

基于图神经网络的多目标路由优化

范一哲, 葛洪武, 娄阳

(中国电子科技集团公司 第五十四研究所, 石家庄 050081)

摘要: 随着通信网络规模的不断扩大和业务需求的多样化, 传统基于规则的路由优化方法已难以满足复杂网络环境下的性能需求, 针对此问题提出一种基于图神经网络的多目标路由优化方法, 将网络拓扑抽象为图结构, 通过节点和边的特征信息进行学习, 实现如时延、吞吐量和链路负载的多目标优化路由选择; 针对传统方法中难以处理动态网络状态和非线性约束的问题, 引入动态权重自适应机制以提升路由策略在不同网络状态下的自适应能力通过在仿真环境中构建不同规模网络拓扑; 对比了 GNN 路由优化方法与 Dijkstra 算法、负载均衡算法和 Q-learning 算法的性能; 实验结果表明, 所提出方法在平均时延、吞吐量和负载均衡度方面均优于传统算法。

关键词: 图神经网络; 多目标路由; 动态权重; 网络优化; 网络自适应

Multi-objective Routing Optimization Based on GNN

FAN Yizhe, GE Hongwu, LOU Yang

(The 54th Research Institute, China Electronics Technology Group Corporation, Shijiazhuang 050081, China)

Abstract: With the continuous expansion of communication network scale and the diversification of business demands, it is difficult for traditional rule-based routing optimization methods to meet performance requirements in complex network environments. To address this issue, a multi-objective routing optimization method based on graph convolutional network (GNN) is proposed. This method abstracts the network topology into a graph structure, and learns through the feature information of nodes and edges to achieve the optimized routing selections of multiple objectives such as delay, throughput, and link load. To tackle the problems of traditional methods in handling dynamic network states and nonlinear constraints, a dynamic weight adaptive mechanism is introduced to enhance the adaptability of the routing strategy under different network states. By constructing network topologies of different scales in a simulation environment, the performance of the GNN routing optimization method is compared with that of the Dijkstra algorithm, load balancing algorithm, and Q-learning algorithm. Experimental results show that the proposed method outperforms traditional algorithms in terms of average delay, throughput, and load balancing degree.

Keywords: GNN; multi-objective routing; dynamic weight; network optimization; network self-adaptation

0 引言

近年来, 随着互联网、物联网及 5G/6G 通信网络的持续扩张, 网络结构规模与业务类型日益复杂, 不同应用在时延、带宽、能耗与可靠性等性能指标上呈现出多目标且相互冲突的特性, 使得多目标路由优化成为网络管理与智能调度的重要方向^[1-2]。

早期研究主要集中于基于加权和法与 Pareto 最优理论的静态多目标优化模型, 文献 [3] 中提出一种基于遗传算法的多目标路由模型, 以时延、带宽和能耗为优化目标, 实现了较好的折中性能。然而, 该类算法在

面对大规模拓扑和动态流量变化时计算复杂度高, 难以实时部署。文献 [4] 引入多目标蚁群算法, 通过启发式搜索改善了收敛速度, 但在高负载条件下仍存在过早收敛问题; 针对这一局限, 文献 [5] 提出了 NSGA-II 框架, 成为后续多目标演化算法的基础; 文献 [6] 将 NSGA-II 应用于软件定义网络 (SDN, software defined network) 环境, 实现了基于流量均衡和时延优化的多目标 SDN 路由算法, 但其目标权重需人工设定, 缺乏自适应性。近年来, 多目标路由研究逐渐从启发式搜索向数据驱动与智能优化方向发展。文献 [7] 结合强化学习框架提出了一种基于深度 Q 网络的多目标路由方

收稿日期: 2025-11-08; 修回日期: 2025-12-15。

作者简介: 范一哲 (2003-), 男, 硕士。

通讯作者: 葛洪武 (1975-), 男, 硕士, 高级工程师。

引用格式: 范一哲, 葛洪武, 娄阳. 基于图神经网络的多目标路由优化[J]. 计算机测量与控制, 2026, 34(2): 219-226.

法,能在动态流量变化下实现端到端策略优化,但模型训练过程需要大量样本且难以解释。文献 [8] 引入多目标 Actor-Critic 结构,通过权重共享机制同时学习延迟与能耗目标,但在异构拓扑中泛化性较差。与此同时,学者们也尝试利用进化强化学习和层次学习机制提升多目标平衡性能,文献 [9] 设计了基于层次强化学习的动态权重调整策略,在高负载场景下性能较传统 RL 方法有所提升。然而,上述方法仍未能有效建模网络拓扑的复杂依赖关系,限制了对网络状态的结构化理解。

随着图神经网络 (GNN, graph neural network) 的快速发展,研究者开始尝试将其引入网络性能建模与路由优化领域。文献 [10] 提出的图卷积网络在节点特征聚合上具备较强的结构感知能力,为后续的 GNN 路由研究提供了基础;文献 [11] 进一步将 GNN 应用于 RouteNet 模型,利用图卷积层学习端到端路径性能,实现了对时延与丢包率的高精度预测。文献 [12] 在 RouteNet-Erlang 中引入 Erlang 建模思想,通过 GNN 实现了对大规模拓扑下网络时延的可微分建模,但该模型仅限于性能预测,未能实现策略优化。文献 [13] 提出 RouteNet-Fermi 模型,扩展了网络流量与资源竞争的建模能力,为多目标决策提供了潜在输入,但仍缺乏可解释的优化机制。为了实现从性能建模到策略优化的跨越,近年来的研究聚焦于 GNN 驱动的端到端多目标优化。文献 [14] 提出基于图注意力机制的多目标路由框架,利用注意力权重反映链路重要性,但模型训练过程依赖静态数据集,动态泛化能力不足。文献 [15] 通过图强化学习结合多目标奖励函数,实现了网络拥塞控制与路径选择的联合优化,但训练复杂且收敛慢。文献 [16] 设计了基于图卷积与多目标损失融合的 GNN-RL 混合模型,但在实时性与解释性方面仍有不足。针对动态权重问题,文献 [17] 提出自适应权重更新机制,通过网络状态反馈调整目标权重,从而提高模型在突发流量下的稳定性。然而,现有框架在大规模拓扑下仍面临可扩展性与训练成本高的问题^[18-20]。

