \|\mathbf{h}_i - \mathbf{h}_j\|_2^2 \quad (18)$$

式中: $s_{i,j}$ 表示图中节点的连接关系,当且仅当节点 i 与节点 j 相连时, $s_{i,j} > 0$. 第二损失函数用以保持二阶相似性,并引入惩罚向量对非零元素的重构误差施加相比零元素更大的惩罚,其表达式为

$$L_{2nd} = \sum_{i=1}^n \|\mathbf{x}'_i - \mathbf{x}_i\|_2^2 \quad (19)$$

式中: \circ 表示哈达玛积. $b_i = \{b_{i,j}\}_{j=1}^n$, $s_{i,j} = 0$ 时, $b_{i,j} = 1$,其他情况 $b_{i,j} = \beta > 1$. 为了同时保持一阶和二阶相似性,SDNE的联合损失为

$$L_{mix} = L_{2nd} + \alpha L_{1st} + \nu L_{reg} \quad (20)$$

式中 L_{reg} 为正则化 L_2 范数,用于防止过拟合.

另一类图自编码器利用变分自编码器(variational autoencoders, VAE)^[23]实现图嵌入,变分自编码器是一种重要的生成模型,能够提高模型的泛化能力. VGAE^[24]首先将变分自编码器应用于图结构,其推理模型,即编码器,利用了一个2层的GCN^[6]结构,其表达式为

$$q(\mathbf{Z}|\mathbf{X}, \mathbf{A}) = \prod_{i=1}^N q(\mathbf{z}_i|\mathbf{X}, \mathbf{A}) \quad (21)$$

$$q(\mathbf{z}_i|\mathbf{X}, \mathbf{A}) = N(\mathbf{z}_i|\boldsymbol{\mu}_i, \text{diag}(\boldsymbol{\sigma}_i^2)) \quad (22)$$

式中: $\boldsymbol{\mu}$ 为编码器的均值矩阵; $\log(\boldsymbol{\sigma})$ 为方差矩阵;

\mathbf{X} 为特征矩阵; \mathbf{A} 为邻接矩阵; \mathbf{z}_i 为随机潜在变量. VGAE的生成函数,即解码器,由隐藏变量的内积得出,其表达式为

$$p(\mathbf{A}|\mathbf{H}) = \prod_{i,j=1}^N \sigma(\mathbf{h}_i \mathbf{h}_j^T) \quad (23)$$

除VGAE外,使用变分自动编码器的图自编码器还包括RGVAE^[25]、DVNE^[26]、ARVGA^[27]等.

1.4 其他图神经网络

除图卷积网络和图注意力网络外,常用的图神经网络还包括门控图神经网络(gated graph neural networks, GGNN)和时空图神经网络(spatial-temporal graph neural networks, STGNN)等.

门控神经网络是对传统图神经网络架构的改进,通过将门控循环单元(gated recurrent unit, GRU)引入图神经网络,提高了模型在信息长期传播时的性能. Li等^[28]提出的门控图序列神经网络将门控循环单元引入到信息传播过程,将迭代循环控制在固定的步数,不再需要进行参数约束以保证收敛. 除该模型外,门控图神经网络模型还包括GAAN^[29]等.

时空图(spatio-temporal graph)^[30]是一种刻画实体间在空间与时间维度上交互的图结构,其拥有节点、时空边(spatio-temporal edge)和时间边(temporal edge)3个基本要素,高维特征空间中的特征矩阵会随时间而变化. 时空图神经网络能够学习时空图中的隐藏模式,同时获取图结构中时间域和空间域的特征信息. 时空图神经网络可以被分为基于循环神经网络(recurrent neural network, RNN)的方法和基于卷积神经网络(convolutional neural networks, CNN)的方法. 基于RNN的STGNN通过图卷积捕获时空相关性,如文献[31-32]. 基于CNN的STGNN相比基于RNN的方法,以非递归的方式处理时空图,能够进行并行计算且可以避免梯度爆炸或梯度消失问题,如CGCN^[33].

2 图神经网络在通信网络领域应用

上述图神经网络方法具有处理复杂通信网络问题的能力,已经被应用到网络功能虚拟化、无线网络资源分配、网络建模与性能分析等方面. 已有研究成果的应用领域与实现方法如表3所示.

