

(12) 按照专利合作条约所公布的国际申请

(19) 世界知识产权组织
国际局

(43) 国际公布日
2024 年 2 月 22 日 (22.02.2024)



(10) 国际公布号
WO 2024/037136 A1

- (51) 国际专利分类号:
H04L 45/00 (2022.01) H04L 45/02 (2022.01)
- (21) 国际申请号: PCT/CN2023/098735
- (22) 国际申请日: 2023 年 6 月 7 日 (07.06.2023)
- (25) 申请语言: 中文
- (26) 公布语言: 中文
- (30) 优先权:
202210974378.6 2022年8月15日 (15.08.2022) CN
- (71) 申请人: 南京邮电大学 (NANJING UNIVERSITY OF POSTS AND TELECOMMUNICATIONS) [CN/CN]; 中国江苏省南京市栖霞区文苑路9号, Jiangsu 210023 (CN)。
- (72) 发明人: 郭永安 (GUO, Yongan); 中国江苏省南京市栖霞区文苑路9号, Jiangsu 210023 (CN)。 吴庆鹏

(WU, Qingpeng); 中国江苏省南京市栖霞区文苑路9号, Jiangsu 210023 (CN)。 张啸 (ZHANG, Xiao); 中国江苏省南京市栖霞区文苑路9号, Jiangsu 210023 (CN)。 余昊 (SHE, Hao); 中国江苏省南京市栖霞区文苑路9号, Jiangsu 210023 (CN)。 钱琪杰 (QIAN, Qijie); 中国江苏省南京市栖霞区文苑路9号, Jiangsu 210023 (CN)。

(74) 代理人: 南京经纬专利商标代理有限公司 (NANJING JINGWEI PATENT & TRADEMARK AGENCY CO., LTD); 中国江苏省南京市鼓楼区中山路179号12楼B座, Jiangsu 210005 (CN)。

(81) 指定国(除另有指明, 要求每一种可提供的国家保护): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CV, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IQ,

(54) Title: GRAPH STRUCTURE FEATURE-BASED ROUTING OPTIMIZATION METHOD AND SYSTEM

(54) 发明名称: 一种基于图结构特征的路由优化方法与系统




图1

- AA Control plane
BB Deep graph learning (DGL) module
CC DGL model
DD Information acquisition module
EE Graph adjacency matrix
FF Network information feature matrix
GG Strategy deployment module
HH Performance optimization
II Optimal routing strategy
JJ Data plane

(57) Abstract: Disclosed in the present invention are a graph structure feature-based routing optimization method and system. The system is used for an SDN environment and comprises a control plane and a data plane, wherein the control plane comprises an information acquisition module, a strategy deployment module, and a deep graph learning (DGL) module. The method comprises: acquiring network topology structure information and information in a network, and generating a corresponding graph adjacency matrix and a network information feature matrix; training a graph learning neural network according to the graph adjacency matrix and the network information feature matrix, to obtain a DGL model allowing for the minimum SDN routing overhead and the maximum link utilization rate; and using the DGL model and deploying same to an SDN. According to the method, a dynamic and complex network topology is learned from a spatial dimension, the difficulty in optimizing a dynamic topology is overcome, and a better routing scheme is provided for the SDN.

IR, IS, IT, JM, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, MG, MK, MN, MU, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW。

(84) 指定国(除另有指明, 要求每一种可提供的地区保护): ARIPO (BW, CV, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SC, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 欧亚 (AM, AZ, BY, KG, KZ, RU, TJ, TM), 欧洲 (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, ME, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG)。

本国际公布:
— 包括国际检索报告(条约第21条(3))。

(57) 摘要: 本发明公开了一种基于图结构特征的路由优化方法与系统, 该系统用于SDN网络环境, 包括控制平面、数据平面, 其中, 控制平面包括信息获取模块、策略部署模块、DGL模块; 该方法获取网络拓扑结构信息和网络中的信息, 并生成相应的图邻接矩阵、网络信息特征矩阵; 根据图邻接矩阵、网络信息特征矩阵, 对图学习神经网络进行训练, 获得使SDN网络路由开销最小、链路利用率最大的深度图学习模型; 应用深度图学习模型, 部署至SDN网络, 该方法从空间维度上学习动态、复杂的网络拓扑, 克服动态拓扑的优化问题, 为SDN网络提供更加优质的路由方案。

一种基于图结构特征的路由优化方法与系统

技术领域

[0001] 本发明涉及计算机网络技术领域，具体涉及一种基于图结构特征的路由优化方法与系统。

背景技术

[0002] 近年来，随着网络环境的复杂化，业务流量的多样化，路由路径优化问题成为一个研究热点。在传统网络中，路由选择采用尽力而为(Best-Effort)模型，利用 OSPF 技术来提供最短路径，无法适应动态、复杂的网络环境。软件定义网络(Software Defined Network, SDN)架构的提出将传统网络的控制平面和数据平面进行解耦，大大增加了路由优化问题解决方案的空间。在 SDN 环境下，深度强化学习与神经网络的结合能够为路由决策提供极大地帮助。但 CNN、RNN、LSTM 等算法本质上适用于欧式空间，例如图像、网格等。网络拓扑通常是一个复杂的模型，链路与链路、节点与节点之间有很强的空间相关性，传统神经网络很难将这一特征表现出来，并且基于深度强化学习的路由优化模型在网络拓扑发生变化时需要重新训练，不具有对动态拓扑的泛化能力。因此，需要有一种方法能够对网络拓扑的空间特征进行提取，从空间维度上学习动态、复杂的网络拓扑，并且能够克服动态拓扑的优化问题，提供更加优质的路由方案。

发明内容

[0003] 本发明目的：在于提供一种基于图结构特征的路由优化方法与系统，适用于 SDN 网络环境下，交换机或路由设备支持传统的二层网络协议，实现从多个网络属性上优化全局的路由开销，适应动态、复杂的 SDN 网络，保障 SDN 网络性能。

[0004] 为实现以上功能，本发明设计一种基于图结构特征的路由优化方法，针对目标 SDN 网络，执行以下步骤 S1-步骤 S3，获得目标 SDN 网络中各条链路的路由开销，调整各条链路的权重，完成目标 SDN 网络的路由优化。

[0005] 步骤 S1:针对目标 SDN 网络，基于南向接口协议，获取目标 SDN 网络的网络拓扑图，根据网络拓扑图中目标 SDN 网络的各链路上各节点之间的连接关系，构建图邻接矩阵，分别针对目标 SDN 网络的各链路上各节点，根据各节点的链路带宽、流量、丢包率、传输时延，构建各节点的信息特征向量，并基于各节点的信息特征向量，构建目标 SDN 网络的网络信息特征矩阵。

[0006] 步骤 S2:以图邻接矩阵、网络信息特征矩阵为目标 SDN 网络的状态，基于图学习神

经网络，以图邻接矩阵、网络信息特征矩阵为输入，通过深度图学习方法，以当前状态下目标 SDN 网络的路由策略、路由开销为输出，基于梯度反向传播方法，更新图学习神经网络的网络参数，并经过预设次数的迭代，对图学习神经网络进行训练，获得使目标 SDN 网络路由开销最小、链路利用率最大的深度图学习模型。

[0007] 步骤 S3:根据训练好的深度图学习模型，基于目标 SDN 网络的状态，获得使目标 SDN 网络路由开销最小的路由策略，将路由策略部署至目标 SDN 网络，根据路由策略改变目标 SDN 网络的各链路权重，完成目标 SDN 网络的路由优化。