综上所述,现有研究在多目标路由优化领域已逐步形成由传统启发式算法向智能学习方法演进的发展脉络。传统路由优化方法凭借明确的优化目标与规则设计,在算法可解释性、收敛稳定性以及工程可实现性方面仍具有不可替代的优势,但在面对大规模、动态变化的网络环境时,其全局建模能力与自适应性会受到一定限制。相比之下,基于图神经网络的学习模型能够直接刻画网络拓扑结构与链路状态之间的复杂关联关系,在多目标联合建模和端到端优化方面展现出显著潜力,但仍面临训练开销大、泛化能力受限以及决策可解释性不足等挑战。因此,未来研究有必要进一步探索动态权重

自适应机制,引入网络状态反馈实现多目标优化权重的在线调整,同时加强 GNN 结构设计与传统路由机理的融合,以实现面向复杂网络环境的智能化多目标优化。

1 图神经网络与多目标路由

1.1 图神经网络

图神经网络是一类专门用于处理图结构数据的深度学习模型,其核心优势在于能够同时捕捉节点特征和网络拓扑信息。在网络路由问题中,GNN 将通信网络抽象为图 $G=(V, E)$,其中节点集合 V 表示路由器、交换机或终端设备,边集合 E 表示网络链路,每个节点和边可携带多种属性,如延迟、带宽、丢包率和链路负载等。GNN 的基本操作是通过邻居聚合机制,将节点自身特征与邻居节点信息进行融合,逐层更新节点表示,从而生成能够反映网络全局拓扑和状态的高维嵌入。

图卷积网络 (GCN, graph convolutional network) 是一种基于谱理论的 GNN,通过邻居特征加权平均来更新节点表示。对于第 l 层节点特征 $H^{(l)}$,包括时延、吞吐量、负载等信息,GCN 的更新公式为:

$$H^{(l+1)} = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H^{(l)} W^{(l)}) \quad (1)$$

其中: \tilde{A} 为加自环的邻接矩阵; \tilde{D} 为 \tilde{A} 的度矩阵; $W^{(l)}$ 为第 l 层的可学习权重矩阵; $\sigma(\cdot)$ 为非线性激活函数。GCN 经典模型架构如图 1 所示。

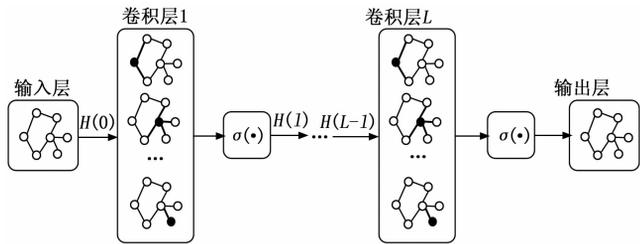


图 1 GCN 经典模型架构

图卷积神经网络的邻居聚合机制本质上是一种在图结构上进行信息传播与特征融合的过程,其核心思想是在保持图拓扑约束的前提下,让每个节点通过不断吸收邻居节点的信息来更新自身表示。这种机制使得 GCN 能够天然地建模复杂网络中的相关性与依赖关系,是其区别于传统多层感知机的重要特征。首先,通过在邻接矩阵中加入自环,节点在聚合邻居信息的同时能够保留自身特征,避免在多层传播后自身信息被淹没。随后,引入基于节点度数的对称归一化操作,使得不同节点在聚合邻居特征时具有可比的尺度,防止高度节点在信息传播过程中占据主导地位。在此基础上,每个节点将其一跳邻居的特征按照归一化权重进行加权求和,并通过共享的线性变换矩阵进行特征映射,最后施加非线性激活函数,从而得到新的节点表示。

通过多层 GCN 的堆叠, 节点能够逐层感知更远距离的邻居信息, 实现多跳结构特征的融合。同时, 其聚合形式以矩阵运算为主, 计算效率高, 易于在 GPU 上并行实现, 并能够与多目标优化、强化学习或其他深度学习框架进行端到端联合训练。

图注意力网络 (GAT, graph attention network) 通过注意力机制可以自适应地为邻居节点分配权重, 从而区分不同邻居的重要性。其节点更新公式为:

$$\mathbf{H}_i^{(t+1)} = \sigma \left(\sum_{j \in N(i)} \alpha_{ij}^{(t)} \mathbf{W}^{(d)} \mathbf{H}_j^{(t)} \right) \quad (2)$$

其中: 注意力系数 $\alpha_{ij}^{(t)}$ 通过邻居节点特征计算得到:

$$\alpha_{ij}^{(t)} = \frac{\exp\{\text{LeakyReLU}[\mathbf{a}^T (\mathbf{W}\mathbf{H}_i \parallel \mathbf{W}\mathbf{H}_j)]\}}{\sum_{k \in N(i)} \exp\{\text{LeakyReLU}[\mathbf{a}^T (\mathbf{W}\mathbf{H}_i \parallel \mathbf{W}\mathbf{H}_k)]\}} \quad (3)$$

