

# 基于时空卷积的机会网络拓扑预测

舒坚<sup>1</sup>, 史佳伟<sup>1</sup>, 刘琳岚<sup>2</sup>, Manar Al-Kali<sup>1</sup>

(1. 南昌航空大学软件学院, 江西 南昌 330063; 2. 南昌航空大学信息工程学院, 江西 南昌 330063)

**摘要:** 机会网络拓扑的高动态性导致其拓扑预测极具挑战。现有拓扑预测方法主要关注网络长期时空依赖, 忽视了短期时空特征。综合考虑机会网络长短期时空依赖关系, 提出一种基于动态时间规整算法与时空卷积的机会网络拓扑预测方法 (DTW-STC)。基于动态时间规整算法确定切片时长, 将机会网络切分为快照, 用快照的链路状态矩阵表征其拓扑信息; 采用时序卷积神经网络获取短期时序特征, 结合网络变化构建时空图表征短期时空关系, 利用图卷积运算提取网络的短期时空特征, 经过多次卷积的堆叠, 得到网络长短期时空特征; 基于自编码器结构实现向量空间切换, 预测下一时刻网络拓扑。3个真实机会网络数据集 ITC、MIT 以及 Asturias-er 上的实验结果表明, DTW-STC 方法的预测性能优于基线方法。

**关键词:** 机会网络; 拓扑预测; 时序卷积; 图卷积; 时空图

**中图分类号:** TP393

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2023060

## Topology prediction for opportunistic network based on spatiotemporal convolution

SHU Jian<sup>1</sup>, SHI Jiawei<sup>1</sup>, LIU Linlan<sup>2</sup>, Manar Al-Kali<sup>1</sup>

1. School of Software, Nanchang Hangkong University, Nanchang 330063, China

2. School of Information Engineering, Nanchang Hangkong University, Nanchang 330063, China

**Abstract:** The high dynamics of opportunistic network topology leads to the challenges of topology prediction. The existing research mainly focuses on the long-term spatiotemporal dependence of networks, ignoring the short-term spatiotemporal features. A topology prediction method for opportunistic network based on dynamic time warping algorithm and spatiotemporal convolution (DTW-STC) was proposed, which integrated long-short term spatiotemporal dependence in opportunistic network. The time slot was determined based on dynamic time warping algorithm, so that the opportunistic network was sliced into snapshots which topology was presented by link state matrix. Temporal convolution was employed to extract short-term temporal features. The spatiotemporal graph, representing the short-term spatiotemporal relationship, was constructed by temporal features and network changes. The short-term spatiotemporal features were captured by graph convolution. After stacks of spatiotemporal convolution, the long-short term spatiotemporal features of network were achieved. Based on the autoencoder structure, vector space transformation was realized, so that the future network topology was predicted. The results on three real opportunistic network datasets, ITC, MIT, and Asturias-er, show that the proposed DTW-STC has better prediction performance than ones of other baseline methods.

**Keywords:** opportunistic network, topology prediction, temporal convolution, graph convolution, spatiotemporal graph

收稿日期: 2022-11-30; 修回日期: 2023-02-27

通信作者: 刘琳岚, liulinlan@nchu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62062050, No.61962037); 江西省研究生创新专项资金资助项目 (No.YC2021-S708)

**Foundation Items:** The National Natural Science Foundation of China (No.62062050, No.61962037), The Innovation Foundation for Postgraduate Student of Jiangxi Province (No.YC2021-S708)

## 0 引言

机会网络是一种不需要源节点和目标节点之间存在完整链路,利用节点移动带来的相遇机会实现通信的自组织网络<sup>[1]</sup>。这种网络由时延容忍网络发展而来,区别于传统无线通信网络,其目的是在没有端到端连接的情况下实现网络通信<sup>[2]</sup>。机会式的通信方式使机会网络具有高动态性<sup>[3]</sup>,因此针对机会网络演化规律的研究极具挑战性。分析网络演化的时空特征,可以为网络路由设计奠定基础,从而提升网络性能<sup>[4]</sup>。

现有拓扑预测方法一般针对完整网络周期进行建模,忽视了网络短期的时空变化,导致提取的网络特征不完整。基于此,本文提出基于动态时间规整算法与时空卷积的机会网络拓扑预测(DTW-STC, dynamic time warping and spatiotemporal convolution)方法,利用时序卷积<sup>[5]</sup>捕获网络短期时序特征,结合网络变化构建时空图表征节点间短期时空关系,利用图卷积运算提取网络短期时空特征,通过堆叠多层时空卷积,得到网络长短期时空特征。本文主要贡献如下。

1) 提出一种机会网络表征方法。该方法基于动态时间规整(DTW, dynamic time warping)算法<sup>[6]</sup>确定切片时长,将机会网络切分为离散快照,采用链路状态矩阵表示网络快照。

2) 提出基于时空卷积的网络长短期时空特征提取方法,提高了拓扑预测性能。该方法采用时序卷积获取网络的短期时序特征,结合网络变化构建时空图,利用图卷积运算提取网络短期时空特征,经多次卷积的堆叠,得到网络长短期时空特征。

## 1 相关研究

目前,拓扑预测方法主要有基于随机游走的拓扑预测、基于自编码器的拓扑预测和基于图卷积网络(GCN, graph convolution network)的拓扑预测。