[0008] 作为本发明的一种优选技术方案：步骤 S1 的具体步骤如下：

步骤 S1.1:针对目标 SDN 网络，基于南向接口协议，获取目标 SDN 网络的网络拓扑结构，其中网络拓扑结构包含 M 个路由器、N 条链路。

[0009] 步骤 S1.2:针对目标 SDN 网络的网络拓扑结构，每个路由器对应一个实节点，每条链路对应一条边，在每条链路所对应的边上插入虚节点，将目标 SDN 网络的网络拓扑结构表示为 M 个实节点、N 个虚节点、2N 条边的网络拓扑图 $G(V,E)$ ，其中， V 表示节点集合， E 表示边集合，具体如下式：

$$V = \{V_{\text{实}}, V_{\text{虚}}\}$$

其中， $V_{\text{实}}$ 表示实节点集合， $V_{\text{虚}}$ 表示虚节点集合；

$$V_{\text{实}} = \{v_{s1}, v_{s2}, \dots, v_{sM}\}$$

其中， $v_{s1}, v_{s2}, \dots, v_{sM}$ 表示 M 个实节点；

$$V_{\text{虚}} = \{v_{x1}, v_{x2}, \dots, v_{xN}\}$$

其中， $v_{x1}, v_{x2}, \dots, v_{xN}$ 表示 N 个虚节点；

$$E = \{e_1, e_2, \dots, e_{2N}\}$$

其中， $e_1, e_2, \dots, e_{2N}$ 表示 2N 条边。

[0010] 步骤 S1.3:令 $x=M+N$ ， x 表示节点总数，节点包括 M 个实节点、N 个虚节点，基于目标 SDN 网络的网络拓扑图，构建 x 阶的图邻接矩阵 A 如下式：

$$A = \begin{bmatrix} a_{11} & \dots & a_{1x} \\ \vdots & \ddots & \vdots \\ a_{x1} & \dots & a_{xx} \end{bmatrix}$$

其中，图邻接矩阵 A 中的元素 a_{ij} 如下式：

$$a_{ij} = \begin{cases} 1 & \text{节点 } i \text{ 和节点 } j \text{ 之间相连} \\ 0 & \text{节点 } i \text{ 和节点 } j \text{ 之间不相连} \end{cases}。$$

[0011] 步骤 S1.4: 针对目标 SDN 网络的任一节点 i , 根据节点 i 的链路带宽、流量、丢包率、传输时延，构建节点 i 的信息特征向量 h_i 如下式：

$$h_i = [B_{wi}, T_{hi}, L_{pi}, D_{ti}]$$

式中， B_{wi} 为节点 i 的链路带宽， T_{hi} 为节点 i 的流量， L_{pi} 为节点 i 的丢包率， D_{ti} 为节点 i 的传输时延；

基于各节点的信息特征向量，构建目标 SDN 网络的网络信息特征矩阵 H 如下式：

$$H = \begin{Bmatrix} h_1 \\ h_2 \\ \vdots \\ h_i \\ \vdots \\ h_x \end{Bmatrix}$$

式中， $h_1, h_2, \dots, h_i, \dots, h_x$ 为各节点的信息特征向量。

[0012] 作为本发明的一种优选技术方案：步骤 S1.4 中所述的节点 i ，若节点 i 为虚节点，则节点 i 的流量 T_{hi} 、丢包率 L_{pi} 、传输时延 D_{ti} 为 0，若节点 i 为实节点，则节点 i 的链路带宽 B_{wi} 为 0。

[0013] 作为本发明的一种优选技术方案：步骤 S2 中所述深度图学习方法包括四个图学习神经网络和一个经验池，四个图学习神经网络分别为在线图策略网络、在线图价值网络、目标图策略网络、目标图价值网络，四个图学习神经网络分别均包括一个输入层、两个隐藏层、一个输出层。

[0014] 在线图策略网络、目标图策略网络的输入层以图邻接矩阵 A 、网络信息特征矩阵 H

为输入，在线图策略网络、目标图策略网络的输出分别作为在线图价值网络、目标图价值网络的输入，其中，各图学习神经网络的输入层到隐藏层、以及隐藏层之间的传播公式相同，将输入层记为第 0 层，第一个隐藏层记为第 1 层，第二个隐藏层记为第 2 层，则传播公式如下式：

$$H^{l+1} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^l W^{l+1} \right)$$

式中， $\sigma(\cdot)$ 表示将括号内部的公式进行归一化， H^l 为第 l 层的网络信息特征矩阵， W^{l+1} 为第 l+1 层的权重矩阵，其中， $H^0 = H$ ， $\tilde{A} = A + I$ ， I 为 x 阶单位矩阵， $\tilde{D}$ 为 $\tilde{A}$ 的度矩阵， $\tilde{D}$ 如下式：

$$\tilde{D} = \text{diag}(\tilde{d}_1, \tilde{d}_2, \dots, \tilde{d}_i, \dots, \tilde{d}_x)$$

其中， $\tilde{d}_i$ 如下式：

$$\tilde{d}_i = 1 + \sum_{j=1}^x a_{ij}$$

其中，在线图策略网络、目标图策略网络中， W^1 是一个 4×4 的矩阵， W^2 是一个 4×1 的矩阵，输出层为全连接层，其输出值为 $x \times 1$ 矩阵，记为路由策略 *Policy*，具体如下式：

$$Policy = H^2 \times K$$

式中， K 为在线图策略网络、目标图策略网络输出层的权重矩阵， H^2 为第 2 层的网络信息特征矩阵；在线图价值网络、目标图价值网络中， W^1 和 W^2 均为 1×1 的矩阵，输出层为聚合层，其输出值为 1×1 矩阵，记为 *Value*，具体如下式：

$$Value = Q \times \frac{\sum_{i=1}^x h_i^2}{x}$$

式中， Q 为输出层的权重值， h_i^2 为第 2 层的网络信息特征矩阵 H^2 中的第 i 个值；根据在线图策略网络输出的路由策略 *Policy*，更新目标 SDN 网络中各条链路的路由开销。

[0015] 作为本发明的一种优选技术方案：步骤 S2 的具体步骤如下：

步骤 S2.1:对在线图策略网络、在线图价值网络、目标策略网络、目标图价值网络的权重矩阵初始化，其中，在线图策略网络的权重矩阵为 W_θ ，在线图价值网络的权重矩阵为 $W_{\theta'}$ ，目标图策略网络的权重矩阵为 W_ω ，目标图价值网络的权重矩阵为 $W_{\omega'}$ 。

[0016] 步骤 S2.2:对经验池进行初始化，具体步骤如下：

步骤 S2.2.1:以图邻接矩阵 A 、网络信息特征矩阵 H 作为目标 SDN 网络的状态 S ，定义

$S = [A, H]$, s_t 表示 t 时刻目标 SDN 网络的状态, $s_t = [A_t, H_t]$, A_t 表示 t 时刻目标 SDN 网络的图邻接矩阵, H_t 表示 t 时刻目标 SDN 网络的网络信息特征矩阵。

[0017] 步骤 S2.2.2: 定义 $Policy_t^O$ 、 $Policy_t^T$ 、 $Value_t^O$ 、 $Value_t^T$ 分别为在线图策略网络、目标图策略网络、在线图价值网络、目标图价值网络的输出层在 t 时刻的输出; 根据下式计算在线图策略网络输出路由策略 $Policy_t^O$ 所获得的环境反馈 f_t :

$$f_t = U(B_w, T_h, L_p, D_t) \times K_f$$

式中, $U(B_w, T_h, L_p, D_t)$ 为链路利用率, B_w 、 T_h 、 L_p 、 D_t 分别为目标 SDN 网络的链路带宽、流量、丢包率、传输时延, K_f 为比例系数; 构建目标 SDN 网络链路利用率最大化的目标函数为 $U_{\max}(B_w, T_h, L_p, D_t)$ 。