其中: \mathbf{a} 为可学习的注意力向量, \parallel 表示向量拼接, $N(i)$ 为节点 i 的邻居集合。GAT 注意力机制如图 2 所示。

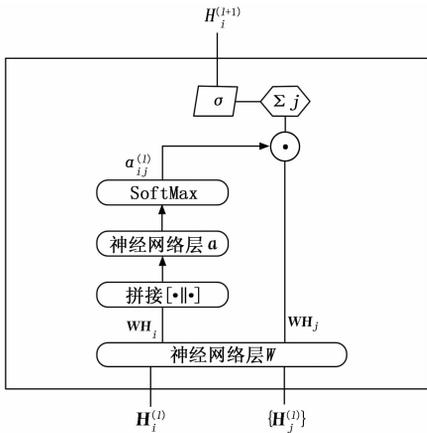


图 2 GAT 注意力机制

GAT 通过在邻居聚合过程中引入可学习的注意力权重, 使模型能够根据邻居的重要性自适应地分配信息贡献, 从而克服传统 GCN 中“所有邻居等权聚合”的局限。其核心思想是在保持图结构约束的前提下, 让模型自动学习“该听谁的”, 使节点在更新自身表示时更加关注对当前任务更有价值的邻居信息。

注意力权重计算通常分为 3 个关键步骤。首先, 对节点特征进行线性映射, 即对每个节点的输入特征通过共享权重矩阵进行变换, 得到新的特征表示。这一操作的目的是将节点特征映射到同一特征空间, 为后续注意力计算提供统一的表示基础。随后, 模型针对每一条边计算节点 i 与其邻居 j 之间的注意力打分, 并通过 LeakyReLU 等非线性函数得到未归一化的相关性系数。在得到邻居之间的相关性系数后, GAT 使用 Softmax 函数在节点 i 的邻域内进行归一化, 生成最终的注意力权重。这样可以保证所有邻居权重之和为 1, 使聚合过

程具有概率意义, 并增强训练过程的稳定性。最终, 节点 i 的新表示由其邻居节点特征的加权和构成, 其中权重正是学习得到的注意力系数。

GAT 的注意力权重机制显著提升了模型对邻居异质性的建模能力。在实际网络中, 不同邻居对节点决策的贡献往往存在明显差异, GAT 通过可学习的权重分配机制, 能够自动突出关键信息、抑制噪声邻居的影响, 从而在动态网络中表现出更强的鲁棒性。

在实现多目标综合优化时, GCN 和 GAT 通常作为网络状态感知和特征表示模块, 与多目标损失函数或强化学习框架相结合, 构建包含时延、吞吐量、负载均衡、能耗等指标的加权损失函数, 通过动态或自适应权重调整来反映不同业务场景下的优化重点。GCN 适合捕捉全局平滑趋势, 而 GAT 在多目标场景中更容易突出关键链路或关键节点对某一目标的主导作用。

1.2 基于动态权重自适应的多目标路由

多目标路由优化通常需要同时考虑平均时延最小化、网络吞吐量最大化与链路负载均衡等多种性能指标。传统方法多采用线性加权策略, 将各目标损失按照固定权重组合为单一损失函数:

$$F(P) = \sum_{i=1}^m a_i f_i(P) \quad (4)$$

其中: $f_i(P)$ 表示第 i 个优化目标, a_i 为相应权重。

固定权重法能够将多目标问题转化为单目标问题, 但权重难以合理设置, 且在不同环境下固定权重往往导致优化结果偏向某一目标, 并且无法保证实时适应性, 当目标间存在强烈冲突时, 固定权重容易使解远离帕累托最优前沿。

为解决上述问题提出了动态权重自适应机制, 其核心思想是在优化过程中根据网络环境状态、优化进程或历史反馈动态调整目标函数的权重, 从而实现更平衡且自适应的优化效果。

在多目标优化中, 系统通过实时监测网络指标 (如时延、链路利用率、丢包率、能耗等), 并据此修正各目标的权重。当链路出现拥塞时, 系统提升时延最小化目标的权重; 当链路负载趋于均衡时, 增加带宽利用或能效优化的权重。

$$a_i(t+1) = \frac{f_i(s_t)}{\sum_{j=1}^m f_j(s_t)} \quad (5)$$

其中: $f_i(s_t)$ 表示当前状态下第 i 个目标的重要性。

在迭代优化中, 根据不同目标函数的收敛速率或梯度变化自适应分配权重。若某一目标收敛过快且已接近稳定值, 则降低其权重, 以保证其他目标能够获得更多优化资源。

$$a_i(t+1) = a_i(t) \cdot \left(1 + \eta \cdot \frac{\|\nabla f_i\|}{\sum_j \|\nabla f_j\|}\right) \quad (6)$$

其中： ∇f_i 为目标函数的梯度， η 为调节因子，其决定了在每次迭代中，变量沿梯度或搜索方向更新的大小，取值区间为 $[0.01, 0.3]$ 。

在目标权衡与权重调整方面，通常将多个优化目标（如时延、吞吐量、丢包率、能耗等）构造成加权损失函数或效用函数。动态权重自适应机制不采用固定权重，而是依据网络状态变化、目标达成度或梯度信息实时更新权重。当某一指标明显恶化时，系统会自动提高该目标对应的权重，使优化过程优先缓解当前瓶颈；而当某一目标已接近满意区间，其权重会被逐步降低，避免“过优化”而牺牲其他性能。

