



研究与开发

## 基于图神经网络的网络性能智能预测

李奕江<sup>1</sup>, 叶会标<sup>2</sup>, 谢仁华<sup>1</sup>, 楼佳丽<sup>1</sup>, 庄丹娜<sup>1</sup>, 李传煌<sup>1</sup>

(1. 浙江工商大学信息与电子工程学院(萨塞克斯人工智能学院), 浙江 杭州 310018;

2. 中国电信股份有限公司浙江分公司, 浙江 杭州 310020)

**摘要:** 传统网络性能预测技术存在网络状态获取不够全面及网络性能评估准确性欠佳等问题, 利用图神经网络学习推理网络关系数据的特点, 结合捕获的网络全局信息, 提出了一种基于图神经网络的网络性能智能预测方法。通过网络系统抽象及网络性能建模, 将复杂的网络信息转化为形式化的图数据进行描述, 利用图空域卷积处理图网络节点的消息传递过程, 实现网络信息之间的关系推理, 研究了实现网络性能预测的图神经网络模型, 提出了一种能处理流量矩阵、网络拓扑、路由策略、节点配置的图神经网络体系结构, 最后通过实验论证了模型能更好地实现包括时延、抖动和丢包率的网络性能的准确预测。

**关键词:** 图神经网络; 网络性能预测; 网络建模; 网络分析

**中图分类号:** TP393

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-0801.2022062

## Intelligent prediction method of network performance based on graph neural network

LI Yijiang<sup>1</sup>, YE Huibiao<sup>2</sup>, XIE Renhua<sup>1</sup>, LOU Jiali<sup>1</sup>, ZHUANG Danna<sup>1</sup>, LI Chuanhuang<sup>1</sup>

1. School of Information and Electronic Engineering (Sussex Artificial Intelligence Institute),  
Zhejiang Gongshang University, Hangzhou 310018, China

2. Zhejiang Branch of China Telecom Co., Ltd., Hangzhou 310020, China

**Abstract:** There are some problems in the traditional network performance prediction technology, such as incomplete network state acquisition and poor accuracy of network performance evaluation. Combined with the characteristics of graph neural network learning and reasoning network relational data and the captured global information of the network, on the basis of the current network performance prediction methods, an intelligent prediction method of network performance based on graph neural network was proposed. Aiming at the complex network information, through the research of network system abstraction and network performance modeling, the network information can be transformed into the graph space convolution was used to process the message passing process of graph network nodes to realize the rela-

收稿日期: 2021-09-23; 修回日期: 2022-02-05

通信作者: 李传煌, chuanhuang\_li@zjgsu.edu.cn

**基金项目:** 国家自然科学基金资助项目 (No.61871468); 国家自然科学基金国际合作与交流项目 (No.62111540270); 浙江省新型网络标准与应用技术重点实验室资助项目 (No.2013E10012); 浙江省重点研发计划基金资助项目 (No.2020C01079)

**Foundation Items:** The National Natural Science Foundation of China (No.61871468), Projects of International Cooperation and Exchanges NSFC (No. 62111540270), Zhejiang Key Laboratory of Network Standards and Applied Technology (No.2013E10012), Zhejiang Key Research and Development Program (No.2020C01079)



tionship reasoning between network information. The graph neural network model for network performance prediction was studied, and a graph neural network architecture which could deal with traffic matrix, network topology, routing strategy and node configuration was proposed. Finally, the experiments show that the model can better achieve accurate prediction of the network performance including delay, jitter and packet loss rate.

**Key words:** graph neural network, network performance prediction, network modeling, network analysis

## 0 引言

由于网络技术和计算机通信技术的迅猛发展,网络规模及其流量呈指数型增长,随之产生了各项复杂的网络业务,用户的需求存在增长趋势<sup>[1]</sup>。与此同时,许多具有实时性特点的新兴多媒体业务有着严格的时延、抖动、丢包率、吞吐量等服务质量(quality of service, QoS)参数要求。种种迹象表明,网络规模的日益庞大和结构的逐渐复杂,导致如今影响网络正常运行的因素不断增加,对网络性能进行实时智能预测的需求也越来越大。

现有的建模技术并不能实现对相关性能指标的准确估计,存在计算量庞大、模型构建理想化、网络信息考虑不全面等缺陷。对于网络性能分析方面的研究,国内外都做了大量的工作,基本分为测量法、解析法、仿真法。单纯利用软件、硬件工具来监测相关特性度量进行数据的简单运算<sup>[2-6]</sup>无法满足新型网络对测量分析的严格要求;利用数学理论方法描述性能特征和系统参数之间的关系,得到性能估计的参数解(如排队论、网络演算等)<sup>[7-11]</sup>建立的是理想模型,与实际复杂的网络有差异;抽象建立网络系统模型,结合数学描述和网络建模相关技术进行性能预测<sup>[12-15]</sup>是现在的趋势,但现有的智能仿真模型在更广泛应用的非欧几里得领域(如拥有复杂、不规则的连接信息的现实网络中)性能一般。图神经网络(graph neural network, GNN)<sup>[16-17]</sup>凭借其强大的对于复杂图数据处理能力而广受欢迎,过去在图神经网络研究领域涌现了可用于解决实际场景中预测和分类问题的各种模型<sup>[18-23]</sup>,在实际网络中,可以将网络映射成节点与边的关系,利用 GNN 从非结构化数

据中生成图,其输出不随节点的输入顺序为转移,边表示两个节点之间的依赖关系,并可以依赖周围的状态来更新节点的状态,这对网络的性能预测研究非常有实际意义。当前的 GNN 模型仍然存在着深层网络性能剧降、代表性节点难选取和可扩展性不够等问题,尤其在网络建模方面,仍缺少完整地考虑实际网络状态和运行的 GNN 模型。本文受消息传递神经网络(message passing neural network, MPNN)机制<sup>[24]</sup>和 RouteNet 模型<sup>[25]</sup>启发,分析已有的 GNN 模型并进行改进,构建综合考虑实际网络的 GNN 模型。