[0018] 步骤 S2.2.3: 定义经验池 R 如下式:

$$R = (s_t, Policy_t^O, s_{t+1}, f_t)$$

式中, s_{t+1} 表示 $t+1$ 时刻目标 SDN 网络的状态, 即在线图策略网络输出路由策略 $Policy_t^O$ 所获得目标 SDN 网络的状态。

[0019] 步骤 S2.3: 针对目标 SDN 网络, 进行预设次数的迭代, 其中预设迭代次数为 T , 具体步骤如下:

步骤 S2.3.1: 令 $t=1$, 获取目标 SDN 网络的初始状态 s_1 ;

步骤 S2.3.2: 在线图策略网络根据 t 时刻目标 SDN 网络的状态 s_t , 输出路由策略 $Policy_t^O$,

过程记为 $Policy_t^O = \pi(s_t|\theta)$, 其中, θ 为在线图策略网络的网络参数;

步骤 S2.3.3: 根据路由策略 $Policy_t^O$, 更新目标 SDN 网络中各条链路的路由开销;

步骤 S2.3.4: 获取根据路由策略 $Policy_t^O$ 更新后的目标 SDN 网络的状态 s_{t+1} , 同时获取环境反馈 f_t ;

步骤 S2.3.5: 将 $(s_t, Policy_t^O, s_{t+1}, f_t)$ 作为一组历史记录存入经验池 R 中;

步骤 S2.3.6: 从经验池 R 中随机抽取 Y 组历史记录 $(s_m, Policy_m^O, s_{m+1}, f_m)$, 其中, 下标 m 表示经验池 R 中任意一组历史记录;

步骤 S2.3.7: 根据步骤 S2.3.6 所抽取的历史记录 $(s_m, Policy_m^O, s_{m+1}, f_m)$, 计算目标图价值

网络所对应的输出 $Value_m^T$ 如下式:

$$Value_m^T = f_m + \gamma Value_{m+1}^T(s_{m+1}, \pi'(s_{m+1}|\theta'))|\omega')$$

式中, $\pi'(s_{m+1}|\theta') = Policy_{m+1}^T$, 表示目标图策略网络根据目标 SDN 网络的状态 s_{m+1} 所选择的路由策略, θ' 为目标图策略网络的网络参数, ω' 为目标图价值网络的网络参数, $Value_{m+1}^T(s_{m+1}, \pi'(s_{m+1}|\theta'))|\omega')$ 表示目标图价值网络基于目标 SDN 网络的状态 s_{m+1} 、且网络参数为 ω' 时, 目标图策略网络所选取的路由策略 $\pi'(s_{m+1}|\theta')$ 的期望值, γ 为折扣因子, 是一个常数, 且 $\gamma \in (0,1)$;

步骤 S2.3.8:根据下式计算在线图价值网络输出值的损失 $Loss_{ogvn}$:

$$Loss_{ogvn} = \frac{1}{Y} \sum_{m=1}^Y (Value_m^T - Value_m^O)^2$$

式中, $Value_m^O = Value_m^O(s_m, \pi(s_m|\theta))|\omega)$, 表示网络参数 ω 的在线图价值网络在目标 SDN 网络的状态 s_m 下, 在线图策略网络输出的路由策略为 $\pi(s_m|\theta)$ 时, 在线图价值网络输出的价值;

步骤 S2.3.9:根据在线图价值网络输出值的损失 $Loss_{ogvn}$, 基于梯度反向传播方法, 更新在线图价值网络的网络参数 ω ;

步骤 S2.3.10:计算梯度值 $\nabla_{\theta} = \frac{1}{Y} \sum_{m=1}^Y \nabla(Value_m^O) \nabla(\pi(s_m|\theta))$, 根据梯度值 ∇_{θ} , 基于梯度反向传播方法, 更新在线图策略网络的网络参数 θ , 其中 $\nabla(\cdot)$ 表示对括号内公式求梯度;

步骤 S2.3.11:分别根据下式, 更新目标图策略网络的网络参数 θ' 、目标图价值网络的网络参数 ω' :

$$\theta' = \tau\theta + (1 - \tau)\theta'$$

$$\omega' = \tau\omega + (1 - \tau)\omega'$$

式中, τ 为常数, 且 $\tau \in (0,1)$;

步骤 S2.3.12:重复 S2.3.2 至步骤 S2.3.11, 直至迭代次数达到预设次数 T , 获得使目标 SDN

网络路由开销最小的路由策略。

[0020] 作为本发明的一种优选技术方案：步骤 S3 的具体步骤如下：

步骤 S31:获取目标 SDN 网络的图邻接矩阵 A 、网络信息特征矩阵 H ；

步骤 S32:基于训练好的深度图学习模型，根据目标 SDN 网络的状态 $[A, H]$ ，获得使目标 SDN 网络路由开销最小的路由策略；

步骤 S33:根据步骤 S32 所获得的路由策略，部署至目标 SDN 网络，根据路由策略改变目标 SDN 网络的各链路权重；

步骤 S34:在流量传输过程中，根据最短路径方案，采用更新后的各链路权重进行流量传输。

[0021] 本发明还设计一种基于图结构特征的路由优化方法的系统，目标 SDN 网络包括控制平面、数据平面，其中，控制平面包括信息获取模块、策略部署模块、DGL 模块；使得所述基于图结构特征的路由优化方法的系统实现所述基于图结构特征的路由优化方法。

[0022] 目标 SDN 网络的各链路及各节点部署于数据平面，控制平面上的信息获取模块用于获取目标 SDN 网络的网络拓扑图，生成图邻接矩阵、网络信息特征矩阵，发送至 DGL 模块。

[0023] DGL 模块基于图学习神经网络，以图邻接矩阵、网络信息特征矩阵为输入，通过深度图学习方法，以当前状态下目标 SDN 网络的路由开销为输出，基于梯度反向传播方法，更新图学习神经网络的网络参数，并经过预设次数的迭代，对图学习神经网络进行训练，获得使目标 SDN 网络路由开销最小、链路利用率最大的深度图学习模型。

[0024] 控制平面上的策略部署模块用于根据 DGL 模块所获得的训练好的深度图学习模型，基于目标 SDN 网络的状态，获得使目标 SDN 网络路由开销最小的路由策略，并将路由策略及目标 SDN 网络路由开销发送到数据平面。

[0025] 有益效果：相对于现有技术，本发明的优点包括：

- 1.采用图学习神经网络获取网络拓扑之中节点和链路之间的空间关系；
- 2.采用策略网络和价值网络的方式，对算法进行无监督学习，使得算法的学习能力更加细致；
- 3.利用智能算法优化 SDN 网络环境下的路由开销，提升了链路利用率，从而在优化了平均端到端时延、丢包率、吞吐量等；
- 4.深度图学习模型具有强的泛化能力，训练后的深度图学习模型在网络拓扑变化时依旧有效，能够适应大规模的动态、复杂网络。

附图说明

[0026] 图 1 是根据本发明实施例提供的基于图结构特征的路由优化方法的系统的整体框图；图 2 是根据本发明实施例提供的 DGL 算法框架图；

图3是根据本发明实施例提供的图学习神经网络结构图。

具体实施方式

[0027] 下面结合附图对本发明作进一步描述。以下实施例仅用于更加清楚地说明本发明的技术方案，而不能以此来限制本发明的保护范围。

[0028] 本发明实施例提供一种基于图结构特征的路由优化方法，针对目标 SDN 网络，执行以下步骤 S1-步骤 S3，获得目标 SDN 网络中各条链路的路由开销，调整各条链路的权重，完成目标 SDN 网络的路由优化。