在保证全局最优性方面，动态权重机制通常与全局搜索或学习框架协同使用，而不是单独依赖权重更新本身。首先，在理论层面，若多目标问题是凸的，且权重更新满足一定的收敛条件，动态加权和的方法可以收敛到帕累托最优解集合中的某一点。其次，在非凸问题中，常通过多次随机初始化、熵正则化、温度系数退火或探索—利用机制，避免权重陷入局部极值。同时，在 GNN 或强化学习框架中，权重更新可嵌入到策略梯度或价值函数学习过程中，通过长期累积回报来评估权重调整对整体性能的影响，从而在时间尺度上逼近全局最优或稳定的帕累托前沿。

2 方法与模型设计

2.1 网络建模与特征构建

基于图神经网络的多目标路由优化方法（GNN-MOR, graph neural network-multi-objective routing）将通信网络抽象为加权无向图：

$$G = (V, E) \quad (7)$$

节点集合 $V = \{v_1, v_2, \dots, v_N\}$ 表示网络设备，如路由器、交换机。每个节点不仅承载数据流量，还参与路由决策。链路集合 $E = \{e_{ij}\}$ 表示节点间的物理或逻辑连接，每条链路具有实时网络属性。

对于网络中的每个节点 v_i ，其特征向量表示为：

$$x_i = [\text{deg}(i), \lambda_i, \bar{b}_i, \bar{t}_i] \quad (8)$$

其中： $\text{deg}(i)$ 表示节点的度，用于反映节点在网络中的连接数量及其拓扑中心性。节点的度决定了节点的路径选择空间和转发能力，高度节点提供更多可选路由但容易成为流量汇聚的拥塞与失效热点，低度节点路径受限但有利于分散负载。路由优化中若过度依赖高度节点可降低时延却牺牲鲁棒性，而合理引入度感知与负载联合约束可在时延、负载均衡和可靠性之间取得更优权衡； λ_i 为节点当前的流量需求，用于描述该节点的负载压力大小。流量需求决定了链路与节点的资源消耗水

平，是拥塞形成和性能退化的根本原因。高流量需求会加剧链路利用率与队列积压，使路由策略必须更加注重负载均衡与拥塞规避；而低或不均衡的流量需求则为路径重构和多路径分流提供空间。流量需求纳入路由决策是实现多目标优化、提升网络稳定性与整体性能的关键； \bar{b}_i 为节点邻接链路的平均可用带宽，反映节点所处局部网络环境的传输能力。平均可用带宽反映了链路在当前负载下仍可用于新业务的剩余传输能力，直接决定了路由对高流量需求的承载上限； \bar{t}_i 为节点邻接链路的平均传播时延，用于衡量节点周围链路的时延特性。该特征向量能够同时体现节点的拓扑属性与其动态运行状态，为 GNN 模型在信息聚合阶段提供更具判别性的输入表示。

对于任意一条链路 e_{ij} ，其特征向量表示为：

$$e_{ij} = [b_{ij}, t_{ij}, u_{ij}] \quad (9)$$

其中： b_{ij} 表示链路的实时带宽，用于刻画链路的数据传输能力； t_{ij} 为链路的传播时延，反映端到端数据包的平均传输时长； u_{ij} 为链路利用率，用于描述链路当前的占用程度与负载状态。链路特征向量侧重于网络连接层面的性能属性，能够为 GNN 在进行消息传递和路径选择时提供基础的物理与逻辑约束。

在基于 GNN 的路由优化中，链路的实时带宽、传播时延和利用率通常作为边特征输入模型，用以刻画链路的瞬时承载能力与传输代价；实时带宽反映链路可用资源水平，传播时延刻画物理传输成本，利用率表征拥塞程度与负载状态。经过归一化或时间平滑后，这些特征在消息传递过程中随邻接关系向节点聚合，使 GNN 能同时感知拓扑结构与动态链路状态，从而学习在不同网络负载与时延条件下的最优路由决策。

2.2 GNN 结构设计

GNN-MOR 模型整体采用“输入层 + GCN 层 + GAT 层 + 输出层”的分层结构，如图 3 所示。

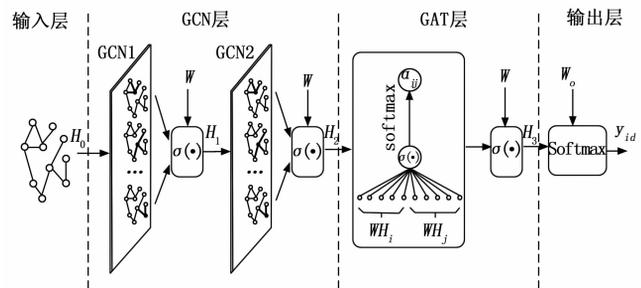


图 3 GNN-MOR 模型结构图

模型输入为节点特征矩阵 $X \in \mathbb{R}^{N \times d_s}$ 与链路特征矩阵 $E \in \mathbb{R}^{M \times d_e}$ ，其中 N 和 M 分别为节点数与边数， d_s 和 d_e 分别为节点和链路的特征维度。模型通过层间特征传播与非线性映射，逐步提取网络在拓扑、带宽、时

延、利用率等维度的高层次表示, 实现从局部结构到全局状态的嵌入建模。

GNN-MOR 首先采用 2 个图卷积层对节点进行特征聚合与更新。每一层节点表示更新的数学表达式为:

$$\mathbf{H}^{(l+1)} = \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (10)$$

其中: $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 为加自环的邻接矩阵, 使节点在聚合时保留自身特征; $\tilde{\mathbf{D}}$ 为 $\tilde{\mathbf{A}}$ 的度矩阵, 其对角线元素为各节点的度值; $\mathbf{H}^{(l)}$ 为第 l 层节点的特征表示; $\mathbf{W}^{(l)}$ 为权重矩阵; $\sigma(\cdot)$ 为非线性激活函数。