针对图神经网络在处理有依赖关系数据的优秀能力,结合软件定义网络(software defined network, SDN)可编程控制全局信息和已有的网络性能评估方法,本文提出一种基于图神经网络的网络性能智能预测方法。该方法利用深度学习中的图神经网络作为一种计算机网络建模技术构建估计网络性能的模型,输入网络基础抽象和网络流量特征,预测时延、丢包率等网络性能,通过得到的性能预测结果智能地调整网络行为,保持网络可靠的运行性能,为网络用户提供更优质的服务。

## 1 基于图神经网络的网络性能智能预测架构

本文所提出的网络性能智能预测架构,结合 SDN,通过控制器获取网络全局信息;在得到网络实时状态信息的情况下,通过网络建模实现网络性能的有效预测。其中,建模得到的网络模型是使用收集的或者网络模拟的数据专门训练的图神经网络来构建的,能够捕获网络要素的基本关系,例如,它可以对将流量负载、路由策略与网络性能联系起来的函数进行建模。

采用图网络的思路：首先构建一个“图”数据，通过理解图节点的基本关系含义，再进行具体的网络数据的学习。基于此，可以凭借已知的节点之间的消息传递性，推理下一个图结构中关系，为此将网络性能预测分为两个问题看待：网络系统抽象和网络性能建模。

实际物理网络可描述为网络的既定配置，包括网络拓扑、大小、网络节点配置、路由策略等，将这些基础网络结构及配置处理成一般图形的神经网络体系结构的输入，针对图结构进行训练和推理从而设计新的图神经网络模型，网络基础结构抽象化描述如图 1 所示。




图 1 网络基础结构抽象化描述

加之由随机分布（包括到达间和包长度过程）描述的流量，在不考虑物理误差等随机条件的情况下，将这些随机过程组合在网络中，网络系统抽象化描述如图 2 所示。




图 2 网络系统抽象化描述

由上述网络系统抽象，拟定输入流量矩阵、网络拓扑、路由策略、节点配置，图神经网络模型能通过将拓扑中的节点、链路与由路由方案产生的源一目的路径以及通过它们的流量进行建模来实现理解拓扑结构、路由和输入流量之间的复杂关系，对所有节点的端到端平均时延等其他性能进行估计，网络性能建模描述如图 3 所示。

结合上述两项描述，本文依赖于图神经网络模型的推理能力来有效地操作和推广以图表示的




图 3 网络性能建模描述

环境，希望能够在整个网络拓扑中传播任何路由方案，并抽象出当前网络状态的有意义的信息。在该种情况下，网络建模能够接收到不同路由方案、节点配置、拓扑变化和流量矩阵变化，并精确地预测网络的性能。将实时收集到的流量信息、网络状态、管理状态作为不同的网络配置，通过图神经网络可以进行相互之间的联系，从而根据当前的网络状态生成性能指标，基于图神经网络的网络性能智能预测架构如图 4 所示。




图 4 基于图神经网络的网络性能智能预测架构

## 2 基于网络全局信息的图神经网络模型

### 2.1 网络系统抽象

对于给定网络  $G$ ，依据图网络定义，定义描述拓扑连接关系  $T$  为：

$$T[i][j] = \begin{cases} 0, & i, j \text{ 不相连} \\ 1, & i, j \text{ 相连} \end{cases} \quad (1)$$

将拓扑中的任一节点  $i$  表示为  $v_i$ ，节点集合为  $V = \{v_i\}_{i=1:N^v}$ ，其中， $N^v$  表示节点数量，节点的特征表示为  $x_{v_i}$ ，该特征包含所选节点的所有信息参数，将节点上的信息进行编码；将拓扑中的任一链路表示为  $l_j$ ，链路集合为  $L = \{l_j\}_{j=1:N^l}$ ，其中， $N^l$  表示链路数量，链路的特征表示为  $x_{l_j}$ ，该特征包含了源节点和目标节点之间定向链路的信息参数。

对于路径  $P$  来说，若源节点  $v_{src} \in V$  以及目标节点  $v_{dst} \in V$ ，则总会找到从  $v_{src}$  到  $v_{dst}$  使得约束都满足的路径  $p_k \in P$ 。定义用表示连接每个  $v_{src} - v_{dst}$



对的所有路径的矩阵  $\mathbf{RM}$  来描述路由配置, 且  $v_i \in V$ ,  $l_j \in L$ , 对于  $p_k \in \mathbf{RM}, k=1:N^p$ , 可以用节点和链路表示该条路径, 即:

$$p_k = \{v_{k(\text{src})}, l_{k(0)}, v_{k(1)}, l_{k(1)} \dots v_{k(\text{dst})} | k=1:N^p\} \quad (2)$$

其中,  $v_{k(\text{src})}$  表示源节点,  $v_{k(\text{dst})}$  表示目标节点,  $N^p$  表示路径数量, 路径的特征可以表示为  $x_{p_k}$ 。

若将节点、链路和路径分别依据路由配置进行关系连接, 则对于节点和路径之间的关系来说, 针对固定网络拓扑和已知的路由配置, 某一节点状态与所有包含该节点的路径状态有关, 因此可将节点集合和路径集合重新定义为:

$$V = \{v_1, v_2, \dots, v_{N^v}\} = \left\{ \begin{bmatrix} p_{v_1 1} \\ p_{v_1 2} \\ \vdots \\ p_{v_1 N^{pN}} \end{bmatrix}, \begin{bmatrix} p_{v_2 1} \\ p_{v_2 2} \\ \vdots \\ p_{v_2 N^{pN}} \end{bmatrix}, \dots, \begin{bmatrix} p_{v_{N^v} 1} \\ p_{v_{N^v} 2} \\ \vdots \\ p_{v_{N^v} N^{pN}} \end{bmatrix} \right\} \quad (3)$$

$$P = \{p_1, p_2, \dots, p_{N^p}\} = \left\{ \begin{bmatrix} v_{p_1 1} \\ v_{p_1 2} \\ \vdots \\ v_{p_1 N^{pN}} \end{bmatrix}, \begin{bmatrix} v_{p_2 1} \\ v_{p_2 2} \\ \vdots \\ v_{p_2 N^{pN}} \end{bmatrix}, \dots, \begin{bmatrix} v_{p_{N^p} 1} \\ v_{p_{N^p} 2} \\ \vdots \\ v_{p_{N^p} N^{pN}} \end{bmatrix} \right\} \quad (4)$$