[0029] 步骤 S1:参照图 1，针对目标 SDN 网络，基于南向接口协议，获取目标 SDN 网络的网络拓扑图，根据网络拓扑图中目标 SDN 网络的各链路上各节点之间的连接关系，构建图邻接矩阵，分别针对目标 SDN 网络的各链路上各节点，根据各节点的链路带宽、流量、丢包率、传输时延，构建各节点的信息特征向量，并基于各节点的信息特征向量，构建目标 SDN 网络的网络信息特征矩阵。

[0030] 步骤 S1 的具体步骤如下：

步骤 S1.1:针对目标 SDN 网络，基于南向接口协议，获取目标 SDN 网络的网络拓扑结构，其中网络拓扑结构包含 M 个路由器、N 条链路。

[0031] 步骤 S1.2:针对目标 SDN 网络的网络拓扑结构，每个路由器对应一个实节点，每条链路对应一条边，在每条链路所对应的边上插入虚节点，将目标 SDN 网络的网络拓扑结构表示为 M 个实节点、N 个虚节点、2N 条边的网络拓扑图 $G(V,E)$ ，其中， V 表示节点集合， E 表示边集合，具体如下式：

$$V = \{V_{\text{实}}, V_{\text{虚}}\}$$

其中， $V_{\text{实}}$ 表示实节点集合， $V_{\text{虚}}$ 表示虚节点集合；

$$V_{\text{实}} = \{v_{s1}, v_{s2}, \dots, v_{sM}\}$$

其中， $v_{s1}, v_{s2}, \dots, v_{sM}$ 表示 M 个实节点；

$$V_{\text{虚}} = \{v_{x1}, v_{x2}, \dots, v_{xN}\}$$

其中， $v_{x1}, v_{x2}, \dots, v_{xN}$ 表示 N 个虚节点；

$$E = \{e_1, e_2, \dots, e_{2N}\}$$

其中， $e_1, e_2, \dots, e_{2N}$ 表示 2N 条边。

[0032] 步骤 S1.3:令 $x=M+N$, x 表示节点总数, 节点包括 M 个实节点、 N 个虚节点, 基于目标 SDN 网络的网络拓扑图, 构建 x 阶的图邻接矩阵 A 如下式:

$$A = \begin{bmatrix} a_{11} & \cdots & a_{1x} \\ \vdots & \ddots & \vdots \\ a_{x1} & \cdots & a_{xx} \end{bmatrix}$$

其中, 图邻接矩阵 A 中的元素 a_{ij} 如下式:

$$a_{ij} = \begin{cases} 1 & \text{节点} i \text{ 和节点} j \text{ 之间相连} \\ 0 & \text{节点} i \text{ 和节点} j \text{ 之间不相连} \end{cases}。$$

[0033] 步骤 S1.4:针对目标 SDN 网络的任一节点 i , 根据节点 i 的链路带宽、流量、丢包率、传输时延, 构建节点 i 的信息特征向量 h_i 如下式:

$$h_i = [B_{wi}, T_{hi}, L_{pi}, D_{ti}]$$

式中, B_{wi} 为节点 i 的链路带宽, T_{hi} 为节点 i 的流量, L_{pi} 为节点 i 的丢包率, D_{ti} 为节点 i 的传输时延。

[0034] 所述节点 i , 若节点 i 为虚节点, 则节点 i 的流量 T_{hi} 、丢包率 L_{pi} 、传输时延 D_{ti} 为 0, 若节点 i 为实节点, 则节点 i 的链路带宽 B_{wi} 为 0。

[0035] 基于各节点的信息特征向量, 构建目标 SDN 网络的网络信息特征矩阵 H 如下式:

$$H = \begin{Bmatrix} h_1 \\ h_2 \\ \vdots \\ h_i \\ \vdots \\ h_x \end{Bmatrix}$$

式中, $h_1, h_2, \dots, h_i, \dots, h_x$ 为各节点的信息特征向量。

[0036] 步骤 S2:以图邻接矩阵、网络信息特征矩阵为目标 SDN 网络的状态, 基于图学习神经网络, 以图邻接矩阵、网络信息特征矩阵为输入, 通过深度图学习方法 (Deep Graph Learning, DGL), 以当前状态下目标 SDN 网络的路由策略、路由开销为输出, 基于梯度反向传播方法, 更新图学习神经网络的网络参数, 并经过预设次数的迭代, 对图学习神经网络

进行训练, 获得使目标 SDN 网络路由开销最小、链路利用率最大的深度图学习模型。

[0037] 步骤 S2 中所述深度图学习方法包括四个图学习神经网络和一个经验池, 参照图 2, 四个图学习神经网络分别为在线图策略网络(Online Graph Strategy Network, OGSN)、在线图价值网络(Online Graph Value Network, OGVN)、目标图策略网络(Target Graph Strategy Network, TGSN)、目标图价值网络(Target Graph Value Network, TGVN), 参照图 3, 四个图学习神经网络分别均包括一个输入层、两个隐藏层、一个输出层。

[0038] 在线图策略网络、目标图策略网络的输入层以图邻接矩阵 A 、网络信息特征矩阵 H 为输入, 在线图策略网络、目标图策略网络的输出分别作为在线图价值网络、目标图价值网络的输入, 其中, 各图学习神经网络的输入层到隐藏层、以及隐藏层之间的传播公式相同, 将输入层记为第 0 层, 第一个隐藏层记为第 1 层, 第二个隐藏层记为第 2 层, 则传播公式如下式:

$$H^{l+1} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^l W^{l+1} \right)$$

式中, $\sigma(\cdot)$ 表示将括号内部的公式进行归一化, H^l 为第 l 层的网络信息特征矩阵, W^{l+1} 为第 $l+1$ 层的权重矩阵, 其中, $H^0 = H$, $\tilde{A} = A + I$, I 为 x 阶单位矩阵, $\tilde{D}$ 为 $\tilde{A}$ 的度矩阵, $\tilde{D}$ 如下式:

$$\tilde{D} = \text{diag}(\tilde{d}_1, \tilde{d}_2, \dots, \tilde{d}_i, \dots, \tilde{d}_x)$$

其中, $\tilde{d}_i$ 如下式:

$$\tilde{d}_i = 1 + \sum_{j=1}^x a_{ij}$$

其中, 在线图策略网络、目标图策略网络中, W^1 是一个 4×4 的矩阵, W^2 是一个 4×1 的矩阵, 输出层为全连接层, 其输出值为 $x \times 1$ 矩阵, 记为路由策略 *Policy*, 具体如下式:

$$Policy = H^2 \times K$$

式中, K 为在线图策略网络、目标图策略网络输出层的权重矩阵, H^2 为第 2 层的网络信息特征矩阵。

[0039] 在线图价值网络、目标图价值网络中, W^1 和 W^2 均为 1×1 的矩阵, 输出层为聚合层, 其输出值为 1×1 矩阵, 记为 *Value*, 具体如下式:

$$Value = Q \times \frac{\sum_{i=1}^x h_i^2}{x}$$

式中, Q 为输出层的权重值, h_i^2 为第 2 层的网络信息特征矩阵 H^2 中的第 i 个值; 根据在线图策略网络输出的路由策略 $Policy$, 更新目标 SDN 网络中各条链路的路由开销。

[0040] 参照图 2, 步骤 S2 的具体步骤如下:

步骤 S2.1: 对在线图策略网络、在线图价值网络、目标策略网络、目标图价值网络的权重矩阵初始化, 其中, 在线图策略网络的权重矩阵为 W_θ , 在线图价值网络的权重矩阵为 $W_{\theta'}$, 目标图策略网络的权重矩阵为 W_ω , 目标图价值网络的权重矩阵为 $W_{\omega'}$, 初始化时, 在线图策略网络、目标策略网络的网络参数一致, 在线图价值网络、目标图价值网络的网络参数一致。