在特征传播阶段, 通过邻接矩阵 $\tilde{\mathbf{A}}$ 捕获节点间的连接关系, 在传播过程中累积邻居节点的时延信息; 在非线性映射阶段, 非线性激活函数 $\sigma(\cdot)$ 捕获网络状态中潜在的复杂关系, 通过权重矩阵 \mathbf{W} 和非线性激活函数学习带宽约束, 从节点特征中提取资源使用效率模式。

将 GCN 层的特征输出作为 GAT 层的输入, 通过自适应地分配邻居节点的重要性权重, 实现特征聚合时的动态加权。节点更新表示为:

$$\mathbf{H}_i^{(l+1)} = \sigma\left(\sum_{j \in \mathcal{N}(i)} \mathbf{a}_{ij}^{(l)} \mathbf{W}^{(l)} \mathbf{H}_j^{(l)}\right) \quad (11)$$

对于节点 v_i 与其邻居节点 $v_j \in \mathcal{N}(i)$, 其注意力系数计算如下:

$$\mathbf{a}_{ij}^{(l)} = \frac{\exp\{\text{LeakyReLU}[a^T(\mathbf{W}\mathbf{H}_i \parallel \mathbf{W}\mathbf{H}_j)]\}}{\sum_{k \in \mathcal{N}(i)} \exp\{\text{LeakyReLU}[a^T(\mathbf{W}\mathbf{H}_i \parallel \mathbf{W}\mathbf{H}_k)]\}} \quad (12)$$

其中: \mathbf{a} 为可学习的注意力参数向量, \parallel 表示向量拼接操作; LeakyReLU 为激活函数。

通过注意力权重机制, 模型能够学习到不同邻居节点对中心节点的贡献度, 从而在特征聚合时突出对路由性能影响更大的关键节点与链路。

通过上述变换, 每个节点不仅包含自身的特征信息, 还融合了邻居节点的特征加权信息, 从而捕获节点间的局部关联性与结构相似性。

经过多层图卷积与注意力融合后, 模型最终在输出层生成每个源-目的节点对 (s, d) 的下一跳概率分布:

$$y_{sd} = \text{Softmax}(\mathbf{W}_o \mathbf{H}_s) \quad (13)$$

其中: \mathbf{W}_o 为输出层权重矩阵, \mathbf{H}_s 表示源节点的高维嵌入表示。

该分布可理解为从源节点到目标节点的下一跳选择概率, 通过该概率分布, GNN-MOR 可捕获不同候选路径的全局潜在价值, 实现对多目标性能的权衡与最优策略的自动决策。基于输出的下一跳概率分布, 在每个节点选择概率最高的下一跳节点, 从而生成确定性路径, 生成的路径集合构成了全网的多目标路由策略图, 通过该策略图可实现灵活的流量分配与全局优化。

动态权重自适应机制在路由策略生成过程中发挥关

键作用。当不同目标损失变化速率不一致时, 自动调整目标权重, 实现训练阶段与推理阶段的一致性优化。当网络状态发生变化时, 模型可快速重新计算节点嵌入并生成新的下一跳概率分布, 使得路由策略具备自适应性与鲁棒性。

2.3 损失函数设计与动态权重自适应机制

在多目标路由问题中, 给定网络拓扑 G 和通信需求集合 $D = \{d_k\}$, 每个需求 d_k 包含源节点、目的节点及时延、带宽需求。目标是为所有需求分配路由路径 $P = \{p_k\}$, 以同时优化以下性能指标:

$$f_1(p) = \frac{1}{|D|} \sum_k \sum_{(i,j) \in p_k} t_{ij} \quad (14)$$

$$f_2(p) = \sum_k \min_{(i,j) \in p_k} b_{ij} \quad (15)$$

$$f_3(p) = \sqrt{\frac{1}{|E|} \sum_{(i,j) \in E} (u_{ij} - \bar{u})^2} \quad (16)$$

其中: $f_1(p)$ 为平均时延, $f_2(p)$ 为网络吞吐量, $f_3(p)$ 为链路负载。

综合考虑网络的三类主要性能指标: 平均时延、吞吐量与负载均衡, 定义多目标损失函数为:

$$L_{\text{total}}(t) = \sum_{i=1}^3 \omega_i(t) L_i(t) \quad (17)$$

其中: $\omega_i(t)$ 为相应目标的动态权重系数; $L_i(t)$ 表示第 i 个优化目标在第 t 轮训练时的损失值, 其在数值上分别对应第 t 轮训练时的 $f_1(p)$ 、 $-f_2(p)$ 、 $f_3(p)$; $L_{\text{total}}(t)$ 为加权后的综合损失函数。

时延损失 $L_1(t)$ 度量所有路由由路径的平均端到端时延差异, 用于最小化整体网络传输延迟; 吞吐量损失 $L_2(t)$ 反映单位时间内成功传输的数据量, 目标是最大化吞吐量; 负载均衡损失 $L_3(t)$ 用于衡量各链路间流量分布的离散程度, 目标是使网络负载分布更均匀。通过对上述三类性能指标的联合优化, 模型能够在保持低时延的同时, 充分利用可用带宽并避免链路过载, 实现全局性能最优。

动态权重自适应机制通过实时感知网络状态和优化进程反馈, 动态调整不同目标在损失函数中的权重: 当某一性能指标恶化或收敛滞后时, 其对应权重被提高以优先缓解当前瓶颈, 而已接近满意区间的目标权重则相应降低, 从而实现多目标之间的自适应平衡。在全局最优性方面, 该机制通常与全局搜索或学习框架相结合, 通过平滑、受限的权重更新规则和长期累计回报评估, 避免陷入局部最优, 使优化过程在动态环境下稳定收敛至帕累托最优或其近似解。