### 1.1 基于随机游走的拓扑预测

该类方法通常设定游走策略,采样网络游走路径,根据路径上节点间关系生成网络嵌入向量,将嵌入向量运用于预测任务。Nguyen等<sup>[7]</sup>通过无偏采样和有偏采样得到游走路径,采用逻辑回归实现预测。Wang等<sup>[8]</sup>按照时间顺序回溯采样游走路径,利用相对节点标识对路径上的节点进行编码。Khoshraftar等<sup>[9]</sup>采用长短期记忆(LSTM, long short term memory)网络学习节点间时序关系得到网络嵌

入向量并初始化随机游走算法。由于随机游走的限制,该类方法适用于拓扑变化缓慢的网络,对于拓扑变化频繁的机会网络,其预测性能较差。

### 1.2 基于自编码器的拓扑预测

该类方法对网络信息进行编码与解码,通过最小化重构误差进行学习。Goyal等<sup>[10]</sup>提出基于深度自编码器的拓扑预测方法,采用非线性层构建自编码器,通过参数继承捕捉网络演化规律,以模型输入作为重构目标。Chen等<sup>[11]</sup>在自编码器与解码器的中间部分引入LSTM,更准确地捕捉了网络演化规律。Goyal等<sup>[12]</sup>在上述研究的基础上,提出3种适用于不同网络的变体。Jiao等<sup>[13]</sup>考虑到捕捉网络拓扑变化的重要性,在自编码器中引入图注意力网络(GAT, graph attention network)<sup>[14]</sup>提取节点邻域信息,结合门控循环单元(GRU, gate recurrent unit)实现预测。上述研究表明,自编码器可以作为一个通用框架学习网络中的潜在特征。

### 1.3 基于图卷积网络的拓扑预测

该类方法结合了GCN与序列模型。Chen等<sup>[15]</sup>提出GC-LSTM(graph convolution embedded LSTM)方法,利用图卷积提取网络拓扑特征,采用LSTM捕捉网络演化规律。Lei等<sup>[16]</sup>在文献[15]的基础上,采用生成对抗网络(GAN, generative adversarial network)强化模型的学习能力,提出加权动态网络的拓扑预测方法。Pareja等<sup>[17]</sup>将GCN的参数作为循环神经网络(RNN, recurrent neural network)的输入,使参数数量不会随着节点数目的变化而改变。Sankar等<sup>[18]</sup>提出基于自注意力机制组成的拓扑预测方法,采用注意力机制提取网络的拓扑与时序特征。Yin等<sup>[19]</sup>提出基于结构嵌入GRU的预测模型,设计了多种约束训练模型以提高预测精度。该类方法将捕获的拓扑特征作为序列模型的输入,以提取网络长期时空特征。

上述研究为机会网络拓扑预测提供了解决方案,但忽视了网络的短期时空特征。基于上述研究<sup>[10,15]</sup>,本文提出DTW-STC方法,拓扑预测流程如图1所示。在编码器与解码器间堆叠时空卷积层,采用时序卷积提取网络短期时序特征,结合网络变化构建时空图表征节点间短期时空关系,将得到的时序特征以及时空图作为GCN的输入,实现对网络短期时空特征的提取,经过时空卷积层的堆叠,得到网络长短期时空特征,实现对下一时刻网络拓扑的预测。