[0041] 步骤 S2.2: 对经验池进行初始化, 具体步骤如下:

步骤 S2.2.1: 以图邻接矩阵 A 、网络信息特征矩阵 H 作为目标 SDN 网络的状态 S , 定义 $S = [A, H]$, S_t 表示 t 时刻目标 SDN 网络的状态, $s_t = [A_t, H_t]$, A_t 表示 t 时刻目标 SDN 网络的图邻接矩阵, H_t 表示 t 时刻目标 SDN 网络的网络信息特征矩阵。

[0042] 步骤 S2.2.2: 定义 $Policy_t^O$ 、 $Policy_t^T$ 、 $Value_t^O$ 、 $Value_t^T$ 分别为在线图策略网络、目标图策略网络、在线图价值网络、目标图价值网络的输出层在 t 时刻的输出; 根据下式计算在线图策略网络输出路由策略 $Policy_t^O$ 所获得的环境反馈 f_t :

$$f_t = U(B_w, T_h, L_p, D_t) \times K_f$$

式中, $U(B_w, T_h, L_p, D_t)$ 为链路利用率, B_w 、 T_h 、 L_p 、 D_t 分别为目标 SDN 网络的链路带宽、流量、丢包率、传输时延, K_f 为比例系数。

[0043] 构建目标 SDN 网络链路利用率最大化的目标函数为 $U_{\max}(B_w, T_h, L_p, D_t)$ 。

[0044] 步骤 S2.2.3: 定义经验池 R 如下式:

$$R = (s_t, Policy_t^O, s_{t+1}, f_t)$$

式中, S_{t+1} 表示 $t+1$ 时刻目标 SDN 网络的状态, 即在线图策略网络输出路由策略 $Policy_t^O$ 所获得目标 SDN 网络的状态。

[0045] 步骤 S2.3:针对目标 SDN 网络, 进行预设次数的迭代, 其中预设迭代次数为 T , 具体步骤如下:

步骤 S2.3.1:令 $t=1$, 获取目标 SDN 网络的初始状态 S_1 ;

步骤 S2.3.2:在线图策略网络根据 t 时刻目标 SDN 网络的状态 S_t , 输出路由策略 $Policy_t^O$, 过程记为 $Policy_t^O = \pi(s_t|\theta)$, 其中, θ 为在线图策略网络的网络参数;

步骤 S2.3.3:根据路由策略 $Policy_t^O$, 更新目标 SDN 网络中各条链路的路由开销;

步骤 S2.3.4:获取根据路由策略 $Policy_t^O$ 更新后的目标 SDN 网络的状态 S_{t+1} , 同时获取环境反馈 f_t ;

步骤 S2.3.5:将 $(s_t, Policy_t^O, s_{t+1}, f_t)$ 作为一组历史记录存入经验池 R 中;

步骤 S2.3.6:从经验池 R 中随机抽取 Y 组历史记录 $(s_m, Policy_m^O, s_{m+1}, f_m)$, 其中, 下标 m 表示经验池 R 中任意一组历史记录;

步骤 S2.3.7:根据步骤 S2.3.6 所抽取的历史记录 $(s_m, Policy_m^O, s_{m+1}, f_m)$, 计算目标图价值网络所对应的输出 $Value_m^T$ 如下式:

$$Value_m^T = f_m + \gamma Value_{m+1}^T(s_{m+1}, \pi'(s_{m+1}|\theta')|\omega')$$

式中, $\pi'(s_{m+1}|\theta') = Policy_{m+1}^T$, 表示目标图策略网络根据目标 SDN 网络的状态 S_{m+1} 所选择的路由策略, θ' 为目标图策略网络的网络参数, ω' 为目标图价值网络的网络参数, $Value_{m+1}^T(s_{m+1}, \pi'(s_{m+1}|\theta')|\omega')$ 表示目标图价值网络基于目标 SDN 网络的状态 S_{m+1} 、且网络参数为 ω' 时, 目标图策略网络所选取的路由策略 $\pi'(s_{m+1}|\theta')$ 的期望值, γ 为折扣因子, 是一个常数, 且 $\gamma \in (0,1)$ 。

[0046] 步骤 S2.3.8:根据下式计算在线图价值网络输出值的损失 $Loss_{ogvn}$:

$$Loss_{ogvn} = \frac{1}{Y} \sum_{m=1}^Y (Value_m^T - Value_m^O)^2$$

式中, $Value_m^O = Value_m^O(s_m, \pi(s_m|\theta)|\omega)$, 表示网络参数 ω 的在线图价值网络在目标 SDN 网络的状态 S_m 下, 在线图策略网络输出的路由策略为 $\pi(s_m|\theta)$ 时, 在线图价值网络

输出的价值。

[0047] 步骤 S2.3.9:根据在线图价值网络输出值的损失 $Loss_{ogvn}$ ，基于梯度反向传播方法，更新在线图价值网络的网络参数 ω 。

[0048] 步骤 S2.3.10:计算梯度值 $\nabla_{\theta} = \frac{1}{Y} \sum_{m=1}^Y \nabla(Value_m^O) \nabla(\pi(s_m|\theta))$ ，根据梯度值 ∇_{θ} ，基于梯度反向传播方法，更新在线图策略网络的网络参数 θ ，其中 $\nabla(\cdot)$ 表示对括号内公式求梯度。

[0049] 步骤 S2.3.11:分别根据下式，更新目标图策略网络的网络参数 θ' 、目标图价值网络的网络参数 ω' ：

$$\theta' = \tau\theta + (1 - \tau)\theta'$$

$$\omega' = \tau\omega + (1 - \tau)\omega'$$

式中， τ 为常数，且 $\tau \in (0,1)$ 。

[0050] 步骤 S2.3.12:重复 S2.3.2 至步骤 S2.3.11，直至迭代次数达到预设次数 T ，获得使目标 SDN 网络路由开销最小的路由策略。

[0051] 步骤 S3:根据训练好的深度图学习模型，基于目标 SDN 网络的状态，获得使目标 SDN 网络路由开销最小的路由策略，将路由策略部署至目标 SDN 网络，根据路由策略改变目标 SDN 网络的各链路权重，完成目标 SDN 网络的路由优化。

[0052] 步骤 S3 的具体步骤如下：

步骤 S31:获取目标 SDN 网络的图邻接矩阵 A 、网络信息特征矩阵 H ；

步骤 S32:基于训练好的深度图学习模型，根据目标 SDN 网络的状态 $[A, H]$ ，获得使目标 SDN 网络路由开销最小的路由策略；

步骤 S33:根据步骤 S32 所获得的路由策略，部署至目标 SDN 网络，根据路由策略改变目标 SDN 网络的各链路权重；

步骤 S34:在流量传输过程中，根据最短路径方案，采用更新后的各链路权重进行流量传输。

[0053] 本发明实施例还提供一种基于图结构特征的路由优化方法的系统，参照图 1，目标 SDN 网络包括控制平面、数据平面，其中，控制平面包括信息获取模块、策略部署模块、DGL 模块；使得所述基于图结构特征的路由优化方法的系统实现所述基于图结构特征的路由优化方法。

[0054] 目标 SDN 网络的各链路及各节点部署于数据平面，控制平面上的信息获取模块用于获取目标 SDN 网络的网络拓扑图，生成图邻接矩阵、网络信息特征矩阵，发送至 DGL 模块。

[0055] DGL 模块基于图学习神经网络，以图邻接矩阵、网络信息特征矩阵为输入，通过深度图学习方法，以当前状态下目标 SDN 网络的路由开销为输出，基于梯度反向传播方法，更新图学习神经网络的网络参数，并经过预设次数的迭代，对图学习神经网络进行训练，获得使目标 SDN 网络路由开销最小、链路利用率最大的深度图学习模型。