表3 图神经网络在通信网络领域应用总结
Table 3 Summary of GNN in communication networks

文献	输出特征	应用领域	GNN 模型	神经网络	学习方法
Mujumbi 等 ^[34]	VNF 资源需求预测	流量预测	基本 GNN	FF	监督学习
Jaliodia 等 ^[35]	VNF 资源需求预测	流量预测	基本 GNN	FF	强化学习
Liu 等 ^[36]	VNF 资源需求预测	SFC 建立	基本 GNN	FF	监督学习
Sun 等 ^[37-38]	迁移后节点间流量图	流量迁移	GN	RNN、FF	强化学习
Heo 等 ^[39]	节点的概率分布	SFC 建立	GGNN	GRU、FF	强化学习
Kim 等 ^[40-41]	VNF 实例数	SFC 建立	基本 GNN	FF	强化学习
Sun 等 ^[42]	节点的概率分布	SFC 建立	GN	RNN、FF	强化学习
Habibi 等 ^[43]	重构特征矩阵	VNE 节点分类	GAE	FF	监督学习
Yan 等 ^[44]	节点映射的概率分布	VNE 节点映射	GCN	CNN、FF	强化学习
Shen 等 ^[45-46]	基站发射功率	无线功率控制	GCN	CNN、FF	监督学习
Guo 等 ^[47]	设备发射功率	无线连接调度	GAE	FF	监督学习
Zhao 等 ^[49]	信道选择向量	信道选择	GCN	CNN、FF	强化学习
Nakashima 等 ^[50]	接入点选择的信道	信道分配	GCN	CNN、FF	强化学习
Yan 等 ^[51]	链路概率图	无线拓扑控制	GCN	CNN、FF	监督学习
Eisen 等 ^[52]	多种输出	无线资源分配	REGNN	CNN	监督学习
Rusek 等 ^[53]	延迟、抖动、丢包	评价指标预测	MPNN	RNN、FF	监督学习
Li 等 ^[54]	网络流完成时间	完成时间预测	GN	FF	监督学习
Geyer 等 ^[55-56]	节点分类	网络演算	GGNN	GRU、FF	监督学习
Almasan 等 ^[57]	Q 学习的 Q 值	路径选择	MPNN	RNN、FF	强化学习
Zhu 等 ^[58]	吞吐量	多路径 TCP 选择	MPNN	RNN、FF	监督学习
Geyer 等 ^[59]	路由器端口	路由策略生成	GQNN	GRU、FF	监督学习

2.1 软件定义网络和网络功能虚拟化

软件定义网络 (software defined network, SDN) 和网络功能虚拟化 (network functions virtualization, NFV) 是近年来通信网络领域的研究热点, SDN 将网络的控制平面与转发平面分离, 通过中央控制器, 获得整个网络的拓扑结构和资源信息. NFV 借助虚拟化技术将网络功能从传统硬件设备中剥离出来, 提升了网络配置的灵活性.

GNN 可以用于解决 SDN 和 NFV 中需要探索图结构的问题, 例如动态资源分配、服务功能链 (service function chain, SFC) 建立和虚拟网络映射 (virtual network embedding, VNE).

2.1.1 SFC 动态资源分配

图神经网络于 2017 年首次用于 NFV 动态资源分配. Mujumbi 等^[34] 提出一种用于 SFC 流量预测的

监督学习方法. 该方法利用 GNN 将输入的历史流量映射为输出的预测流量, 并据此调节资源分配. 此模型的图神经网络训练 2 个函数: 点的转移函数和输出函数. 节点 n 的转移函数输入 n 的特征、所有邻接边特征、所有相邻节点特征及状态, 输出节点 n 的状态. 输出函数根据点的状态和特征计算节点输出.

Jaliodia 等^[35] 使用与文献[34] 同样的图神经网络, 但采用异步深度强化学习 (deep reinforcement learning, DRL) 模型解决 SFC 资源需求预测问题. 此类问题的本质是传统的基于机器学习的回归模型.

Liu 等^[36] 利用 GNN 预测 NFV 资源需求, 从而获得请求即将到来的预先信息, 并提高基于深度强化学习的 SFC 重构算法的有效性.

网络流量迁移也是动态资源配置的一个重要分支问题. Sun 等^[37-38]提出一种利用 GNN 和深度强化学习实现 NFV 网络流量迁移的方法,该方法将输入的网络拓扑结构映射为输出的迁移后网络拓扑结构,用于实现网络流量的扩增、缩减和负载均衡.