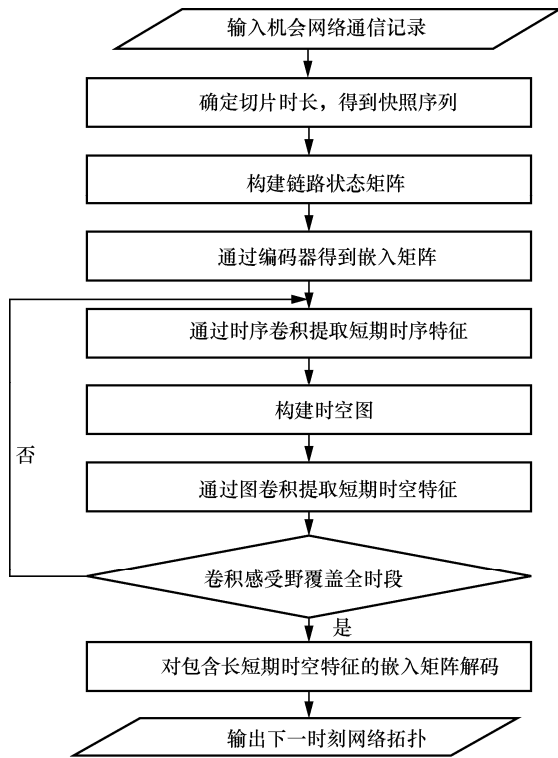


图 1 拓扑预测流程

## 2 机会网络表征

将机会网络切分为网络快照，采用加权邻接矩阵（即链路状态矩阵）表示快照，将多个快照的链路状态矩阵作为基于时空卷积拓扑预测（STC）模型的输入。

### 2.1 问题描述

固定切片时长  $T$ ，将机会网络  $G$  切分为一系列网络快照，可定义为  $G = \{G_1, G_2, \dots, G_i, \dots, G_n\}$ ，其中， $n$  表示快照序列长度， $G_i = \{\mathcal{V}_i, \mathcal{E}_i, \mathcal{M}_i\}$  表示第  $i$  个网络快照， $\mathcal{V}_i$  表示快照  $G_i$  的节点集合， $\mathcal{E}_i$  表示快照  $G_i$  的边集合， $\mathcal{M}_i$  表示权重集合。将快照表示为链路状态矩阵  $\mathbf{A}^w = \{\mathbf{A}_1^w, \mathbf{A}_2^w, \dots, \mathbf{A}_i^w, \dots, \mathbf{A}_n^w\}$ ，则拓扑预测可以描述为给定  $\tau$  个快照的链路状态矩阵  $\{\mathbf{A}_t^w, \mathbf{A}_{t+1}^w, \dots, \mathbf{A}_{t+\tau-1}^w\}$ ，预测  $t + \tau$  时刻的网络拓扑。

### 2.2 网络切片

观测不同切片时长下快照序列的变化趋势，确定切片时长。设切片单位为  $\Delta t$ ，生成切片时长  $T$  的备选集  $\{\Delta t, \dots, m\Delta t, \dots, k\Delta t\}$ ，其中， $m$  表示快照序列号， $k$  表示备选集中元素个数。按照备选集对机会网络进行切分，切片时长  $m\Delta t$  对应的快照序列为  $G^m = \{G_1^m, G_2^m, \dots, G_i^m, \dots, G_n^m\}$ 。采用 DTW 算法计算切片时长  $m\Delta t$  与  $(m+1)\Delta t$  对应快照序列间的距离，

如式(1)所示<sup>[5]</sup>，其中， $r_i^m$  表示快照  $G_i^m$  的链路数量。

$$\begin{aligned} DTW(r^m, r^{m+1}) &= DTW(r_i^m, r_j^{m+1}) + \\ &\min(DTW(r_{i-1}^m, r_j^{m+1}), DTW(r_i^m, r_{j-1}^{m+1}), \\ &DTW(r_{i-1}^m, r_{j-1}^{m+1})) \end{aligned} \quad (1)$$

距离值越小，2 个快照序列的相似度越高，反之则越低。计算两两快照序列间的距离并绘制曲线，找出最大点作为变异点。在该点前，由于切片时长  $T$  过短，表征结果较冗余，无法体现网络动态性；在该点后，由于切片时长  $T$  过长，快照内信息丢失较多，无法反映网络的演化规律。设  $\Delta t = 20$  s，3 个数据集（ITC、MIT 和 Asturias-er）的快照序列相似度如图 2 所示。




图 2 3 个数据集的快照序列相似度

由图 2 可知, ITC、MIT 以及 Asturias-er 数据集的快照序列间距离分别在  $m=12$ 、 $m=13$  和  $m=15$  时取大值, 因此确定 3 个数据集的切片时长分别为 240 s、260 s 和 300 s。

切片时长算法的复杂度取决于 DTW 算法的复杂度以及  $k$  值的大小。DTW 算法的时间复杂度是输入 2 个快照序列长度的乘积。因此, 切片时长算法的时间复杂度为

$$O(n^2(k-1)) \quad (2)$$

### 2.3 网络快照表示

预测任务主要关注最近时刻网络链路状况<sup>[20]</sup>, 本文根据连接断开时刻确定链路状态矩阵中节点对  $\langle u, v \rangle$  的权值  $w_{uv}$ , 如式(3)所示。

$$w_{uv} = \begin{cases} 1 & , t_{f,uv} \geq T_f \\ \frac{T_f - t_{f,uv}}{T_f - T_b} & , T_b \leq t_{f,uv} < T_f \\ 0 & , t_{f,uv} < T_b \end{cases} \quad (3)$$

其中,  $T_b$  表示当前快照的开始时刻,  $T_f$  表示当前快照的终止时刻,  $t_{f,uv}$  表示节点对  $\langle u, v \rangle$  的连接断开时刻, 切片时长  $T = T_f - T_b$ 。

若  $t_{f,uv} \geq T_f$ , 则权值为 1; 若  $t_{f,uv}$  在当前快照所处时间段内, 节点对  $\langle u, v \rangle$  的连接断开时刻越早, 则权值越大; 若  $t_{f,uv} < T_b$ , 则权值为 0。

依据式(3), 可将第  $i$  个网络快照  $G_i$  表示为链路状态矩阵  $A_i^w$ , 如式(4)所示。

$$A_i^w = \begin{bmatrix} 0 & w_{12} & \cdots & w_{1N} \\ w_{21} & 0 & \cdots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & \cdots & 0 \end{bmatrix} \quad (4)$$

其中,  $N$  为机会网络节点总量。

## 3 预测模型

如图 3(a)所示, STC 模型包括 3 个部分: 编码器、时空卷积层和解码器。STC 模型将链路状态矩阵编码作为网络嵌入, 通过堆叠的多个时空卷积层, 提取网络中的长短期时空特征, 利用解码器, 输出下一时刻网络拓扑。

### 3.1 编码器

将链路状态矩阵集合  $\{A_i^w, A_{i+1}^w, \dots, A_{i+\tau-1}^w\}$  作为编码器的输入, 输出嵌入矩阵集合  $\{X_i, X_{i+1}, \dots, X_{i+\tau-1}\}$ 。