[0056] 控制平面上的策略部署模块用于根据 DGL 模块所获得的训练好的深度图学习模型，基于目标 SDN 网络的状态，获得使目标 SDN 网络路由开销最小的路由策略，并将路由策略及目标 SDN 网络路由开销发送到数据平面。

[0057] 上面结合附图对本发明的实施方式作了详细说明，但是本发明并不限于上述实施方式，在本领域普通技术人员所具备的知识范围内，还可以在不脱离本发明宗旨的前提下做出各种变化。

权利要求书

1. 一种基于图结构特征的路由优化方法，其特征在于，针对目标 SDN 网络，执行以下步骤 S1-步骤 S3，获得目标 SDN 网络中各条链路的路由开销，调整各条链路的权重，完成目标 SDN 网络的路由优化：

步骤 S1:针对目标 SDN 网络，基于南向接口协议，获取目标 SDN 网络的网络拓扑图，根据网络拓扑图中目标 SDN 网络的各链路上各节点之间的连接关系，构建图邻接矩阵，分别针对目标 SDN 网络的各链路上各节点，根据各节点的链路带宽、流量、丢包率、传输时延，构建各节点的信息特征向量，并基于各节点的信息特征向量，构建目标 SDN 网络的网络信息特征矩阵；

步骤 S2:以图邻接矩阵、网络信息特征矩阵为目标 SDN 网络的状态，基于图学习神经网络，以图邻接矩阵、网络信息特征矩阵为输入，通过深度图学习方法，以当前状态下目标 SDN 网络的路由策略、路由开销为输出，基于梯度反向传播方法，更新图学习神经网络的网络参数，并经过预设次数的迭代，对图学习神经网络进行训练，获得使目标 SDN 网络路由开销最小、链路利用率最大的深度图学习模型；

步骤 S3:根据训练好的深度图学习模型，基于目标 SDN 网络的状态，获得使目标 SDN 网络路由开销最小的路由策略，将路由策略部署至目标 SDN 网络，根据路由策略改变目标 SDN 网络的各链路权重，完成目标 SDN 网络的路由优化。

2. 根据权利要求 1 所述的一种基于图结构特征的路由优化方法，其特征在于，步骤 S1 的具体步骤如下：

步骤 S1.1:针对目标 SDN 网络，基于南向接口协议，获取目标 SDN 网络的网络拓扑结构，其中网络拓扑结构包含 M 个路由器、N 条链路；

步骤 S1.2:针对目标 SDN 网络的网络拓扑结构，每个路由器对应一个实节点，每条链路对应一条边，在每条链路所对应的边上插入虚节点，将目标 SDN 网络的网络拓扑结构表示为 M 个实节点、N 个虚节点、2N 条边的网络拓扑图 $G(V,E)$ ，其中， V 表示节点集合， E 表示边集合，具体如下式：

$$V = \{V_{\text{实}}, V_{\text{虚}}\}$$

其中， $V_{\text{实}}$ 表示实节点集合， $V_{\text{虚}}$ 表示虚节点集合；

$$V_{\text{实}} = \{v_{s1}, v_{s2}, \dots, v_{sM}\}$$

其中， $v_{s1}, v_{s2}, \dots, v_{sM}$ 表示 M 个实节点；

$$V_{\text{虚}} = \{v_{x1}, v_{x2}, \dots, v_{xN}\}$$

其中, $v_{x1}, v_{x2}, \dots, v_{xN}$ 表示 N 个虚节点;

$$E = \{e_1, e_2, \dots, e_{2N}\}$$

其中, $e_1, e_2, \dots, e_{2N}$ 表示 $2N$ 条边;

步骤 S1.3: 令 $x=M+N$, x 表示节点总数, 节点包括 M 个实节点、 N 个虚节点, 基于目标 SDN 网络的网络拓扑图, 构建 x 阶的图邻接矩阵 A 如下式:

$$A = \begin{bmatrix} a_{11} & \dots & a_{1x} \\ \vdots & \ddots & \vdots \\ a_{x1} & \dots & a_{xx} \end{bmatrix}$$

其中, 图邻接矩阵 A 中的元素 a_{ij} 如下式:

$$a_{ij} = \begin{cases} 1 & \text{节点 } i \text{ 和节点 } j \text{ 之间相连} \\ 0 & \text{节点 } i \text{ 和节点 } j \text{ 之间不相连} \end{cases}$$

步骤 S1.4: 针对目标 SDN 网络的任一节点 i , 根据节点 i 的链路带宽、流量、丢包率、传输时延, 构建节点 i 的信息特征向量 h_i 如下式:

$$h_i = [B_{wi}, T_{hi}, L_{pi}, D_{ti}]$$

式中, B_{wi} 为节点 i 的链路带宽, T_{hi} 为节点 i 的流量, L_{pi} 为节点 i 的丢包率, D_{ti} 为节点 i 的传输时延;

基于各节点的信息特征向量, 构建目标 SDN 网络的网络信息特征矩阵 H 如下式:

$$H = \begin{Bmatrix} h_1 \\ h_2 \\ \vdots \\ h_i \\ \vdots \\ h_x \end{Bmatrix}$$

式中, $h_1, h_2, \dots, h_i, \dots, h_x$ 为各节点的信息特征向量。

3. 根据权利要求 2 所述的一种基于图结构特征的路由优化方法, 其特征在于, 步骤 S1.4 中

所述的节点 i ，若节点 i 为虚节点，则节点 i 的流量 T_{hi} 、丢包率 L_{pi} 、传输时延 D_{ti} 为 0，若节点 i 为实节点，则节点 i 的链路带宽 B_{wi} 为 0。

4. 根据权利要求 2 所述的一种基于图结构特征的路由优化方法，其特征在于，步骤 S2 中所述深度图学习方法包括四个图学习神经网络和一个经验池，四个图学习神经网络分别为在线图策略网络、在线图价值网络、目标图策略网络、目标图价值网络，四个图学习神经网络分别均包括一个输入层、两个隐藏层、一个输出层；

在线图策略网络、目标图策略网络的输入层以图邻接矩阵 A 、网络信息特征矩阵 H 为输入，在线图策略网络、目标图策略网络的输出分别作为在线图价值网络、目标图价值网络的输入，其中，各图学习神经网络的输入层到隐藏层、以及隐藏层之间的传播公式相同，将输入层记为第 0 层，第一个隐藏层记为第 1 层，第二个隐藏层记为第 2 层，则传播公式如下式：

$$H^{l+1} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^l W^{l+1} \right)$$

式中， $\sigma(\cdot)$ 表示将括号内部的公式进行归一化， H^l 为第 l 层的网络信息特征矩阵， W^{l+1} 为第 $l+1$ 层的权重矩阵，其中， $H^0 = H$ ， $\tilde{A} = A + I$ ， I 为 x 阶单位矩阵， $\tilde{D}$ 为 $\tilde{A}$ 的度矩阵， $\tilde{D}$ 如下式：

$$\tilde{D} = \text{diag}(\tilde{d}_1, \tilde{d}_2, \dots, \tilde{d}_i, \dots, \tilde{d}_x)$$