SFC 动态资源分配问题的本质是拓扑结构的变换,优化目标为端到端总延迟,且不存在复杂限制条件,易于利用 GNN 求解.

2.1.2 服务功能链建立

不同于 SFC 动态资源分配, SFC 建立问题需要根据输入的网络请求,通过算法按次序求得输出的网络拓扑结构. SFC 建立问题包含虚拟网络功能(virtual network function, VNF)的放置和链接的建立. 解决该问题通常需要借助自然语言处理中的序列模型.

Heo 等^[39]提出了一种针对该问题的图神经网络序列模型. 该模型由编码器和解码器组成,编码器用于表示网络的拓扑结构,解码器用于计算相邻节点的概率和执行 VNF 的概率. 在编码器中,拓扑结构由标记矩阵和邻接矩阵表示. 标记矩阵用于标记节点可接收的 VNF 类型,邻接矩阵用于表示延迟. 编码器使用 GGNN 将拓扑结构进行编码,解码器每次选择一个节点直到完成整个路径选择. 解码器的状态编码包含完整 VNF 请求、下一个需执行的 VNF 和当前所在物理节点. 解码器输出选择下一个节点的概率以及是否要在此节点上执行 VNF.

Kim 等^[40-41]利用 GNN 学习代表物理网络的图结构中节点的状态嵌入,再通过附加输出层对节点上的 VNF 类型和最优 VNF 实例数进行预测,能够得到更具体的 VNF 管理策略,该模型同时适用于物理网络动态变化的场景.

Sun 等^[42]提出了与文献[39-41]相似的强化学习模型用于解决 VNF 放置问题,区别在于使用 GNN 抽取节点和链接资源.

上述 SFC 建立方法关注于 VNF 放置问题. 此类方法借助于 GNN 可用于图节点分类的特性,但并未涉及链接建立,因此具有一定的局限性.

2.1.3 虚拟网络映射

虚拟网络映射问题类似 SFC 建立问题,但网络请求、资源限制条件更为复杂. VNE 问题分为节点映射和链接映射. 已有的 GNN 解决 VNE 问题的方法主要集中在节点映射方面.

Habibi 等^[43]提出一种利用 GAE 辅助 VNE 物理节点分类的方法. 该模型的输入是邻接矩阵和资

源特征矩阵,通过图神经网络训练出可以重建网络拓扑结构的监督学习模型.

Yan 等^[44]提出利用 GCN 结合深度强化学习完成节点分类任务. 该方法采用 actor-critic 强化学习,其中 GCN 用于抽取物理节点特征,从物理节点抽取出的特征与虚拟网络请求通过前馈神经网络(feed forward neural networks, FF)融合,最终得到映射节点的概率分布.

事实上,针对大规模复杂网络的 SFC 建立和 VNE 问题,考虑到节点和链接资源以及优化目标的复杂性,图神经网络是提取拓扑信息的有力工具,具有提供更快速、更优化的解的潜力.

2.2 无线资源分配

随着 5G、物联网、边缘计算等技术的快速发展与应用,无线网络的资源分配问题变得越来越重要. 无线接入网可以抽象为图拓扑结构,其中用户和基站为点,无线信道为链接. 用户、基站、无线信道需要通力协作,通过资源的有效配置,在不同应用场景下实现多样化的优化目标,提升网络资源的利用率.

2.2.1 功率控制

无线功率控制问题是如何确定各发送端的发射功率,使网络达到整体最优的信噪比的问题. 其基本模型是一个带有限制条件的优化问题,优化目标是信号与干扰加噪声比的加权和,限制条件是基站或设备的发射功率.

Shen 等^[45]提出将多用户无线信道用一个完全图来表示,并利用 GNN 解决功率控制问题. 该完全图的节点是一个收发对,节点特征包含直接信道状态和权重;图的链接是干扰信道,链接特征为干扰信道状态. 该方法通过 GCN 训练转移函数和输出函数,用于输出每个发射器最优化的发射功率.

考虑到实际问题中基站和用户的情况,Guo 等^[47]提出一种解决异构网络功率控制问题的方法. 该模型的节点包含基站和用户 2 种异构节点,异构节点采用不同的转移函数,并用参数共享得到输出结果.

无线功率控制问题并不是一个直观的图结构问题,因此需要通过建模将问题转化为图结构,随后利用 GNN 模型求解.

2.2.2 其他资源分配问题

无线功率控制问题的 GNN 模型可以被扩展,用以解决其他无线资源分配问题,例如波束成形^[46]、设备间通信^[48]、信道选择^[49-50]、拓扑控制^[51]等.