权重计算公式如下:

$$r_i(t) = \frac{L_i(t-1)}{L_i(t) + \epsilon} \quad (18)$$

$$\omega_i(t) = \frac{\exp[r_i(t)/\tau]}{\sum_{j=1}^3 \exp[r_j(t)/\tau]} \quad (19)$$

其中： $r_i(t)$ 表示第 i 个目标在相邻两次训练间的相对下降速率； ϵ 为防止分母为零而引入的微小常数； τ 为温度系数，用于控制权重分布的平滑程度，其初始取值范围为 $[0.5, 5]$ 。当 τ 较小时，权重分布更为尖锐；当 τ 较大时，权重变化较平滑，各目标贡献更为均衡。

3 实验与分析

为验证所提出的基于图神经网络的多目标路由优化方法在实际网络环境中的有效性，本研究在仿真平台上搭建了一个可复现的网络路由实验环境，并设计了多组对比实验。实验从网络拓扑、评价指标、基线算法及训练参数等方面进行了全面设计，确保实验结果具有可靠性。

本实验平台搭建在 ubuntu22.04 环境下，基于 Mininet 构建虚拟网络拓扑，实现可控的路由和流量调度，使用 Ryu 控制器模拟 SDN 环境，通过 OpenFlow 协议管理路由策略，深度学习框架采用 Pytorch 实现 GNN 模型训练与推理，使用 PYG (Pytorch-Geometric) 作为图神经网络的核心实现框架。

为了验证算法在不同规模网络中的泛化能力，本文设计了三类拓扑，如表 1 所示。

表 1 不同规模网络表

网络规模	节点数	链路数
小型	8	14
中型	20	45
大型	50	110

网络拓扑参考了真实的 NSFNET 骨干网结构，并随机生成链路带宽 (100~1 000 Mbps)、传播时延 (2~10 ms) 及丢包率 (0.1%~0.5%) 等参数。每条链路的带宽和时延均服从均匀分布，确保数据分布的多样性。

为验证 GNN-MOR 的优势，本文选取 Dijkstra 最短路径算法、负载均衡 (LB) 算法以及 Q-learning 路由算法作为对比。通过对比不同算法的平均时延、吞吐量、负载方差以及链路利用率的分布和分析 GNN-MOR 的训练收敛效果，以体现 GNN-MOR 的优势。

实验参数设置学习率为 0.001，批次大小为 32，训练轮次为 200，动态权重初值均为 1/3。每组实验重复 20 次取平均结果，所有实验均在相同随机种子下运行以保证可重复性。训练集与测试集按照 8:2 划分，其中测试集包含随机生成的网络状态，用于评估模型的泛化能力。

图 4 展示了 GNN-MOR 的训练损失收敛曲线。

由图 4 可知，损失在初始轮次中迅速下降并在 100 次后趋于平稳，表明模型能够高效学习路由策略。动态

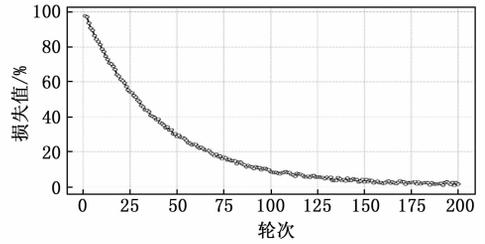


图 4 GNN-MOR 训练损失收敛曲线图

权重在训练过程中自动调整，早期更关注吞吐量优化，中后期逐渐平衡时延与负载目标，实现多指标综合最优。这一结果证明动态权重机制有效抑制单一目标的过拟合，使得多目标优化取得平衡。

在中型网络中，3 种基线算法与 GNN-MOR 的平均性能对比如表 2 所示。

表 2 中型网络下不同算法性能对比

算法	平均时延/ms	吞吐量/Mbps	负载方差
Dijkstra	12.5	80.3	0.35
负载均衡(LB)	14.8	82.1	0.21
Q-learning	11.7	84.5	0.26
GNN-MOR	10.2	88.7	0.18

实验对比如图 5~7 所示。

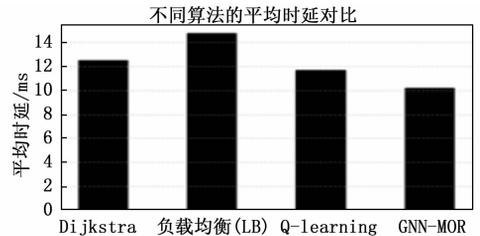


图 5 不同算法平均时延对比图

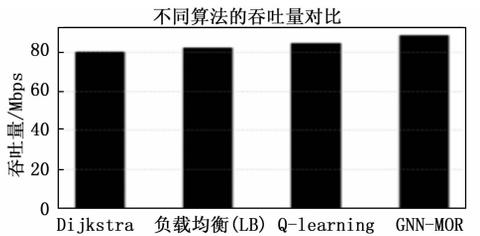


图 6 不同算法吞吐量对比图

由图 5~7 可以得出，在中型网络实验环境下，GNN-MOR 算法相比于其它 3 种算法，其平均时延更低、吞吐量更大、负载方差更小，其性能最优。

与传统 Dijkstra 算法、经典负载均衡算法以及 Q-learning 路由相比，GNN-MOR 在综合性能上更具优势。Dijkstra 以最短路径为核心，通常可获得较低的平均时延，但在流量集中时容易造成链路拥塞，吞吐量提升受限且负载方差较大；负载均衡算法通过分散流量有