其中， $\tilde{d}_i$ 如下式：

$$\tilde{d}_i = 1 + \sum_{j=1}^x a_{ij}$$

其中，在线图策略网络、目标图策略网络中， W^1 是一个 4×4 的矩阵， W^2 是一个 4×1 的矩阵，输出层为全连接层，其输出值为 $x \times 1$ 矩阵，记为路由策略 *Policy*，具体如下式：

$$Policy = H^2 \times K$$

式中， K 为在线图策略网络、目标图策略网络输出层的权重矩阵， H^2 为第 2 层的网络信息特征矩阵；

在线图价值网络、目标图价值网络中， W^1 和 W^2 均为 1×1 的矩阵，输出层为聚合层，其输出值为 1×1 矩阵，记为 *Value*，具体如下式：

$$Value = Q \times \frac{\sum_{i=1}^x h_i^2}{x}$$

式中, Q 为输出层的权重值, h_i^2 为第 2 层的网络信息特征矩阵 H^2 中的第 i 个值;

根据在线图策略网络输出的路由策略 $Policy$, 更新目标 SDN 网络中各条链路的路由开销。

5. 根据权利要求 4 所述的一种基于图结构特征的路由优化方法, 其特征在于, 步骤 S2 的具体步骤如下:

步骤 S2.1: 对在线图策略网络、在线图价值网络、目标策略网络、目标图价值网络的权重矩阵初始化, 其中, 在线图策略网络的权重矩阵为 W_θ , 在线图价值网络的权重矩阵为 $W_{\theta'}$, 目标图策略网络的权重矩阵为 W_ω , 目标图价值网络的权重矩阵为 $W_{\omega'}$;

步骤 S2.2: 对经验池进行初始化, 具体步骤如下:

步骤 S2.2.1: 以图邻接矩阵 A 、网络信息特征矩阵 H 作为目标 SDN 网络的状态 S , 定义 $S = [A, H]$, s_t 表示 t 时刻目标 SDN 网络的状态, $s_t = [A_t, H_t]$, A_t 表示 t 时刻目标 SDN 网络的图邻接矩阵, H_t 表示 t 时刻目标 SDN 网络的网络信息特征矩阵;

步骤 S2.2.2: 定义 $Policy_t^O$ 、 $Policy_t^T$ 、 $Value_t^O$ 、 $Value_t^T$ 分别为在线图策略网络、目标图策略网络、在线图价值网络、目标图价值网络的输出层在 t 时刻的输出; 根据下式计算在线图策略网络输出路由策略 $Policy_t^O$ 所获得的环境反馈 f_t :

$$f_t = U(B_w, T_h, L_p, D_t) \times K_f$$

式中, $U(B_w, T_h, L_p, D_t)$ 为链路利用率, B_w 、 T_h 、 L_p 、 D_t 分别为目标 SDN 网络的链路带宽、流量、丢包率、传输时延, K_f 为比例系数;

构建目标 SDN 网络链路利用率最大化的目标函数为 $U_{\max}(B_w, T_h, L_p, D_t)$;

步骤 S2.2.3: 定义经验池 R 如下式:

$$R = (s_t, Policy_t^O, s_{t+1}, f_t)$$

式中, s_{t+1} 表示 $t+1$ 时刻目标 SDN 网络的状态, 即在线图策略网络输出路由策略 $Policy_t^O$ 所获得目标 SDN 网络的状态;

步骤 S2.3: 针对目标 SDN 网络, 进行预设次数的迭代, 其中预设迭代次数为 T , 具体步骤如

下:

步骤 S2.3.1:令 $t=1$ ，获取目标 SDN 网络的初始状态 S_1 ；

步骤 S2.3.2:在线图策略网络根据 t 时刻目标 SDN 网络的状态 S_t ，输出路由策略 $Policy_t^O$ ，

过程记为 $Policy_t^O = \pi(s_t|\theta)$ ，其中， θ 为在线图策略网络的网络参数；

步骤 S2.3.3:根据路由策略 $Policy_t^O$ ，更新目标 SDN 网络中各条链路的路由开销；

步骤 S2.3.4:获取根据路由策略 $Policy_t^O$ 更新后的目标 SDN 网络的状态 S_{t+1} ，同时获取环境反馈 f_t ；

步骤 S2.3.5:将 $(s_t, Policy_t^O, s_{t+1}, f_t)$ 作为一组历史记录存入经验池 R 中；

步骤 S2.3.6:从经验池 R 中随机抽取 Y 组历史记录 $(s_m, Policy_m^O, s_{m+1}, f_m)$ ，其中，下标 m 表示经验池 R 中任意一组历史记录；

步骤 S2.3.7:根据步骤 S2.3.6 所抽取的历史记录 $(s_m, Policy_m^O, s_{m+1}, f_m)$ ，计算目标图价值网络所对应的输出 $Value_m^T$ 如下式：

$$Value_m^T = f_m + \gamma Value_{m+1}^T(s_{m+1}, \pi'(s_{m+1}|\theta')|\omega')$$

式中， $\pi'(s_{m+1}|\theta') = Policy_{m+1}^T$ 表示目标图策略网络根据目标 SDN 网络的状态 s_{m+1} 所选择的路由策略， θ' 所选择的路由策略， ω' 为目标图价值网络的网络参数，

$Value_{m+1}^T(s_{m+1}, \pi'(s_{m+1}|\theta')|\omega')$ 表示目标图价值网络基于目标 SDN 网络的状态 s_{m+1} 且网络参数为 ω' 时，目标图策略网络所选取的路由策略 $\pi'(s_{m+1}|\theta')$ 的期望值，

γ 为折扣因子，是一个常数，且 $\gamma \in (0,1)$ ；

步骤 S2.3.8:根据下式计算在线图价值网络输出值的损失 $Loss_{ogvn}$ ：

$$Loss_{ogvn} = \frac{1}{Y} \sum_{m=1}^Y (Value_m^T - Value_m^O)^2$$

式中， $Value_m^O = Value_m^O(s_m, \pi(s_m|\theta)|\omega)$ 表示网络参数 ω 的在线图价值网络在目标 SDN 网络的状态 s_m 下，在线图策略网络输出的路由策略为 $\pi(s_m|\theta)$ 时，在线图价值

网络输出的价值；

步骤 S2.3.9:根据在线图价值网络输出值的损失 $Loss_{ogvn}$ ，基于梯度反向传播方法，更新在线图价值网络的网络参数 ω ；

步骤 S2.3.10:计算梯度值 $\nabla_{\theta} = \frac{1}{Y} \sum_{m=1}^Y \nabla(Value_m^O) \nabla(\pi(s_m|\theta))$ ，根据梯度值 ∇_{θ} ，基于梯度反向传播方法，更新在线图策略网络的网络参数 θ ，其中 $\nabla(\cdot)$ 表示对括号内公式求梯度；

步骤 S2.3.11:分别根据下式，更新目标图策略网络的网络参数 θ' 、目标图价值网络的网络参数 ω' ：

$$\theta' = \tau\theta + (1 - \tau)\theta'$$

$$\omega' = \tau\omega + (1 - \tau)\omega'$$

式中， τ 为常数，且 $\tau \in (0,1)$ ；

步骤 S2.3.12:重复 S2.3.2 至步骤 S2.3.11，直至迭代次数达到预设次数 T ，获得使目标 SDN 网络路由开销最小的路由策略。

6. 根据权利要求 5 所述的一种基于图结构特征的路由优化方法，其特征在于，步骤 S3 的具体步骤如下：

步骤 S31:获取目标 SDN 网络的图邻接矩阵 A 、网络信息特征矩阵 H ；

步骤 S32:基于训练好的深度图学习模型，根据目标 SDN 网络的状态 $[A, H]$ ，获得使目标 SDN 网络路由开销最小的路由策略；

步骤 S33:根据步骤 S32 所获得的路由策略，部署至目标 SDN 网络，根据路由策略改变目标 SDN 网络的各链路权重；

步骤 S34:在流量传输过程中，根据最短路径方案，采用更新后的各链路权重进行流量传输。

7. 一种基于图结构特征的路由优化方法的系统，其特征在于，目标 SDN 网络包括控制平面、数据平面，其中，控制平面包括信息获取模块、策略部署模块、DGL 模块；使得所述基于图结构特征的路由优化方法的系统实现如权利要求 1-6 中任一项所述的基于图结构特征的路由优化方法；