Lee 等^[48]提出一种基于图嵌入解决设备间通信

无线连接调度问题的方法. 该问题的图抽象模型与文献[45]相同, 区别在于优化问题的变量是二元的, 即收发对是否开启. 该方法采用 Structure2Vec 图嵌入模型将图结构转化为低维向量, 并通过 FF 解决二元分类问题从而得到输出结果.

考虑到信道状态难以获得的情况, Zhao 等^[49] 提出利用强化学习结合 GCN 解决认知无线电中信道选择和功率控制问题. 智能体观测网络状态, 通过 GCN 生成动作, 执行动作后根据网络的反馈学习优化 GCN 参数.

Nakashima 等^[50] 利用基于深度强化学习的 GCN 提取具有拓扑信息的信道向量的特征, 进而生成信道部署策略. 该方法能够在密集部署的无线局域网中进行信道分配, 从而提高系统吞吐量.

Yan 等^[51] 提出了一种基于 GCN 的节能拓扑控制算法, 利用 GCN 模仿最大生成树算法, 进行链路预测, 并根据概率图向拓扑中引入新的边, 优化了 5G 和 B5G 环境下无线自组织物联网生命周期.

Eisen 等^[52] 提出一种解决无线资源分配的统一模型: 随机边图神经网络 (random edge graph neural networks, REGNN). REGNN 和已有方法相比具有可扩展性和可转化性, 可以用于解决功率控制、带有多用户请求的多接入以及随机接入无线控制系统等问题.

GNN 解决无线资源分配问题的基本原理是抽取并学习节点特征、链接特征和拓扑结构, 在每个节点上输出一个最优化数值.

2.3 网络建模与性能分析

网络建模与性能分析是实现高效通信网络的一个基础问题. 如上文所述, GNN 可以用于有线、无线等网络的资源优化, 网络中的各种资源通过优化策略被分配到设备上, 因此急需一个高效的网络模型用以评价资源分配的好坏.

2.3.1 网络性能指标分析

网络性能指标分析需要根据现有网络的拓扑结构和资源状态, 通过算法计算出评价当前网络的一个指标. 该指标可以是简单的端到端延迟, 也可以是针对特定情况的复杂指标.

Rusek 等^[53] 提出 RouteNet, 利用 GNN 精确评估网络路径的端到端延迟与丢包. RouteNet 将网络拓扑结构、流量矩阵和端到端路径作为输入, 根据网络状态输出性能评价指标 (延迟、抖动、丢包等). RouteNet 内部包含一个多层的信息传递神经网络, 采用 RNN 作为转移函数, 将链接和路径信息压缩到

隐藏状态向量, 最终通过输出函数得到路径的评价指标值. RouteNet 被用于以下 2 种示例问题: 1) 基于网络延迟丢包的路由优化; 2) 有预算限制的网络拓扑升级.

针对数据中心网络, Li 等^[54] 提出一种利用 GNN 推断网络流完成时间的方法. 每一个网络流作为 GNN 的输入, 由 5 个特征组成: 原地址、目标地址、网络流大小、起始时间、服务类型. 该方法采用基于 GNN 的监督学习, 神经网络结构由编码器、核心、解码器构成. 编码器将节点和连接特征编码; 核心执行多层信息传递; 解码器输出完成时间特征.

网络演算是一种基于非线性代数的确定性排队理论, 目前已广泛应用于网络建模与性能分析, 特别是为计算延迟和积压等端到端性能参数的确界提供了有效工具. Geyer 等^[55-56] 提出利用 GNN 构建网络演算模型, 用于推断网络延迟、辅助判定多协议标签交换 (multi-protocol label switching, MPLS) 配置合理性.

2.3.2 路由选择与评价

路由选择是通信网络领域古老且核心的优化问题. 人工智能算法已经被用于网络的路由选择. 在光传输网络中, Almasan 等^[57] 采用基于 Q 学习的 DRL 推断端到端路径. 为提升算法效果, GNN 代替传统神经网络, 被用于计算 Q 学习中的 Q 值.

在多径路由中, Zhu 等^[58] 利用 RouteNet 模型, 根据给定的网络拓扑和多径路由, 预测多径传输控制协议 (transmission control protocol, TCP) 吞吐量, 并以此指导 TCP 路径选择.