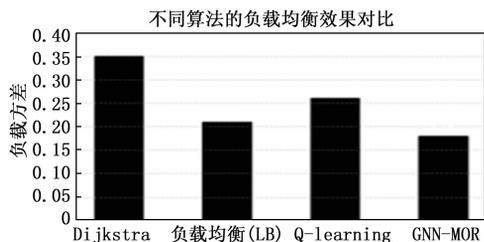


图 7 不同算法负载均衡效果对比图

效降低负载方差、提高吞吐量, 但往往牺牲路径长度, 导致平均时延上升; Q-learning 能根据反馈自适应调整路由, 在动态环境下性能优于静态算法, 但收敛速度慢、状态维度受限, 整体稳定性和规模扩展性不足。相比之下, GNN-MOR 能够同时建模全局拓扑结构与实时链路状态, 在多目标损失约束下实现时延与吞吐的协同优化, 既保持较低平均时延, 又显著提升网络吞吐量, 并通过结构感知与动态权重机制有效降低负载方差, 在复杂、大规模和动态网络中表现出更优的综合性能。

为了验证模型的可扩展性, 将实验扩展至小型 (8 节点) 与大型 (50 节点) 网络, 结果见表 3。

表 3 不同网络规模下算法性能对比

网络规模	算法	平均时延/ms	吞吐量/Mbps	负载方差
小型	Dijkstra	8.1	45.6	0.22
小型	负载均衡(LB)	7.8	46.3	0.15
小型	Q-learning	7.8	47.5	0.18
小型	GNN-MOR	7.2	49.8	0.12
大型	Dijkstra	28.3	180.4	0.42
大型	负载均衡(LB)	32.5	185.7	0.30
大型	Q-learning	26.1	188.6	0.28
大型	GNN-MOR	23.7	196.1	0.21

由表 3 可以观察到, 在小型网络中, 4 种算法的差距尚不显著, 传统的 Dijkstra 和 LB 算法在简单拓扑下也能维持的性能, GNN-MOR 算法整体优于其它 3 种算法。但随着网络规模扩展至 50 节点, 传统算法的时延迅速上升, 链路利用率分布不均衡的问题更加明显, GNN-MOR 的在大规模网络中优势更为显著, 展现了极强的可扩展性和鲁棒性。

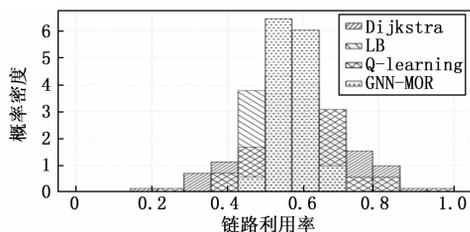


图 8 不同算法链路利用率对比图

分析图 8 可知, Dijkstra 分布最宽, 波动最大, 有些链路过载, 有些链路闲置, 说明负载均衡不佳; 负载均衡 (LB) 算法分布比 Dijkstra 集中, 但仍有一定波动, 说明简单负载均衡策略改善了部分链路利用率差异; Q-learning 分布中等集中, 波动小于 Dijkstra, 但比 GNN-MOR 稍大, 说明强化学习可以根据流量自适应优化路由, 但仍受局部信息限制; GNN-MOR 分布最集中且峰值最高, 说明绝大多数链路利用率接近平均值, 负载均衡效果最佳, 流量分布最均匀。结果表明 GNN-MOR 相比于其他 3 种算法能够实现最均衡的流量分配。

4 结束语

本文提出了一种基于图神经网络的多目标路由优化方法 (GNN-MOR), 并创新性地引入动态权重自适应机制以增强模型在不同网络状态下的自适应能力。通过将通信网络抽象为图结构, 将节点和链路特征作为输入, GNN 模型能够在端到端训练过程中学习复杂的路由策略, 实现对时延、吞吐量和链路负载均衡的综合优化。通过在不同规模的网络拓扑上进行仿真实验, 结果表明 GNN-MOR 在时延、吞吐量和负载均衡三项核心指标上均优于传统算法, 能够根据网络状态变化实时调整优化方向, 避免某一指标过度优化, 并且在任意网络规模环境下, GNN-MOR 都能保持稳定性能。

实验结果表明, GNN-MOR 在多目标路由优化中具有显著优势, 尤其适用于动态网络环境, 为智能网络管理和自动化路由优化提供了可行的解决方案。

参考文献:

- [1] VAEZI M. A survey on 5G Advances and the road toward 6G [J]. IEEE Communications Surveys & Tutorials, 2022, 24 (2): 1117 - 1174.
- [2] MOYSEN J, GIUPPONI L. From 4G to 5G: Self-organized network management meets machine learning [J]. Computer Communications, 2018, 129: 248 - 268.
- [3] AHMED Y. A genetic algorithm optimization for multi-objective multicast routing [J]. Intelligent Automation & Soft Computing, 2020, 26 (6): 1201 - 1216.
- [4] MAHMOUD A, MOFADDEL. Multi-objective multicast routing based on antcolony optimization in mobile Ad-Hoc networks [J]. Journal of Statistics Applications & Probability, 2021, 10: 687 - 694.
- [5] DEB K. A fast and elitist multiobjective genetic algorithm: NSGA-II [J]. IEEE Transactions on Evolutionary Computation, 2002, 6 (2): 182 - 197.
- [6] WAQAS A. An innovative NSGA-II-based Byzantine fault tolerant solution for software defined network environments [J]. Computer Networks, 2024, 254: 110819.

[7] YANG M Y. Deep reinforcement learning based multi-objective routing in dynamic networks [J]. IEEE Transactions on Mobile Computing, 2025, 24 (3): 1322 - 1337.

[8] RYU K. Multi-objective optimization of energy saving and throughput in heterogeneous networks using deep reinforcement learning [J]. Sensors, 2021, 21 (23): 7925.