编码器由 2 个非线性层组成, 分别如式(5)和式(6)所示。


$$\hat{X}_{t+i} = \text{ReLU}(A_{t+i}^w W_{\text{en}}^1 + b_{\text{en}}^1) \quad (5)$$

$$X_{t+i} = \text{ReLU}(\hat{X}_{t+i} W_{\text{en}}^2 + b_{\text{en}}^2) \quad (6)$$

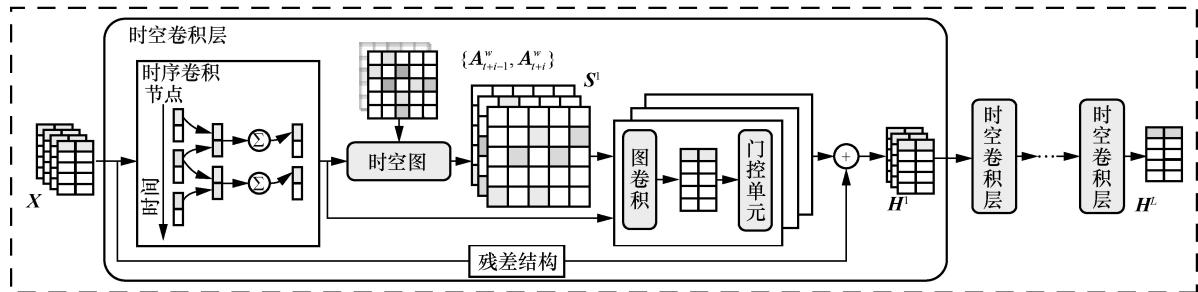
其中,  $A_{t+i}^w \in \mathbb{R}^{N \times N}$  表示  $t+i$  时刻的链路状态矩阵,  $W_{\text{en}}^1 \in \mathbb{R}^{N \times F}$  和  $W_{\text{en}}^2 \in \mathbb{R}^{F \times F}$  表示权重矩阵,  $b_{\text{en}}^1 \in \mathbb{R}^{1 \times F}$  和  $b_{\text{en}}^2 \in \mathbb{R}^{F}$  表示偏置向量,  $F$  表示嵌入维度, ReLU 表示每一层的激活函数。

### 3.2 时空卷积层

通过时空卷积层捕获网络短期时空特征, 更新嵌入矩阵, 如图 3(b)所示, 时空卷积层包括 4 个部



(a) 预测模型框架



(b) 时空卷积层框架

图 3 预测模型整体框架

分: 时序卷积、时空图、图卷积和门控单元及残差结构。

### 3.2.1 时序卷积

本文设计时序卷积捕获节点的短期时序特征, 如式(7)所示。

$$\hat{\mathbf{H}}_{t+i}^l = \sum_{i=0}^{K-1} \mathbf{H}_{t+i-di}^{l-1} \boldsymbol{\theta}^l [i] \quad (7)$$

其中,  $d$  为扩展系数,  $K$  为卷积核尺寸,  $\boldsymbol{\theta}^l \in \mathbb{R}^{k \times F \times F}$  为第  $l$  层时序卷积的可学习滤波核。第 0 层时序卷积的输入  $\mathbf{H}^0$  是编码器输出的嵌入矩阵  $\{\mathbf{X}_t, \mathbf{X}_{t+1}, \dots, \mathbf{X}_{t+\tau-1}\}$ , 第  $l$  层时序卷积的感受野是  $t+i-(K-1)dl+1$  至  $t+i$  时刻的嵌入矩阵, 该时序卷积的输出包含感受野内的短期时序特征, 感受野的大小为  $(K-1)dl+1$ 。

本文设置  $K=2$ 、 $d=1$ , 第 1 层时序卷积输出的第  $i$  个嵌入矩阵  $\hat{\mathbf{H}}_{t+i}^1 \in \mathbb{R}^{N \times F}$  包含  $t+i-1$  至  $t+i$  时刻的网络短期时序特征。

### 3.2.2 时空图

将嵌入矩阵  $\hat{\mathbf{H}}_{t+i}^1$  转换为网络拓扑, 考虑拓扑变化情况, 构建时空图表征节点间短期时空关系, 如图 4 所示。时序语义矩阵  $\mathbf{E}$  包含了节点间关系的时序相似性, 拓扑变化矩阵  $\mathbf{D}$  反映了感受野内拓扑变化情况, 将两者组合可得到机会网络的时空图。

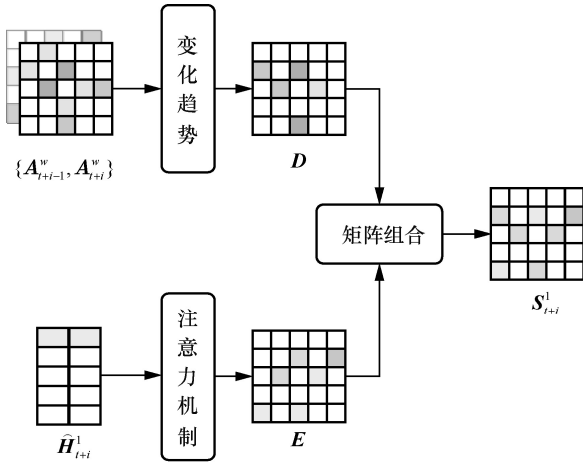


图4 构建时空图

如图 4 所示, 将  $\hat{\mathbf{H}}_{t+i}^1 \in \mathbb{R}^{N \times F}$  和其感受野对应的  $t+i-1$  至  $t+i$  时刻的链路状态矩阵  $\{\mathbf{A}_{t+i-1}^w, \mathbf{A}_{t+i}^w\}$  作为输入, 输出时空图  $\mathbf{S}_{t+i}^1$ 。考虑到机会网络的稀疏性, 本文选择  $N'$  个具有代表性的节点参与时空图