同理可得链路路与路径关系的各自集合表示:

$$L = \{l_1, l_2, \dots, l_{N^l}\} = \left\{ \begin{bmatrix} p_{l_1 1} \\ p_{l_1 2} \\ \vdots \\ p_{l_1 N^{pN}} \end{bmatrix}, \begin{bmatrix} p_{l_2 1} \\ p_{l_2 2} \\ \vdots \\ p_{l_2 N^{pN}} \end{bmatrix}, \dots, \begin{bmatrix} p_{l_{N^l} 1} \\ p_{l_{N^l} 2} \\ \vdots \\ p_{l_{N^l} N^{pN}} \end{bmatrix} \right\} \quad (5)$$

$$P = \{p_1, p_2, \dots, p_{N^p}\} = \left\{ \begin{bmatrix} l_{p_1 1} \\ l_{p_1 2} \\ \vdots \\ l_{p_1 N^{pN}} \end{bmatrix}, \begin{bmatrix} l_{p_2 1} \\ l_{p_2 2} \\ \vdots \\ l_{p_2 N^{pN}} \end{bmatrix}, \dots, \begin{bmatrix} l_{p_{N^p} 1} \\ l_{p_{N^p} 2} \\ \vdots \\ l_{p_{N^p} N^{pN}} \end{bmatrix} \right\} \quad (6)$$

在描述节点的特征  $x_{v_i}$  时, 节点所代表的转发设备具有不同的转发行为, 设定节点配置不同的队列调度策略和队列大小, 定义节点使用以下队列调度策略: 严格优先级 (strict priority, SP)、加权公平队列 (weighted fair queuing, WFQ) 和差额循环队列 (deficit round robin, DRR)。定义输入的流量为路径特征  $x_{p_k}$ , 链路带宽为链路特征  $x_{l_j}$ 。

## 2.2 性能模型构建

本文中目标构建的图神经网络模型基于一种表示空域卷积的形式化框架——MPNN, 这是一种由图网络 (graph network, GN)、门控循环单元 (gate recurrent unit, GRU)、图自编码器 (graph auto-encoder, GAE)、多层感知机 (multi-layer perceptron, MLP) 所构成的级联神经网络模型。依据前面对网络特性的分析, 本文将输入路径、链路、节点特征, 输出路径级别的隐藏状态信息, 评估路径级别的性能指标, 设计的图神经网络模型具体架构如图 5 所示。

首先收集 NSFNet 拓扑的网络状态视图和资源视图的数据集, 其中, 数据集包括相关性能信息、流量信息、路由信息和拓扑信息。模型依据




图 5 图神经网络模型架构

DataNetAPI 从数据集中提取所需的特征信息, 进行格式转化和数据预处理——将数据统一映射到  $[0,1]$  完成归一化。再使用 TensorFlow 框架中常用的二进制序列数据文件存储格式 TFRecords 来实现数据存储及读取。最后将其划分为训练集和测试集, 训练集用于调整网络的参数权重和偏差, 测试集用于测试训练后的网络模型来反映网络性能。给定图网络  $G$ , 根据路由策略 RM, 将节点、链路和路径特征  $(x_v, x_l, x_p)$  作为输入, 得到节点、链路和路径的初始状态集合  $(h_v^0, h_l^0, h_p^0)$ 。

具体地, 本文所设定的节点特征  $x_v$  为节点配置信息, 链路特征  $x_l$  为链路带宽, 路径特征  $x_p$  为路径级别输入流量, 其中节点配置信息见表 1。

表 1 节点配置信息

| 节点参数            | 描述                            |
|-----------------|-------------------------------|
| Level-QoS       | 支持的 QoS 类别数                   |
| Queue-Size      | 节点的每个输出队列的大小                  |
| Schedule-Policy | 服务 QoS 队列的策略                  |
| Schedule-Weight | 与每个 QoS 队列关联的权重列表 (仅 WFQ、DRR) |

对节点  $v$  进行空域卷积, 将连接节点的所有隐藏状态信息求和, 以更新当前节点的隐藏状态, 如式 (7) 所示。

$$h_v^{l+1} = \sum_{u \in ne[v]} h_u^l \quad (7)$$

根据节点、链路和路径的相互关系, 进行状态的更新:

$$h_{v_i} = f(h_{p_{i(1)}}, h_{p_{i(2)}}, \dots, h_{p_{i(N)}}), v_i \in p_k, k=1, 2, \dots, N^p \quad (8)$$

$$h_{l_j} = f(h_{p_{j(1)}}, h_{p_{j(2)}}, \dots, h_{p_{j(N)}}), l_j \in p_k, k=1, 2, \dots, N^p \quad (9)$$

$$h_{p_k} = g(h_{v_{k(0)}}, h_{l_{k(0)}}, h_{v_{k(1)}}, \dots, h_{l_{k(p_k)}}, h_{v_{k(p_k)}}), \quad (10)$$

$$v_i, l_j \in p_k, k=1, 2, \dots, N^p$$

其中,  $|p_k|$  表示路径  $p_k$  的标识符,  $f$  和  $g$  为隐藏状态的更新函数。节点、链路、路径的状态空域卷积过程如图 6 所示。




图 6 节点、链路、路径的状态空域卷积过程

根据 MPNN, 可以将空域卷积分为两个步骤: 消息传递和状态更新, 即对于第  $k$  条路径来说, 若要更新路径的隐藏信息, 对与该条路径相关联的节点和链路的状态信息进行消息交错传递; 再结合路径当前状态进行状态更新。

$$m_p^{t+1} = \sum_{v_i, l_j \in p_k} M_t(h_p^t, h_{v_i}^t, h_{l_j}^t) \quad (11)$$

$$h_p^{t+1} = U_t(h_p^t, m_p^{t+1}) \quad (12)$$

其中,  $M_t$  为消息函数,  $U_t$  为更新函数,  $t$  为空域卷积的运行步数。

循环该隐藏状态消息传递和状态更新过程, 使得每个目标实体的隐藏状态都波动很小, 图的信息流动总体趋于平稳, 节点、链路、路径的消息传递过程如图 7 所示。




图 7 节点、链路、路径的消息传递过程



这一消息传递过程由 GRU 完成。将当前输入特征  $x^t$  和节点传递下来的包含之前相关信息的隐藏状态  $h^{t-1}$  作为 GRU 的输入,通过式(11)~式(14)的计算过程,得到隐藏节点的输出  $y^t$  和传递给下一个隐藏状态  $h^t$ 。

$$u^t = \sigma(W^u x^t + U^u h^{t-1}) \quad (13)$$

$$r^t = \sigma(W^r x^t + U^r h^{t-1}) \quad (14)$$

$$\tilde{h}^t = \tanh(W x^t + r^t \odot U h^{t-1}) \quad (15)$$

$$y^t = u^t \odot h^{t-1} + (1 - u^t) \odot \tilde{h}^t \quad (16)$$

完成上述过程之后,在神经网络进行拟合前加入 GAE,以学习状态特征和输出特征的高效表示,提取更有用的信息,提高相关度。GAE 对输入的状态数据进行去噪以及为了可视化进行降维,可以在预测结果生成的前提下降低模型复杂度。