值得注意的是, 为了减小动作数据集空间, 以上路由选择方法^[57-58], 均将备选路径限定在 K 条最短路径范围内, 因此限制了方法的应用场景与拓展性. 事实上, 随着通信网络复杂性的增加, 对最优路由策略的要求也不断提高, GNN 的拓扑信息感知能力允许算法根据流量分布动态地调整路由策略.

Geyer 等^[59] 提出利用 GNN 学习分布式路由算法. 该方法将路由器接口抽象为拓扑结构中的点, 并使用 GNN 训练出隐藏节点信息, 使得每一个节点都有对于图拓扑结构的本地表示. 该方法是少有的面向分布式的 GNN 应用.

3 结论与展望

1) 现有通信网络领域应用主要采用 GN、GCN、MPNN 模型, 鲜有使用 GAE 模型, 没有使用 GAT 模型. 现有应用多数将 FF、RNN、CNN 等作为聚合函

数,传递节点与拓扑信息并输出预测值,应用范围有限. GN、GCN、MPNN 由于其自身局限性,难以解决复杂的通信网络问题.

2) 学习方法主要分为监督学习和强化学习. 监督学习多用于流量/资源/指标预测,节点分类等问题;强化学习多用于路径选择、拓扑变换/映射等问题.

3) 现有应用目标主要集中在节点的任务. 输出特征多为节点的特征或网络的整体指标,很少用于链接任务.

4) 现有应用几乎都基于集中式学习,需要得到所有节点的信息,才能进行学习.

通过以上结论可知,图神经网络在通信网络领域应用仍处在初级阶段. 因此,得出如下值得探索的未来研究方向:

1) 充分利用 GAE、GAT 模型的优势,挖掘其解决网络问题的能力. 例如,GAT 模型具有易于处理动态图和有向图的特性,可用于解决复杂网络拓扑结构问题.

2) 通信网络中的众多资源优化问题通常很难获得精确的标签,因此强化学习与图神经网络结合作为未来的重要应用方向,具有广阔前景.

3) 在通信网络中存在大量链接预测、拓扑生成等链接任务,需要开发合适的算法模型解决此类问题.

4) 在边缘计算等场景中,分布式机器学习与图神经网络结合是值得探索的研究方向.

参考文献:

[1] 李晓理, 张博, 王康, 等. 人工智能的发展及应用 [J]. 北京工业大学学报, 2020, 46(6): 583-90.
LI X L, ZHANG B, WANG K, et al. Development and application of artificial intelligence [J]. Journal of Beijing University of Technology, 2020, 46(6): 583-590. (in Chinese)

[2] GORI M, MONFARDINI G, SCARSELLI F. A new model for learning in graph domains [C] // 2005 IEEE International Joint Conference on Neural Networks. Piscataway: IEEE, 2005: 729-34.

[3] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model [J]. IEEE Transactions on Neural Networks, 2008, 20: 61-80.

[4] VESSELINOVA N, STEINERT R, PEREZ-RAMIREZ D F, et al. Learning combinatorial optimization on graphs: a survey with applications to networking [J]. ArXiv Preprint

ArXiv, 2020: 200511081.

[5] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and locally connected networks on graphs [J]. ArXiv Preprint ArXiv, 2013: 13126203.

[6] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks [J]. ArXiv Preprint ArXiv, 2016: 160902907.

[7] LI R, WANG S, ZHU F, et al. Adaptive graph convolutional neural networks [J]. ArXiv Preprint ArXiv, 2018: 180103226.

[8] LEVIE R, MONTI F, BRESSON X, et al. Cayleynets: graph convolutional neural networks with complex rational spectral filters [J]. IEEE Transactions on Signal Processing, 2018, 67(1): 97-109.

[9] ZHANG X, LIU H, LI Q, et al. Attributed graph clustering via adaptive graph convolution [J]. ArXiv Preprint ArXiv, 2019: 190601210.

[10] MICHELI A. Neural network for graphs: a contextual constructive approach [J]. IEEE Transactions on Neural Networks, 2009, 20: 498-511.

[11] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for quantum chemistry [J]. ArXiv Preprint ArXiv, 2017: 170401212.

[12] NIEPERT M, AHMED M, KUTZKOV K. Learning convolutional neural networks for graphs [C] // International Conference on Machine Learning. Cambridge: JMLR, 2016: 2014-23.

[13] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs [C] // Advances in Neural Information Processing Systems. New York: Curran Associates, 2017: 1024-34.