的构建<sup>[21]</sup>,  $N'$  个节点组成集合  $\text{Top}_{t+i}^1$ , 以降低模型的运算开销。

1) 时序语义矩阵  $\mathbf{E}$ 。依据节点集合  $\text{Top}_{t+i}^1$ , 从  $\hat{\mathbf{H}}_{t+i}^1$  中选取相应的节点嵌入向量  $\hat{\mathbf{h}}_u$  和  $\hat{\mathbf{h}}_v$ , 计算两者注意力值, 得到时序相似性, 如式(8)所示。

$$E_{uv} = \frac{\text{dot}(\hat{\mathbf{h}}_u \mathbf{W}_Q^1, \hat{\mathbf{h}}_v \mathbf{W}_K^1)}{\sqrt{F}} \quad (8)$$

其中,  $\mathbf{W}_Q^1 \in \mathbb{R}^{F \times F}$ 、 $\mathbf{W}_K^1 \in \mathbb{R}^{F \times F}$  表示权重矩阵,  $\text{dot}(\cdot)$  表示向量点积, 节点  $u$  和  $v$  属于节点集合  $\text{Top}_{t+i}^1$ ,  $E_{uv}$  表示节点对  $\langle u, v \rangle$  间的时序相似性。

2) 拓扑变化矩阵  $\mathbf{D}$ 。时序卷积是从全局视角对短期时序特征进行提取的, 难以有效感知网络中局部拓扑变化。本文将  $\{\mathbf{A}_{t+i-1}^w, \mathbf{A}_{t+i}^w\}$  作为输入, 从集合  $\text{Top}_{t+i}^1$  中选取节点参与计算, 用链路状态矩阵的变化反映网络的局部拓扑变化, 如式(9)所示。

$$D_{uv} = W_D^1 (\mathbf{A}_{t+i}^w(u, v) - \mathbf{A}_{t+i-1}^w(u, v)) + b_D^1 \quad (9)$$

其中,  $W_D^1 \in \mathbb{R}^1$  表示权重,  $b_D^1 \in \mathbb{R}^1$  表示偏置,  $D_{uv}$  表示变化值。利用权重与偏置自适应表示网络拓扑变化。

3) 矩阵组合。本文设计掩码矩阵  $\mathbf{M}$  组合时序语义矩阵  $\mathbf{E}$  与拓扑变化矩阵  $\mathbf{D}$ 。采用非线性层压缩节点对  $\langle u, v \rangle$  在不同时刻的状态值, 得到掩码值  $M_{uv}$ , 如式(10)和式(11)所示。

$$M_{uv} = \text{Sigmoid} \left( \sum_{j=t+i-1}^{t+i} U_j^1 \mathbf{A}_j^w(u, v) + b_M^1 \right) \quad (10)$$

$$S_{uv} = M_{uv} E_{uv} + (1 - M_{uv}) D_{uv} \quad (11)$$

其中,  $U_j^1 \in \mathbb{R}^1$  表示权重,  $b_M^1 \in \mathbb{R}^1$  表示偏置,  $S_{uv}$  表示时空图中节点对  $\langle u, v \rangle$  对应的元素值, 节点  $u$  和  $v$  属于节点集合  $\text{Top}_{t+i}^1$ 。

将集合  $\text{Top}_{t+i}^1$  外节点所对应的时空图元素置 0。依据上述步骤, 得到第 1 层  $t+i$  时刻时空图  $\mathbf{S}_{t+i}^1$ 。

### 3.2.3 图卷积

得到时空图  $\mathbf{S}_{t+i}^1$  后, 采用图卷积更新嵌入矩阵, 使其包含不同时刻下邻居节点的信息, 提取网络的短期时空特征, 图卷积如式(12)所示。

$$\tilde{\mathbf{H}}_{t+i}^1 = \sum_{j=1}^{\alpha} (\mathbf{S}_{t+i}^1)^j \hat{\mathbf{H}}_{t+i}^1 \mathbf{W}_V^1 + \hat{\mathbf{H}}_{t+i}^1 \quad (12)$$

其中,  $\mathbf{W}_V^1 \in \mathbb{R}^{F \times F}$  表示权重矩阵,  $\alpha$  表示聚合邻居

阶次,  $(\mathbf{S}_{t+i}^1)^i$  表示节点与其第  $i$  阶邻居的依赖关系,  $\hat{\mathbf{H}}_{t+i}^1$  表示图卷积层的初始特征。