经过一系列的消息传递过程以及信息提取过程之后,对状态进行聚合并读出预测值,主要使用读出函数  $R$  计算整张图的特征向量,输出路径级特征的预测值。本文所构建的图神经网络由 MLP 来进行图读取,并在该图神经网络中引入 ReLU 激活函数,使其更加逼近非线性函数。

为了解决在模型在训练和预测的时候输入的数据分布的不同,采用计划采样机制<sup>[26]</sup>。该机制在模型训练的前期,以较大的概率输入目标序列的真实标签以改善因为模型训练初期预测不准确而难以收敛的现象,随着训练过程的进行,概率慢慢衰减。设已训练到了  $i$  个 mini-batch,则定义概率  $\epsilon_i$  为反向 sigmoid 衰减,以此增加模型容错能力。

$$\epsilon_i = \frac{k}{k + e^{\frac{i}{k}}} \quad (17)$$

由于在训练过程生成  $y_t$  时,输入的  $y_{t-1}$  为训练集标注序列的真值,而在预测的时候,输入的  $y'_{t-1}$  为在  $t-1$  步时生成的可能是预测正确也可能是预测错误的标签,若为错误标签,则会导致错误爆炸。计划采样机制在训练过程中,下一步的输入不完全使用真实的序列标签,以概率  $\epsilon_i$  选择真

实标签,以概率  $1 - \epsilon_i$  选择模型的自身输出,在训练的过程中,  $\epsilon_i$  大小如学习率一样可变,计划采样机制如图 8 所示。




图 8 计划采样机制

### 2.3 具体算法

本文设定 GNN 参数的配置为一个包含 GNN 基本参数（如隐藏层数、学习率等的配置文件）。在明确输入的数据集以及配置文件后,首先会对图神经网络进行训练学习:在前向传播中,调用全局更新函数  $f$  (前馈神经网络)  $T_n$  次,令  $h_v^{Tn}$  收敛,即节点的隐藏状态近似不动点解,通过局部输出函数  $g$  得到有监督信号节点的输出和计算出模型的损失,进而迭代式计算  $T_n$  次梯度,得到  $f$  与  $g$  对最初隐藏状态  $h_v^0$  的梯度,更新模型参数。在该过程中,需设置学习步数表示学习数量,指定前馈和反馈过程次数和终止条件,以此调整网络的权重和偏差达到稳定的状态,用于模型的拟合。最终,经过训练的图神经网络会用于测试集测试,评估最终模型的预测能力。

具体的基于图神经网络的网络性能智能预测算法如算法 1 所示。

**算法 1** 基于图神经网络的网络性能智能预测算法

输入  $x_p, x_l, x_v, R$

对于  $\forall p \in R$ , 进行路径初始化:  $h_p^0 \leftarrow [x_p, 0, \dots, 0]$

对于  $\forall l \in C$ , 进行链路初始化:  $h_l^0 \leftarrow$

$[x_l, 0, \dots, 0]$

对于  $\forall v \in N$ ，进行节点初始化： $h_v^0 \leftarrow [x_v, 0, \dots, 0]$

**for**  $t=1$  **do**

对于  $\forall p \in R$ ，有  $\mathbf{p}_k = \{v_{p_{src}}, l_{p_l}, v_{p_l}, \dots, v_{p_{dst}}\}$ , **do**

**if**  $l, v \in p$ , **do**

$h'_p \leftarrow GRU_t(h'_p, h'_l, h'_v)$

$\tilde{m}_{p,l,v}^{t+1} \leftarrow h'_p$

**end**

$h_p^{t+1} \leftarrow h'_p$

**end**

对于  $\forall l \in C$ ，有  $\mathbf{l}_j = \{p_{l_1}, p_{l_2}, \dots\}$ , **do**

$m_l^{t+1} \leftarrow \sum_{p:k \in p} \tilde{m}_{p,k}^{t+1}$

$h_l^{t+1} \leftarrow GRU_t(h_l^t, m_l^{t+1})$

**end**

对于  $\forall v \in N$ ，有  $\mathbf{l}_j = \{p_{l_1}, p_{l_2}, \dots\}$ , **do**

$m_v^{t+1} \leftarrow \sum_{p:k \in p} \tilde{m}_{p,k}^{t+1}$

$h_v^{t+1} \leftarrow GRU_t(h_v^t, m_v^{t+1})$

**end**

**end**

$h_p^t \leftarrow AE(h_p^t)$

输出  $\hat{y}_p \leftarrow F_p(h_p)$

### 3 实验仿真及分析

#### 3.1 实验环境与评估参数

本实验的硬件条件是搭载有核心型号为 GP102 的 NVIDIA TITAN XP 显卡的 GPU 服务器，软件环境是 64 位 Ubuntu16.04 操作系统，运算平台为 CUDA10.1，使用 TensorFlow 作为深度学习框架，编程语言是 Python。

本文通过 L2 损失——均方误差 (mean square error, MSE) 作为损失误差函数，通过均方根误差 (root mean square error, RMSE) 和皮尔森 (Pearson) 系数评估模型的表现，通过 L1 损失——

平均绝对误差 (mean absolute error, MAE) 对比评估本文提出的模型与 Rusek 等<sup>[25]</sup>提出的 RouteNet 模型的表现，通过 RMSE 指标来对比评估本文提出的模型与 Huang 等<sup>[27]</sup>提出的 DRL-TC 模型的表现，通过计算绝对平均距离 (mean absolute distance, MAD) 来表示预测结果的好坏。