[14] ATWOOD J, TOWSLEY D. Diffusion-convolutional neural networks [C] // Advances in Neural Information Processing Systems. New York: Curran Associates, 2016: 1993-2001.

[15] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. ArXiv Preprint ArXiv, 2017: 171010903.

[16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Advances in Neural Information Processing Systems. New York: Curran Associates, 2017: 5998-6008.

[17] WANG X, JI H, SHI C, et al. Heterogeneous graph attention network [C] // The World Wide Web Conference. New York: ACM, 2019: 2022-32.

[18] YANG S, LI G, YU Y. Dynamic graph attention for referring expression comprehension [C] // Proceedings of the IEEE International Conference on Computer Vision.

- Piscataway: IEEE, 2019: 4644-4653.
- [19] PEROZZI B, AL-RFOU R, SKIENA S. Deepwalk: online learning of social representations [C] // Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2014: 701-710.
- [20] GROVER A, LESKOVEC J. Node2vec: scalable feature learning for networks [C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 855-864.
- [21] TIAN F, GAO B, CUI Q, et al. Learning deep representations for graph clustering [C] // AAAI Conference. Menlo Park: AAAI, 2014: 1293-1299.
- [22] WANG D, CUI P, ZHU W. Structural deep network embedding [C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 1225-1234.
- [23] KINGMA D P, WELING M. Auto-encoding variational bayes[J]. ArXiv Preprint ArXiv, 2013: 13126114.
- [24] KIPF T N, WELING M. Variational graph auto-encoders[J]. ArXiv Preprint ArXiv, 2016: 161107308.
- [25] MA T, CHEN J, XIAO C. Constrained generation of semantically valid graphs via regularizing variational autoencoders [C] // Advances in Neural Information Processing Systems. New York: Curran Associates, 2018: 7113-7124.
- [26] ZHU D, CUI P, WANG D, et al. Deep variational network embedding in wasserstein space [C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2018: 2827-2836.
- [27] PAN S, HU R, LONG G, et al. Adversarially regularized graph autoencoder for graph embedding [J]. ArXiv Preprint ArXiv, 2018: 180204407.
- [28] LI Y, TARLOW D, BROCKSCHMIDT M, et al. Gated graph sequence neural networks [J]. ArXiv Preprint ArXiv, 2015: 151105493.
- [29] ZHANG J, SHI X, XIE J, et al. Gaan: gated attention networks for learning on large and spatiotemporal graphs [J]. ArXiv Preprint ArXiv, 2018: 180307294.
- [30] JAIN A, ZAMIR A R, SAVARESE S, et al. Structural-rnn: deep learning on spatio-temporal graphs [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 5308-5317.
- [31] LI Y, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting [J]. ArXiv Preprint ArXiv, 2017: 170701926.
- [32] SEO Y, DEFFERRARD M, VANDERGHEYNST P, et al. Structured sequence modeling with graph convolutional recurrent networks [C] // International Conference on Neural Information Processing. Berlin: Springer, 2018: 362-73.
- [33] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [J]. ArXiv Preprint ArXiv, 2017: 170904875.
- [34] MIJUMBI R, HASIJA S, DAVY S, et al. Topology-aware prediction of virtual network function resource requirements [J]. IEEE Transactions on Network and Service Management, 2017, 14: 106-120.
- [35] JALODIA N, HENNA S, DAVY A. Deep reinforcement learning for topology-aware VNF resource prediction in NFV environments [C] // 2019 IEEE Conference on Network Function Virtualization and Software Defined Networks. Piscataway: IEEE, 2019: 1-5.
- [36] LIU Y, LU Y, LI X, et al. On dynamic service function chain reconfiguration in IoT networks [J]. IEEE Internet of Things Journal, 2020, 7: 10969-10984.
- [37] SUN P, LAN J, GUO Z, et al. DeepMigration: flow migration for NFV with graph-based deep reinforcement learning [C] // 2020 IEEE International Conference on Communications. Piscataway: IEEE, 2020: 1-6.
- [38] SUN P, LAN J, LI J, et al. Efficient flow migration for NFV with graph-aware deep reinforcement learning [J]. Computer Networks, 2020, 183: 107575.
- [39] HEO D, LANGE S, KIM H G, et al. Graph neural network based service function chaining for automatic network control [C] // 2020 21st Asia-Pacific Network Operations and Management Symposium. Piscataway: IEEE, 2020: 7-12.
- [40] KIM H G, PARK S, HEO D, et al. Graph neural network-based virtual network function deployment prediction [C] // 2020 16th International Conference on Network and Service Management. Piscataway: IEEE, 2020: 1-7.
- [41] KIM H G, PARK S, LANGE S, et al. Graph neural network-based virtual network function management [C] // 2020 21st Asia-Pacific Network Operations and Management Symposium. Piscataway: IEEE, 2020: 13-18.
- [42] SUN P, LAN J, LI J, et al. Combining deep reinforcement learning with graph neural networks for optimal VNF placement [J]. IEEE Communications Letters, 2020(99): 1.