### 3.2.4 门控单元与残差结构

本文采用门控单元使预测模型进一步关注短期时空特征。将嵌入矩阵  $\tilde{\mathbf{H}}_{t+i}^1$  输入门控单元, 利用平均池化获取图级别嵌入  $\beta_{t+i}^1$ , 通过非线性层对特征间依赖关系进行建模, 如式(13)和式(14)所示。

$$\beta_{t+i}^1 = \frac{1}{N} \sum_{u=1}^N \tilde{h}_u \quad (13)$$

$$\hat{\mathbf{H}}_{t+i}^1 = \text{Sigmoid}(\beta_{t+i}^1 \mathbf{W}_G^1 + \mathbf{b}_G^1) \odot \tilde{\mathbf{H}}_{t+i}^1 \quad (14)$$

其中,  $\mathbf{W}_G^1 \in \mathbb{R}^{F \times F}$  和  $\mathbf{b}_G^1 \in \mathbb{R}^{1 \times F}$  分别表示权重矩阵和偏置向量,  $\tilde{h}_u \in \tilde{\mathbf{H}}_{t+i}^1$ ,  $\odot$  表示对位相乘。

为解决时空卷积堆叠多层引起的网络退化问题, 引入残差结构, 如式(15)所示。

$$\mathbf{H}_{t+i}^1 = \text{Norm}(\hat{\mathbf{H}}_{t+i}^1 + \mathbf{H}_{t+i}^0) \quad (15)$$

其中,  $\mathbf{H}_{t+i}^0$ 、 $\mathbf{H}_{t+i}^1$  分别表示第 1 层时空卷积层输入与输出的第  $i$  个嵌入矩阵,  $\text{Norm}(\cdot)$  表示层标准化。

### 3.2.5 长短期时空特征提取

通过堆叠多层时空卷积层, 嵌入矩阵  $\mathbf{H}^L$  包含  $t$  至  $t+\tau-1$  时刻的长短期时空特征, 如图 5 所示。




图 5 堆叠多层时空卷积层

### 3.3 解码器

将嵌入矩阵  $\mathbf{H}^L$  输入解码器, 得到下一刻网络拓扑。解码器包括 2 个非线性层, 如式(16)和式(17)所示。

$$\hat{\mathbf{Y}}_{t+\tau} = \text{ReLU}(\mathbf{H}^L \mathbf{W}_{\text{de}}^1 + \mathbf{b}_{\text{de}}^1) \quad (16)$$

$$\mathbf{Y}_{t+\tau} = \text{Sigmoid}(\hat{\mathbf{Y}}_{t+\tau} \mathbf{W}_{\text{de}}^2 + \mathbf{b}_{\text{de}}^2) \quad (17)$$

其中,  $\mathbf{W}_{\text{de}}^1 \in \mathbb{R}^{F \times F}$  和  $\mathbf{W}_{\text{de}}^2 \in \mathbb{R}^{F \times N}$  表示权重矩阵,  $\mathbf{b}_{\text{de}}^1 \in \mathbb{R}^{1 \times F}$  和  $\mathbf{b}_{\text{de}}^2 \in \mathbb{R}^{1 \times N}$  表示偏置向量。

### 3.4 损失函数

损失函数包括预测相似度和拓扑相似度。预测相似度指预测值与真实值的相似程度, 拓扑相似度指网络嵌入与网络拓扑的相似程度。损失函数表示为

$$\text{Loss} = \frac{1}{N} \|\mathbf{A}_{t+\tau} - \mathbf{Y}_{t+\tau}\|_F^2 - \gamma \sum_{i=0}^{\tau-1} \mathbf{A}_{t+i}^w \log(\text{Sigmoid}(\text{dot}(\mathbf{H}^L, \mathbf{H}^L))) \quad (18)$$

其中,  $\gamma$  为调控拓扑相似度损失的超参数。

### 3.5 时间复杂度分析

STC 模型中, 编码器与解码器的时间复杂度取决于线性变换, 表示为

$$O(N^2 F + NF) \quad (19)$$

时序卷积的时间复杂度为

$$O(N(\tau-l)KF^2) \quad (20)$$

时空图中, 选取  $N'$  个代表性节点参与运算, 其时序语义矩阵的时间复杂度为

$$O(N'F^2) \quad (21)$$

拓扑变化矩阵时间复杂度为

$$O(((K-1)l+1)(N'^2 F + NF)) \quad (22)$$

矩阵组合时间复杂度为

$$O(((K-1)l+1)N'^2 + N'^2) \quad (23)$$

图卷积包括时空图的幂运算和矩阵乘法, 其时间复杂度为

$$O(N^\alpha) + O(N^2 F + NF) \quad (24)$$

门控单元可分解为图级别表示计算和矩阵对位相乘, 残差结构本质上是矩阵加法, 两者的时间复杂度之和为

$$O(NF + F) + O(NF) \quad (25)$$

时空卷积层的堆叠数量与输入序列长度  $\tau$  相

关，时间复杂度为  $O(1)$ 。

综上，STC 模型的时间复杂度主要取决于参与计算的节点数、网络嵌入维度以及模型结构，表示为

$$O(N^2F + NF + NK^2F^2 + N'F^2 + ((K-1)L+1)(N'^2F + N'F) + N^\alpha) \quad (26)$$

## 4 实验

本节实验在 ITC、MIT 和 Asturias-er 机会网络数据集上，将 DTW-STC 方法与 7 种基线方法进行比较，验证 DTW-STC 方法的有效性。