#### 3.2 数据集获取及处理

首先收集 NSFNet 拓扑下的网络状态视图和资源视图的数据集，其中，数据集包括相关性能信息、流量信息、路由信息和拓扑信息。本文的数据集为开源数据集，由 Rusek 等<sup>[28]</sup>在知识定义网络 (knowledge defined network, KDN)<sup>[28]</sup>经 OMNet++ 仿真软件建模 NSFNet 拓扑所得。

此外本文选用 2021 ITU Artificial Intelligence / Machine Learning in 5G Challenge 官方所提供的数据集来进行模型泛化性测试，该开源数据集通过 OMNet++ 建模生成。与 NSFNet 数据集所包含的信息相同，该数据集也包含了相关的性能信息、流量信息、路由信息和拓扑信息等。

本文通过 DataNetAPI 对两个数据集分别进行所需要信息的提取，并进行数据预处理——归一化，让不同维度的特征在数值上有一定可比性，将数据统一映射到 [0,1] 上，以利于模型在训练过程中收敛。本文采用的 min-max 标准化： $X$  变量代表模型使用的预测变量， $Y$  变量代表目标值。则对序列  $\{x_1, x_2, \dots, x_n\}$  进行变换：

$$y_i = \frac{x_i - \min_{1 \leq j \leq n} \{x_j\}}{\max_{1 \leq j \leq n} \{x_j\} - \min_{1 \leq j \leq n} \{x_j\}} \quad (18)$$

#### 3.3 仿真实验及结果分析

本文采取 NSFNet 网络数据集样本 26 万个，对测试集，以大约 7:3 的比例使用选取训练集中不包含的剩余样本 112 000 个。则本文使用的数据集样本见表 2。



表2 系统训练集与测试集样本参数

| 数据集    | 类别  | 总计      |
|--------|-----|---------|
| NSFNet | 训练集 | 208 000 |
|        | 验证集 | 52 000  |
|        | 测试集 | 112 000 |

其中,数据集包含了不同的路由方案和各种流量强度的流量矩阵,在利用样本数据对模型进行训练的过程中,每次训练从数据集中随机选择80%的数据集作为图神经网络模型深度学习的训练数据集,在训练结束后,选取数据集集中的另外20%数据集作为模型验证集进行测试,在训练期间,为防止过拟合,添加L2正则化损失最小化,通过Tensorboard观察模型收敛状况,达到收敛状态后,保存最终模型。


设置自适应时刻估计(adaptive moment estimation, Adam)算法,初始学习率为0.001,批次大小为32、迭代次数为80 000、激活函数为ReLU,需要再实验进一步确认神经元数和层数。为此,本文设计4种图神经网络模型见表3。

表3 4种不同的图神经网络模型结构


| 超参数       | 模型名称 |      |      |      |
|-----------|------|------|------|------|
|           | GNN0 | GNN1 | GNN2 | GNN3 |
| GRU层数     | 2    | 2    | 2    | 2    |
| GRU神经元数   | 16   | 32   | 32   | 32   |
| MLP全连接层数  | 2    | 2    | 4    | 4    |
| MLP各层神经元数 | 256  | 256  | 128  | 256  |
| 激活函数      | ReLU | ReLU | ReLU | ReLU |

其中,变化的是在消息传递过程中依赖的GRU神经元数以及在读出阶段使用的MLP全连接层数和各层的神经元数。对比设计的4种GNN模型,改变GRU和MLP的神经元数和MLP全连接层数,对不同的GNN模型进行模型训练,GNN模型的L2损失对比如图9所示。


由图9可知,模型损失值收敛的速度几近趋同,GNN0和GNN2相较于GNN1和GNN3波动较大,预测效果相对较弱且不稳定。为了进一步




(a) GNN0模型的L2损失



(b) GNN1模型的L2损失



(c) GNN2模型的L2损失



(d) GNN3模型的L2损失

图9 GNN模型的L2损失对比

筛选表现最优的模型,分别对时延、抖动和丢包率3种网络性能进行模型训练,并将RMSE和Pearson系数作为评价参数。其中,RMSE越接近0,Pearson系数越接近1,模型表现越好。更明确地,本文分别对时延、抖动和丢包率3种网络性能进行模型训练,同样将RMSE和Pearson系数作为评价参数。以时延为例,得到了如图10、图11所示RMSE和Pearson系数对比。




图10 GNN模型的RMSE对比




图11 GNN模型的Pearson系数对比

图10和图11可看出,GNN1相较于其他3种GNN模型的RMSE平均值离0更近,同时,其Pearson系数平均值也离1更近。训练步数一样,GNN1模型的误差波动范围是最小的,因此,可以说明其预测的效果相较于其他模型来说较好且稳定,而随着训练步数增加,GNN1的收敛值也是最小的。

4种不同的图神经网络模型收敛后的各性能评估结果见表4。

从表4可以更清晰地看出:在硬件条件和数据集都相同的情况下,4种图神经网络模型都有比较优秀的收敛效果,其中GNN1在时延、抖动和

丢包率的RMSE系数比其他3种图神经网络都要更接近0,Pearson系数更接近1。

表4 四种不同的图神经网络模型性能评估结果比较

| 评价参数      |      | 模型名称  |        |       |       |
|-----------|------|-------|--------|-------|-------|
|           |      | GNN0  | GNN1   | GNN2  | GNN3  |
| RMSE      | 系数时延 | 0.044 | 0.028  | 0.049 | 0.031 |
|           | 抖动   | 0.033 | 0.027  | 0.035 | 0.031 |
|           | 丢包率  | 0.042 | 0.029  | 0.047 | 0.033 |
| Pearson系数 | 系数时延 | 0.997 | 0.9975 | 0.995 | 0.995 |
|           | 抖动   | 0.975 | 0.985  | 0.975 | 0.978 |
|           | 丢包率  | 0.997 | 0.998  | 0.995 | 0.996 |