- [43] HABIBI F, DOLATI M, KHONSARI A, et al. Accelerating virtual network embedding with graph neural networks [C] // 2020 16th International Conference on Network and Service Management. Piscataway: IEEE, 2020: 1-9.
- [44] YAN Z, GE J, WU Y, et al. Automatic virtual network embedding: a deep reinforcement learning approach with graph convolutional networks [J]. IEEE Journal on Selected Areas in Communications, 2020, 38: 1040-1057.
- [45] SHEN Y, SHI Y, ZHANG J, et al. A graph neural network approach for scalable wireless power control [C] // 2019 IEEE Globecom Workshops. Piscataway: IEEE, 2019: 1-6.
- [46] SHEN Y, SHI Y, ZHANG J, et al. Graph neural networks for scalable radio resource management: architecture design and theoretical analysis [J]. IEEE Journal on Selected Areas in Communications, 2020, 39 (1): 101-115.
- [47] GUO J, YANG C. Learning power control for cellular systems with heterogeneous graph neural network [J]. ArXiv Preprint ArXiv, 2020: 201103164.
- [48] LEE M, YU G, LI G Y. Graph embedding based wireless link scheduling with few training samples [J]. ArXiv Preprint ArXiv, 2019: 190602871.
- [49] ZHAO D, QIN H, SONG B, et al. A graph convolutional network-based deep reinforcement learning approach for resource allocation in a cognitive radio network [J]. Sensors, 2020, 20: 5216.
- [50] NAKASHIMA K, KAMIYA S, OHTSU K, et al. Deep reinforcement learning-based channel allocation for wireless lans with graph convolutional networks [J]. IEEE Access, 2020, 8: 31823-31834.
- [51] YAN P, CHOUDHURY S, AL-TURJMAN F, et al. An energy-efficient topology control algorithm for optimizing the lifetime of wireless ad-hoc IoT networks in 5G and B5G [J]. Computer Communications, 2020, 159: 83-96.
- [52] EISEN M, RIBEIRO A R. Optimal wireless resource allocation with random edge graph neural networks [J]. IEEE Transactions on Signal Processing, 2020, 68: 2977-2991.
- [53] RUSEK K, SUÁREZ-VARELA J, ALMASAN P, et al. RouteNet: leveraging graph neural networks for network modeling and optimization in SDN [J]. IEEE Journal on Selected Areas in Communications, 2020, 38: 2260-2270.
- [54] LI J, SUN P, HU Y. Traffic modeling and optimization in datacenters with graph neural network [J]. Computer Networks, 2020, 181: 107528.
- [55] GEYER F, SCHMID S. DeepMPLS: fast analysis of MPLS configurations using deep learning [C] // 2019 IFIP Networking Conference. Piscataway: IEEE, 2019: 1-9.
- [56] GEYER F, BONDORF S. DeepTMA: predicting effective contention models for network calculus using graph neural networks [C] // IEEE INFOCOM 2019-IEEE Conference on Computer Communications. Piscataway: IEEE, 2019: 1009-1017.
- [57] ALMASAN P, SUÁREZ-VARELA J, BADIA-SAMPERA A, et al. Deep reinforcement learning meets graph neural networks: an optical network routing use case [J]. ArXiv Preprint ArXiv, 2019: 13126114.
- [58] ZHU T, CHEN X, CHEN L, et al. GCLR: GNN-based cross layer optimization for multipath TCP by routing [J]. IEEE Access, 2020, 8: 17060-17070.
- [59] GEYER F, CARLE G. Learning and generating distributed routing protocols using graph-based deep learning [C] // Proceedings of the 2018 Workshop on Big Data Analytics and Machine Learning for Data Communication Networks. New York: ACM, 2018: 40-45.

(责任编辑 杨开英)