目标 SDN 网络的各链路及各节点部署于数据平面，控制平面上的信息获取模块用于获取目标 SDN 网络的网络拓扑图，生成图邻接矩阵、网络信息特征矩阵，发送至 DGL 模块；

DGL 模块基于图学习神经网络，以图邻接矩阵、网络信息特征矩阵为输入，通过深度图学

习方法，以当前状态下目标 SDN 网络的路由开销为输出，基于梯度反向传播方法，更新图学习神经网络的网络参数，并经过预设次数的迭代，对图学习神经网络进行训练，获得使目标 SDN 网络路由开销最小、链路利用率最大的深度图学习模型；

控制平面上的策略部署模块用于根据 DGL 模块所获得的训练好的深度图学习模型，基于目标 SDN 网络的状态，获得使目标 SDN 网络路由开销最小的路由策略，并将路由策略及目标 SDN 网络路由开销发送到数据平面。




图1




图2

输入层 隐藏层 输出层




图3

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2023/098735

A. CLASSIFICATION OF SUBJECT MATTER

H04L45/00(2022.01)i; H04L45/02(2022.01)i

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

IPC: H04L

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

CNTXT, WPABS, ENTXTC, CNKI, IEEE: 软件定义网络, 路由, 优化, 图, 神经网络, 模型, 训练, 拓扑, 邻接, 状态, 矩阵, 向量, 输入, 输出, 深度, 学习, 链路, 权重, SDN, route, routing, optimization, graph, neural, network, model, train+, topology, state, matrix, vector, input, output, deep, learn+, link, weight

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
PX	CN 115225561 A (NANJING UNIVERSITY OF POSTS AND TELECOMMUNICATIONS) 21 October 2022 (2022-10-21) claims 1-7	1-7
A	CN 111245718 A (ZHEJIANG GONGSHANG UNIVERSITY) 05 June 2020 (2020-06-05) description, paragraphs [0028]-[0047]	1-7
A	CN 111314171 A (SHENZHEN POWER SUPPLY BUREAU CO., LTD.) 19 June 2020 (2020-06-19) entire document	1-7
A	CN 113194034 A (HUAZHONG UNIVERSITY OF SCIENCE AND TECHNOLOGY) 30 July 2021 (2021-07-30) entire document	1-7
A	CN 114697229 A (HUAZHONG UNIVERSITY OF SCIENCE AND TECHNOLOGY) 01 July 2022 (2022-07-01) entire document	1-7



Further documents are listed in the continuation of Box C.



See patent family annex.

* Special categories of cited documents:

“A” document defining the general state of the art which is not considered to be of particular relevance

“D” document cited by the applicant in the international application

“E” earlier application or patent but published on or after the international filing date

“L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

“O” document referring to an oral disclosure, use, exhibition or other means

“P” document published prior to the international filing date but later than the priority date claimed

“T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

“X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

“Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

“&” document member of the same patent family

Date of the actual completion of the international search

15 September 2023

Date of mailing of the international search report

20 September 2023

Name and mailing address of the ISA/CN

China National Intellectual Property Administration (ISA/
CN)
China No. 6, Xitucheng Road, Jimenqiao, Haidian District,
Beijing 100088

Authorized officer

Telephone No.

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2023/098735

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	WO 2022116957 A1 (ZTE CORP.) 09 June 2022 (2022-06-09) entire document	1-7
A	车向北 等 (CHE, Xiangbei et al.). "一种基于图神经网络的SDN路由性能预测模型 (A Prediction Model of SDN Routing Performance Based on Graph Neural Network)" 电子学报 (<i>Acta Electronica Sinica</i>), Vol. 49, No. 3, 31 March 2021 (2021-03-31), entire document	1-7

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/CN2023/098735

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)		Publication date (day/month/year)
CN	115225561	A	21 October 2022	None		
CN	111245718	A	05 June 2020	None		
CN	111314171	A	19 June 2020	None		
CN	113194034	A	30 July 2021	None		
CN	114697229	A	01 July 2022	None		
WO	2022116957	A1	09 June 2022	CN	114650249	A 21 June 2022

国际检索报告

国际申请号

PCT/CN2023/098735

A. 主题的分类 H04L45/00(2022.01)i; H04L45/02(2022.01)i 按照国际专利分类(IPC)或者同时按照国家分类和IPC两种分类		
B. 检索领域 检索的最低限度文献(标明分类系统和分类号) IPC: H04L 包含在检索领域中的除最低限度文献以外的检索文献 在国际检索时查阅的电子数据库(数据库的名称, 和使用的检索词(如使用)) CNTXT, WPABS, ENTXT, CNKI, IEEE: 软件定义网络, 路由, 优化, 图, 神经网络, 模型, 训练, 拓扑, 邻接, 状态, 矩阵, 向量, 输入, 输出, 深度, 学习, 链路, 权重, SDN, route, routing, optimization, graph, neural, network, model, train+, topology, state, matrix, vector, input, output, deep, learn+, link, weight		
C. 相关文件		
类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求
PX	CN 115225561 A (南京邮电大学) 2022年10月21日 (2022 - 10 - 21) 权利要求1-7	1-7
A	CN 111245718 A (浙江工商大学) 2020年6月5日 (2020 - 06 - 05) 说明书第[0028]-[0047]段	1-7
A	CN 111314171 A (深圳供电局有限公司) 2020年6月19日 (2020 - 06 - 19) 全文	1-7
A	CN 113194034 A (华中科技大学) 2021年7月30日 (2021 - 07 - 30) 全文	1-7
A	CN 114697229 A (华中科技大学) 2022年7月1日 (2022 - 07 - 01) 全文	1-7
A	WO 2022116957 A1 (ZTE CORPORATION) 2022年6月9日 (2022 - 06 - 09) 全文	1-7
☒ 其余文件在C栏的续页中列出。 ☒ 见同族专利附件。		
* 引用文件的具体类型: “A” 认为不特别相关的表示了现有技术一般状态的文件 “D” 申请人在国际申请中引证的文件 “E” 在国际申请日的当天或之后公布的在先申请或专利 “L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件(如具体说明的) “O” 涉及口头公开、使用、展览或其他方式公开的文件 “P” 公布日先于国际申请日但迟于所要求的优先权日的文件 “T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件 “X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性 “Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性 “&” 同族专利的文件		
国际检索实际完成的日期 2023年9月15日		国际检索报告邮寄日期 2023年9月20日
ISA/CN的名称和邮寄地址 中国国家知识产权局 中国北京市海淀区蓟门桥西土城路6号 100088		授权官员 刘姗 电话号码 (+86) 010-53961626

国际检索报告

国际申请号

PCT/CN2023/098735

C. 相关文件

类 型*	引用文件，必要时，指明相关段落	相关的权利要求
A	车向北 等. “一种基于图神经网络的SDN路由性能预测模型” 电子学报, 第49卷, 第3期, 2021年3月31日 (2021 - 03 - 31), 全文	1-7

国际检索报告
关于同族专利的信息

国际申请号

PCT/CN2023/098735

检索报告引用的专利文件			公布日 (年/月/日)	同族专利	公布日 (年/月/日)
CN	115225561	A	2022年10月21日	无	
CN	111245718	A	2020年6月5日	无	
CN	111314171	A	2020年6月19日	无	
CN	113194034	A	2021年7月30日	无	
CN	114697229	A	2022年7月1日	无	
WO	2022116957	A1	2022年6月9日	CN 114650249 A	2022年6月21日