综上所述,本文选取GNN1作为最终新构建的GNN模型,其GRU层数为2,神经元数为32以及MLP全连接层数为2,各层的神经元数为256。为了验证本文构建的GNN模型相较于RouteNet来说,由于扩展了体系结构和模型改进而评估更准确,为此进行实验对比,本文选取MAE作为度量模型的预测能力的评价参数,如图12所示。




图12 新构建的GNN模型与RouteNet模型的MAE对比

如图12所示,随着训练步数的增加,新构建的GNN模型与RouteNet相较而言,MAE函数曲线波动更小,且距0更近,因此预测效果更为优秀稳定。尤其是步数越多,差距越明显。经计算,在0~100 000步数范围中,新构建的GNN模型的MAE系数平均值大约为0.028 2,而RouteNet的MAE系数平均值大约为0.034 9,相比之下新构建的GNN模型降低了近19.20%的MAE指标。这都得益于模型的改进对于有用信息的提取更为



精准,使得训练时候的预测能力得到明显的提升。

为进一步验证本文新构建的 GNN 模型在网络性能预测能力上具有明显的优越性,再选取 RMSE 作为度量模型预测能力的评价参数,与 DRL-TC 模型进行实验对比。本研究将 800 个不同的随机网络流量矩阵按每组 100 个均分为 8 组,进行所述新构建 GNN 模型与 DRL-TC 模型的预测能力评估,对每组流量矩阵分别测试并计算得到相应的 RMSE 指标,如图 13 所示。




图 13 新构建的 GNN 模型与 DRL-TC 模型的 RMSE 对比

如图 13 所示,综合各个网络流量矩阵分组,从整体上看新构建的 GNN 模型与 DRL-TC 模型相比 RMSE 指标的函数曲线波动更小,且距 0 更近,可以得出其预测效果更为优秀稳定。经计算,在所选取的 8 组共 800 个随机流量矩阵中,新构建的 GNN 模型的 RMSE 系数平均值大约为 0.063 2,而 DRL-TC 的 RMSE 系数平均值大约为 0.082 5,相比之下新构建的 GNN 模型降低了近 23.39% 的 RMSE 指标,从而证明了本文新构建的 GNN 模型具有更为优秀的网络性能预测能力。

更进一步地,为了体现体系结构的扩展对性能评估的影响,先用 MAD 刻画新构建的 GNN 模型的预测结果,选取时延模型进行真实值与预测值的差值。使用 Python 中的 seaborn.regplot 线性回归模型拟合函数,将足量“真实值-预测值”数据对作为输入,进行拟合计算得到所需的回归

线;从而能够以横纵坐标分别表示真实值和预测值的离散点是否聚集在回归线上判断训练后的模型是否有良好的预测性能。

实际上,本文研究在进行性能评估时的理想回归模型为  $y = x + \varepsilon$ 。其中,  $x$  自变量为时延真实值 (true-delay),通过 NSFNet 数据集获取;  $y$  因变量为时延预测值 (prediction),通过新构建的 GNN 模型输出的网络性能预测值获取;而  $\varepsilon$  用来表征时延真实值与预测值之间的差值,最佳理想状态下应为趋近无穷小的量。若由上述步骤获取的回归线拟合为一元线性函数,则此时该函数经线性缩放变换可拟合为理想回归模型,从而证明所述新构建的 GNN 模型能够得到正确的网络性能预测结果。

新构建的 GNN 模型在时延预测上的结果如图 14 所示。




图 14 新构建的 GNN 模型在时延预测上的结果

由图 14 可知,经 GNN 模型预测的结果散点基本都聚集在回归线上,经计算其绝对平均距离 MAD 为 0.026 7,预测值与真实值基本重合,由此证实了新构建的模型在网络性能评估中的时延指标有突出表现。为了总体评估该模型在时延、抖动和丢包率中的预测性能以及与 RouteNet 作体系结构上的对比,本文采用累积分布函数 (cumulative distribution function, CDF) 对预测结果进行分析。

新构建的 GNN 模型与 RouteNet 模型网络性能预测的 CDF 对比如图 15 所示,对于 CDF 图像




图 15 新构建的 GNN 模型与 RouteNet 模型网络性能预测的 CDF 对比

来说, 以平均相对误差 (mean relative error, MRE)  $\varepsilon$  作为横坐标, 以预测的离散结果与实际的离散值的相对误差小于或等于  $\varepsilon$  的值的累积分布作为纵坐标, 即:

$$P\left(\frac{f-y}{y} < \varepsilon\right) \quad (19)$$

由于 CDF 为离散变量的和, 因此呈现的是梯形结构, 最终会达到 1, CDF 梯形线越集中到中心点位置, 则预测效果越优秀。首先对于新构建 GNN 模型来说, 由于本次采用的是经时延数据训练的模型, 因此可以看出实线部分中, 时延的预测效果要略好于抖动和丢包率, 在其他网络性能评估指标中同样具有良好的预测效果。由于模型的体系结构经过调整和改进, 综合考虑到了节点信息, 在新构建的包含节点配置的数据集下, 相对于虚线来说, 实线要明显更靠近中心线, 说明新构建的 GNN 模型的预测值与真实值的相对误差分布更接近于 0, 该模型在预测评估网络性能这一方面要比 RouteNet 更加精准。

进一步地, 为测试本文提出的 GNN 模型的跨数据集泛化效果, 选用 2021 年 ITU Artificial Intelligence/Machine Learning in 5G Challenge 所提供的数据集来进行实验。为了能够对模型的跨数据集泛化效果进行合理评估, 此处所采取的实验方案与基于 NSFNet 数据集进行测试时保持一致, 同样采

用 CDF 指标来对预测结果进行分析。

基于新数据集进行网络性能预测的 CDF 对比如图 16 所示, 从图 16 上可以看出, 基于该数据集的测试结果与基于 NSFNet 数据集的测试结果呈现相同的梯形结构。并且在时延、抖动和丢包率 3 项性能指标上, 相对于代表 RouteNet 的虚线来说, 代表新构建的 GNN 模型的实线同样要更靠近中心线, 这证明了其在新数据集上进行网络性能预测评估时, 同样有着更加精准的效果。由此可以得出, 本文所构建的 GNN 模型具有较好的跨数据集泛化效果。