### 4.1 实验设计

#### 4.1.1 实验数据集

实验在 ITC、MIT 以及 Asturias-er 真实机会网络数据集<sup>[22]</sup>上进行，实验数据集信息如表 1 所示。

ITC 数据集记录了 12 天内学生携带 iMote 设备产生的通信数据，该数据集规模较小，网络拓扑变化较频繁；MIT 数据集记录了学生携带诺基亚 6600 手机产生的通信数据，相较于 ITC 数据集，该数据集拓扑变化相对平稳；Asturias-er 记录了 229 台车载设备产生的通信数据，该数据集持续时间较长，网络规模较大。

#### 4.1.2 评价指标

本文采用 AUC (area under curve) 和 PRAUC

(area under precision-recall curve)<sup>[23]</sup>作为评价指标。AUC 的计算式为

$$AUC = \frac{p' + 0.5p''}{p} \quad (27)$$

其中， $p$  为预测样本的比较次数， $p'$  为正例中所选链路预测值大于反例中的次数， $p''$  为两者相等的次数。PRAUC 由 AUC 发展而来，对稀疏网络能做出正确评价，计算式为

$$PRAUC = \frac{1}{N} \sum_{u=1}^N \sum_{v=1}^N \frac{|\{A(u,v)=1\} \cap \{Y(u,v)=1\}|}{|\{A(u,v)=1\}|} \quad (28)$$

其中， $A(u,v)=1$  表示节点  $u$  和节点  $v$  间存在链路， $Y(u,v)=1$  表示节点  $u$  和节点  $v$  间存在预测链路。

#### 4.1.3 基线方法

采用 Self-Attention<sup>[24]</sup>、CTDNE<sup>[7]</sup>、Dyngraph2vec<sup>[12]</sup>、E-LSTM-D<sup>[11]</sup>、GCN-GAN<sup>[16]</sup>、SE-GRU<sup>[19]</sup> 以及 T-GCN<sup>[25]</sup>作为基线方法，如表 2 所示。

#### 4.1.4 实验参数

本文在 Intel(R) i5-6850K 和 GTX1080Ti 实验环境下进行，采用 Python 及 Pytorch 等编程，按照 6:2:2 的比例划分训练集、验证集与测试集。

ITC、MIT 以及 Asturias-er 数据集的切片时长  $T$  分别设置为 240 s、260 s 以及 300 s，嵌入维度  $F$  分别设置为 32<sup>[26]</sup>、64 和 128，参考文献<sup>[27]</sup>设置扩展

表 1 实验数据集信息

数据集	设备	网络类型	持续时间/天	节点数/个	链路数/条
ITC	iMote	蓝牙	12	50	6 871
MIT	诺基亚 6600	蓝牙	246	97	102 511
Asturias-er	车载设备	GPS	336	229	523 804

表 2 实验对照的基线方法

名称	类型	描述
Self-Attention	序列模型	采用注意力机制计算每个时间步的注意力值以提取时序特征
CTDNE	基于随机游走的预测模型	通过随机游走方法得到网络嵌入，将该嵌入运用于拓扑预测任务
Dyngraph2vec	基于自编码器的预测模型	采用自编码器与 RNN 得到网络嵌入，将该嵌入运用于拓扑预测任务
E-LSTM-D	基于自编码器的预测模型	自编码器和 LSTM 结合模型
GCN-GAN	基于图卷积网络的预测模型	GCN 与 LSTM 结合模型，并利用 GAN 强化模型学习能力
SE-GRU	基于图卷积网络的预测模型	结构编码与 GRU 结合模型，并设计多种损失约束
T-GCN	时空图神经网络	GCN 与 GRU 结合模型