[9] AXEL A. dynamic weights in multiobjective deep reinforcement learning [J]. Proceedings of Machine Learning Research, 2019, 97: 11 - 20.

[10] ZHOU J. Graph neural networks: a review of methods and applications [J]. AI Open, 2020, 1: 57 - 81.

[11] KRZYSZTOF R. RouteNet: Leve-raging graph neural networks for network performance modeling and optimization in SDN [J]. IEEE Journal on Selected Areas in Communications, 2020, 38 (10): 2260 - 2270.

[12] MIQUEL F. RouteNetErlang: a graph neural network for network performance evaluation [J]. IEEE INFO-COM, 2022: 2018 - 2027.

[13] MIQUEL F. RouteNetFermi: network modeling with graph neural networks [J]. IEEE/ACM Transactions on Networking, 2023, 31 (6): 3080 - 3095.

[14] YING W. GATR: a graph attention deep reinforcement learning approach with variancesensitive rewards for RPL

routing optimization [J]. Journal of King Saud University-Computer and Information Sciences, 2025, 37: 274.

[15] JIA W X. A graph reinforcement learning based SDN routing path selection for optimizing longterm revenue [J]. Future Generation Computer Systems, 2024, 150: 412 - 423.

[16] CHEN B. An approach to combine the power of deep reinforcement learning with a graph neural network for routing optimization [J]. Electronics, 2022, 11 (3): 368.

[17] XIA F. Dynamic weight mapping adaptive routing (DWMAR) for IP network [D]. University of British Columbia, 2004.

[18] JIANG W. Graph neural networks for routing optimization: challenges and opportunities [J]. Sustainability, 2024, 16 (21): 9239.

[19] MIQUEL F. Scaling graphbased deep learning models to larger networks [J/OL]. Networking and Internet Architecture, 2021-10-4. <https://doi.org/10.48550/arXiv.2110.01261>.

[20] ZHENG D. DistDGL: distributed graph neural network training for billionscale graphs [J/OL]. Machine Learning, 2020 - 10 - 11. <https://doi.org/10.48550/arXiv.2010.05337>.

(上接第 218 页)

[4] 袁 进, 郭新年, 刘 浏. 北斗 B1C 信号捕获方法设计 [J]. 无线电工程, 2021, 51 (9): 933 - 938.

[5] 周 骥, 郭承军, 曹建蜀, 等. GNSS CBOC 信号快速无模糊度捕获算法研究 [J]. 信号处理, 2015, 31 (7): 876 - 882.

[6] 许 睿, 唐瑞琪, 罗 凯, 等. 基于自相关侧峰消除的北斗 B1C 快速高精度捕获算法 [J]. 中国惯性技术学报, 2021, 29 (1): 62 - 68.

[7] 贾茹尚. 卫星导航信号捕获算法基于 ZYNQ 平台的研究与实现 [D]. 济南: 山东大学, 2022.

[8] 马 超, 瞿 智, 李献斌, 等. BeiDou BOC B1C navigation signal simulation and generation [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (1): 154 - 159.

[9] 冯永新, 王 森. BDS QMBOC 信号的捕获方法研究 [J]. 沈阳理工大学学报, 2021, 40 (5): 1 - 5.

[10] 呼询雄. 北斗三代多频点卫星信号捕获关键技术的研究 [D]. 桂林: 桂林电子科技大学, 2022.

[11] 田方礼, 董立桥. Galileo E1 卫星信号产生设计与实现 [C] //武汉: 第四届中国卫星导航学术年会, 2013: 107 - 111.

[12] 李政阳. BOC 调制信号捕获跟踪算法的研究与实现 [D]. 成都: 电子科技大学, 2025.

[13] 孙希延, 郝 放, 纪元法, 等. 基于相关移位 BOC (n,

n) 无模糊度捕获算法 [J]. 北京理工大学学报, 2020, 40 (3): 298 - 304.

[14] 舒 翊, 胡 辉, 谢虹群, 等. 适用于任意阶数的 BOC 信号无模糊度捕获算法 [J]. 哈尔滨理工大学学报, 204, 29 (3): 90 - 98.

[15] 王 剑, 戚涵天, 刘瑞华. 一种适用于 BOC (m, n) 的无模糊捕获算法 [J]. 电子与信息学报, 2018, 40 (8): 1829 - 1837.

[16] 谢慧雁. BOC 信号的高精度跟踪及多径抑制技术研究 [D]. 哈尔滨: 哈尔滨工程大学, 2016.

[17] 钱素娟, 尹新富. 基于 ASPeCT 的 BOC 调制信号捕获与跟踪研究 [J]. 现代电子技术, 2016, 39 (21): 65 - 69.

[18] 王淞波. BOC 调制信号的软件接收机设计 [D]. 北京: 北京理工大学, 2015.

[19] 王 刚. 基于 BOC 调制方式新型直捕技术研究 [D]. 哈尔滨: 哈尔滨工程大学, 2013.

[20] 黄毓臻, 夏文龙, 郭庆功. 基于互相关重构的 BOC 副峰抑制算法 [J]. 通信技术, 2025, 58 (6): 595 - 603.

[21] 杨再秀, 杨俊武, 郑晓冬, 等. 现代 GNSS 信号捕获性能评估理论与应用 [J]. 中国科学: 物理学, 力学, 天文学, 2021, 51 (1): 183 - 196.

[22] 王 鹏, 张展豪, 金志威, 等. 基于 PCF 重构的北斗 B1C 信号无模糊捕获算法 [J]. 河北大学学报 (自然科学版), 2023, 43 (3): 320 - 329.