图 16 基于新数据集进行网络性能预测的 CDF 对比

## 4 真实应用测试及分析

### 4.1 实验方案设计

为测试本文所提出的基于图神经网络的网络性能智能预测模型在真实环境中的性能效果, 将其应用于 SDN 路由优化中。模型基于 SDN 获取的网络实时状态信息, 预测得到网络性能参数, 能够实时调整网络行为, 完成路由策略的优化。

所述应用网络性能智能预测模型的 SDN 路由优化方案, 主要分为两个步骤: 第一步是从 SDN 数据平面获取真实输入数据, 应用网络模型预测特定配置的网络性能; 第二步是在 SDN 控制平面接收到网络状态的实时更新后, 结合预测网络性能信息与当前网络状态信息找到最优路由。该 SDN 路由优化方案具体如图 17 所示。




图 17 基于网络性能智能预测模型的 SDN 路由优化方案

同时, 本文将该路由优化的整体方案作为待评估策略, 选取深度确定性策略梯度 (deep deterministic policy gradient, DDPG) 算法进行策略性能测试评估。DDPG 是一个强大的针对连续行为的策略学习算法, 基于该算法以及行为-评判 (actor-critic, AC) 框架的策略评估架构如图 18 所示。




图 18 基于 AC 框架的 DDPG 算法策略评估架构

此外, 本实验使用基于 Dijkstra 算法的 ShortestPath 路由优化方案、基于 RouteNet 模型的路由优化方案等两种策略作为对照, 与基于本文研究所提出的网络性能智能预测模型的 SDN 路由优化方案进行性能对比。

#### 4.2 实验结果与分析

本研究评估了在 6 种不同的流量强度 (traffic intensity, TI) 场景下, 不同的路由优化策略所实现的性能, 并对每种 TI 各评估 100 个不同的网络流量矩阵。基于上述基础, 对 3 种不同的路由优化策略, 分别测试并计算得到 600 组数据, 再通过性能指标平均值的比对, 得出最佳的方案。

本实验中所关注的性能指标为时延、抖动一

时延比和丢包率。时延与丢包率越低, 则意味着经过对应路由优化策略优化之后的网络性能越佳; 而抖动由时延产生, 可表征前后两个时延值的差异, 时延一抖动比越低, 可以说明经对应路由优化策略优化后的网络状态越稳定。实际上, 当经优化后网络性能指标越佳, 网络状态越稳定, 在整体架构中其他部分完全一致的前提下, 可以证明优化策略中所使用的网络性能预测模型具有更佳效果。

上述 3 种优化策略在流量强度为 11~16 所得到的时延、抖动一时延比和丢包率对比情况如图 19、图 20 和图 21 所示, 各性能指标都用箱线图表示, 其中,  $x$  轴表示不同的流量强度,  $y$  轴分别表示时延、抖动一时延比和丢包率。




图 19 不同优化策略在不同流量强度下的时延对比

从图 19 中可以看到, 3 种策略中, 应用了本文研究所提出的网络性能智能预测模型的路由优化策略对应的时延最低, 且随着流量强度的上升, 与其余两种路由优化策略的差距愈加明显。

从图 20 中可以看到, 3 种策略中, 应用了本文研究所提出的网络性能智能预测模型的路由优化策略对应的抖动一时延比最低, 且随着流量强度的上升, 与其余两种路由优化策略的差距同样呈现愈加明显的趋势。

从图 21 中可以看到, 3 种策略中, 应用了本文研究所提出的网络性能智能预测模型的路由优化策略对应的丢包率是最低的。




图 20 不同优化策略在不同流量强度下的抖动/时延对比




图 21 不同优化策略在不同流量强度下的丢包率对比

结合以上实验结果,可以得到的结论是,在3种路由优化策略中,应用了本文研究所提出的网络性能智能预测模型的路由优化策略性能最佳,即证明了该模型的网络性能预测具有最佳效果。

该对比实验所使用的数据是通过SDN数据平面获取真实输入数据,即在真实环境下使用真实数据完成了模型预测性能指标的测试,验证了本文所提出的基于图神经网络的网络性能智能预测模型具有极佳的预测效果,要明显优于一般传统模型以及RouteNet模型等。

## 5 结束语

网络新兴业务的急剧增多带来了QoS的更严格要求,复杂的网络信息使得网络性能的分析面临着重大挑战,已提出的网络性能分析技术面对实际复杂多变的网络有着计算困难、与实际差

异巨大、考虑不全面等问题,为此如何综合考虑影响网络性能的各类因素,从而对复杂网络进行可靠的性能分析这一难题亟待解决。

本文在结合网络性能分析方法和图神经网络模型的基础上,将性能分析定为智能预测,提出了一种基于图神经网络的网络性能智能预测总体方案,并将该方案分为网络系统抽象和网络性能建模这两个问题分析并结合SDN控制组件的集中管制下可获取的网络信息和图网络的定义,将网络进行系统抽象并进行图数据描述,对原始网络数据进行了提取和处理,以节点、链路和路径的相互消息传递过程为主要设计理念,基于图神经网络空域卷积的框架,扩展了原图神经网络的体系结构并构建了多种不同结构的图神经网络模型。选取表现最佳的图神经网络模型并在仿真以及真实场景中进行了时延、抖动和丢包率等多种网络性能指标的实验评估,证明了该模型网络性能智能预测的有效性和优势。

在本文研究基础上,下一阶段将在模型中加入更多具有代表性的网络特征和性能特征,就实现多样化网络性能智能预测模型的应用场景方向开展进一步的研究工作。

## 参考文献:

- [1] 2020 年中国互联网发展趋势报告[EB]. 2020. Report on China's Internet Development Trend in 2020[EB]. 2020.
- [2] LIU L K, ZHANG H L, SHI J T, et al. I2P anonymous communication network measurement and analysis[C]// Smart Computing and Communication, 4th International Conference. Switzerland: Springer Cham, 2019:105-115.
- [3] CHEN Y, HU J Y, ZHAO H, et al. Measurement and analysis of the swarm social network with tens of millions of nodes[J]. IEEE Access, 2018: 1.
- [4] 戴冕, 程光, 周余阳. 软件定义网络的测量方法研究[J]. 软件学报, 2019(6):1853-1874. DAI M, CHENG G, ZHOU Y Y. Survey on measurement method in software-defined networking[J]. Journal of Software, 2019(6):1853-1874.



- [5] JIA S Y, LUCKIE M, HUFFAKER B, et al. Tracking the deployment of IPv6: topology, routing and performance[J]. *Computer Networks*, 2019 (165): 106947.
- [6] 马卫国, 郎为民, 张寅, 等. 虚拟化网络功能测量问题研究[J]. *电信快报*, 2020 (3): 1-5.  
MA W G, LANG W M, ZHANG Y, et al. Research on function measurement of virtual network[J]. *Telecommunications Information*, 2020(3): 1-5.
- [7] 辛建芳, 朱琦, 梁广俊, 等. 基于排队论的 D2D 蜂窝异构网络的性能分析[J]. *信号处理*, 2018, 34(4): 391-399.  
XIN J F, ZHU Q, LIANG G J, et al. Performance analysis based on queuing theory for D2D underlaying cellular networks[J]. *Journal of Signal Processing*, 2018, 34(4): 391-399.
- [8] 熊兵, 左明科, 黎维, 等. 面向软件定义核心网的 OpenFlow 分组转发优先制排队模型研究[J]. *电子学报*, 2019, 47(10): 2040-2049.  
XIONG B, ZUO M K, LI W, et al. A prioritized queueing model of OpenFlow packet forwarding in software-defined core networks[J]. *Acta Electronica Sinica*, 2019, 47(10): 2040-2049.
- [9] 李庆华, 陈志刚, 张连明, 等. 基于网络演算的无线自组网 QoS 性能确定上界研究[J]. *通信学报*, 2008(29): 32-39.  
LI Q H, CHEN Z G, ZHANG L M, et al. Deterministic upper bounds on QoS performance about wireless ad hoc network based on network calculus[J]. *Journal on Communications*, 2008(29): 32-39.
- [10] 任双印. 基于网络演算的软件定义网络服务质量研究[D]. 长沙: 国防科技大学, 2018.  
REN S Y. A software defined network QoS research based on network calculus[D]. Chang sha: National University of Defense Technology, 2018.
- [11] 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 Press, 2019.
- [12] XIAO S H, HE D D, GONG Z B. Deep-Q: traffic-driven QoS inference using deep generative network[C]//The 2018 Workshop on Network Meets AI & ML. New York: ACM Press, 2018: 67-73.
- [13] GEYER F. DeepComNet: Performance evaluation of network topologies using graph-based deep learning[C]//Proceedings of the 11th EAI International Conference on Performance Evaluation Methodologies and Tools. New York: ACM Press, 2017.
- [14] NAKASHIMA M, SIM A, KIM J. Evaluation of deep learning models for network performance prediction for scientific facilities[C]//HPDC'20: The 29th International Symposium on High-Performance Parallel and Distributed Computing. New York: ACM Press, 2020.
- [15] SHI ZP, LI J, WU CT. DeepDDoS: online DDoS attack detection[C]//2019 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2020.
- [16] GORI M, MONFARDINI G, SCARSELLI F. A new model for learning in graph domains[C]//IEEE International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2005.
- [17] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. *IEEE Transactions on Neural Networks*, 2009, 20(1):61-80.
- [18] XIAN XF, FANG LG, SUN SM. ReGNN: A repeat aware graph neural network for session-based recommendations[J]. *IEEE Access*, 2020, 8:98518-98525.
- [19] RAGESH R, SELLAMANICKAM S, LINGAM V, et al. A graph convolutional network composition framework for semi-supervised classification[EB]. 2020.
- [20] WANG ZY, GOMBOLAY M. Learning scheduling policies for multi-robot coordination with graph attention networks[J]. *IEEE Robotics and Automation Letters*, 2020.5(3): 4509-4516
- [21] FAN S, HUANG B. Labeled graph generative adversarial networks[EB]. 2019.
- [22] GUO SN, LIN YF, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Piscataway: IEEE Press, 2019(33): 922-929.
- [23] PENG H, WANG HF, DU BW, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting[J]. *Information Sciences*, 2020(521): 277-290.
- [24] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for quantum chemistry[C]//Proceedings of the 34th International Conference on Machine Learning. Cambridge: JMLR, 2017(70): 1263-1272.
- [25] RUSEK K, JOSÉ SUÁREZ-VARELA, MESTRES A, et al. Unveiling the potential of graph neural networks for network modeling and optimization in SDN[C]//Proceedings of the 2019 ACM Symposium on SDN Research. New York: ACM Press, 2019: 140-151.
- [26] BENGIO S, VINYALS O, JAITLY N, et al. Scheduled sampling for sequence prediction with recurrent neural networks[C]//Advances in Neural Information Processing Systems. New York: Curran Associates, Inc., 2015: 1171-1179.
- [27] HUANG XH, ZENG M, XIE K. Intelligent traffic control for QoS optimization in hybrid SDNs[J]. *Computer Networks*, 2021, 189(2): 107877.
- [28] CLARK D D, PARTRIDGE C, RAMMING J C, et al. A knowledge plane for the internet[C]//Conference on Applications. New York: ACM Press, 2003: 3-10.

## [作者简介]



**李奕江**（1997- ），男，浙江工商大学信息与电子工程学院（萨塞克斯人工智能学院）硕士生，主要研究方向为新一代网络技术、人工智能应用。



**楼佳丽**（1998- ），女，浙江工商大学信息与电子工程学院（萨塞克斯人工智能学院）硕士生，主要研究方向为新一代网络技术、人工智能应用。




**叶会标**（1973- ），男，中国电信股份有限公司浙江分公司云网监控维护中心核心网室主任，主要研究方向为中国电信 4G、5G 核心网、VoLTE 网络的运营管理等。



**庄丹娜**（1995- ），女，浙江工商大学信息与电子工程学院（萨塞克斯人工智能学院）硕士生，主要研究方向为新一代网络技术、人工智能应用。



**谢仁华**（1997- ），男，浙江工商大学信息与电子工程学院（萨塞克斯人工智能学院）硕士生，主要研究方向为新一代网络技术、人工智能应用。



**李传煌**（1980- ），男，博士，浙江工商大学信息与电子工程学院（萨塞克斯人工智能学院）教授、硕士生导师，主要研究方向为软件定义网络、开放可编程网络、边缘计算、人工智能应用。