系数  $d$ ，序列长度  $\tau$  为  $10^{[19]}$ ，学习率为 0.001。

## 4.2 实验结果与分析

### 4.2.1 切片方法的验证

本节实验将本文切片方法的切片时长与文献[28]的切片时长及设定的切片时长进行对比，切片时长对预测性能的影响如图 6 所示。

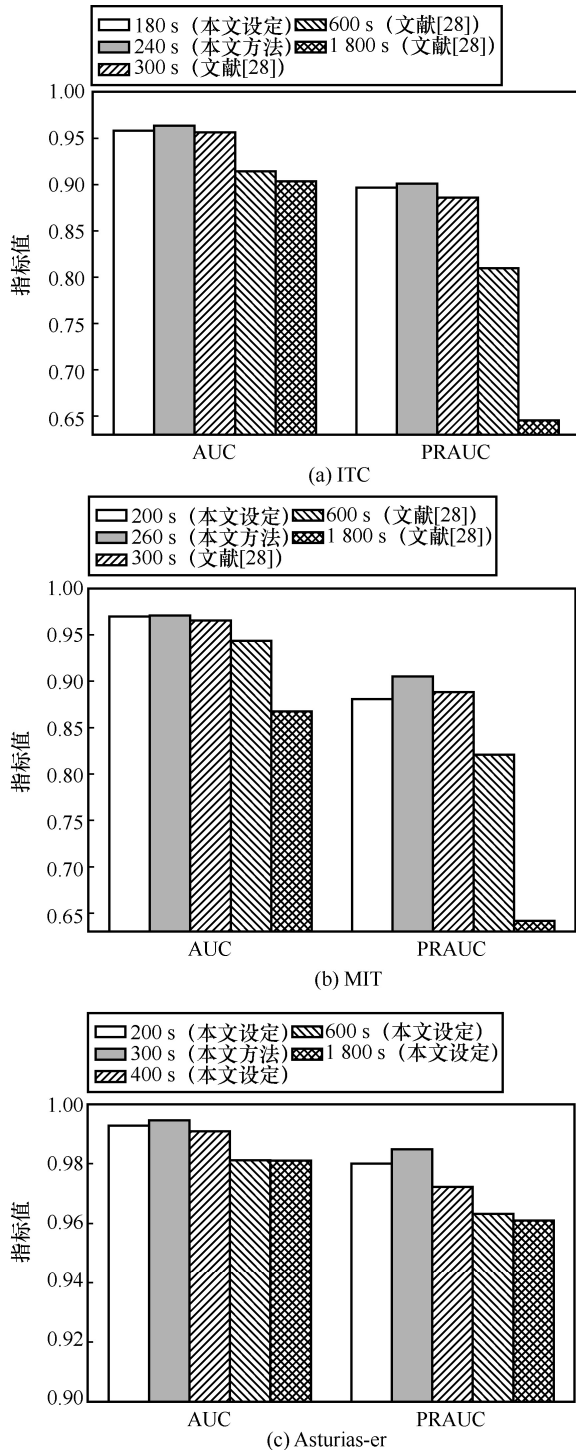


图 6 切片时长对预测性能的影响

从图 6(a)可知，本文切片方法确定 ITC 数据集的切片时长为 240 s，对比的切片时长为 180 s、300 s<sup>[28]</sup>、600 s<sup>[28]</sup>、1 800 s<sup>[28]</sup>，本文切片方法的预测性能最优。

从图 6(b)可知，本文切片方法确定 MIT 数据集的切片时长为 260 s，对比的切片时长为 200 s、300 s<sup>[28]</sup>、600 s<sup>[28]</sup>、1 800 s<sup>[28]</sup>，本文切片方法的预测性能最优。

从图 6(c)可知，本文切片方法确定 Asturias-er 数据集切片时长为 300 s，对比的切片时长为 200 s、400 s、600 s、1 800 s，均为本文设定的切片时长，本文切片方法的预测性能最优。

上述实验验证了本文切片方法的有效性。

### 4.2.2 快照表示方法的验证

通过与文献[29]方法的比较，验证本文快照表示方法 DTW-STC 的有效性，实验结果如图 7 所示。




图 7 快照表示方法有效性验证

由图 7 可知，采用 DTW-STC 方法的预测性能均优于文献[29]，特别是在 MIT 上，其 AUC 和 PRAUC 比文献[29]方法分别提高了 6.52%和 14.96%。

### 4.2.3 $\alpha$ 和 $\gamma$ 的确定

分析聚合邻居阶次  $\alpha$ 、调控参数  $\gamma$  对 STC 模型预测性能的影响。设置  $\alpha$  为 1、2、3、4， $\gamma$  为 0.1、0.2、0.3、0.4、0.5，实验结果如图 8 和图 9 所示。通常， $\alpha$  越大，包含节点邻居信息越多，预测性能越好。然而，从图 8 可知，聚合高阶邻居信息时，预测精度下降，这是因为机会网络的连接较稀疏、高阶邻居少（如表 3 所示），当  $\alpha$  过大时，聚合过程会引入噪声，影响了 STC 模型的预测性能。




图 8 不同聚合邻居阶次  $\alpha$  下模型预测性能

表 3 数据集中快照 3 阶与 4 阶邻居的平均个数

数据集	3 阶邻居/个	4 阶邻居/个
ITC	2.09	1.22
MIT	2.25	1.23
Asturias-er	0.48	0.016




图 9 不同调控参数  $\gamma$  下模型预测性能

由图 9 可知，若  $\gamma$  过小，网络嵌入与网络拓扑的相似度较小，导致预测性能较低；若  $\gamma$  过大，STC 无法关注未来时刻网络拓扑，影响了 STC 模型的预测性能。

由图 8 和图 9 可知，确定 ITC、MIT 以及 Asturias-er 数据集的  $\alpha$  分别为 2、3 和 2，调控参数  $\gamma$  分别为 0.4、0.3 和 0.3。

#### 4.2.4 消融实验

通过消融实验验证 STC 模型中时空图、拓扑变化矩阵与门控单元的有效性, 实验结果如表 4 所示。

由表 4 可知, 移除任一模块后预测性能均有所下降, AUC 和 PRAUC 分别降低了 0.44%~2.63%和 1.81%~5.77%。特别地, 移除时空图后, 下降幅度最大, AUC 和 PRAUC 的平均值降低了 1.97%和 4.37%, 这是因为移除时空图后, STC 模型无法获取节点间时空关系, 导致未能有效提取网络长短期时空特征, 说明时空图对预测性能的贡献最大; 移除拓扑变化矩阵后, AUC 和 PRAUC 的平均值分别下降了 0.75%和 1.9%, 移除门控单元后, AUC 和 PRAUC 的平均值分别下降了 0.80%和 2.24%, 这说明这 2 个模块对预测性能的贡献较小, 同时反映了拓扑变化矩阵能够提升节点间时空关系的表征能力, 门控单元使 STC 模型进一步关注了短期时空特征。

上述结果说明, 本文方法中时空图、拓扑变换矩阵、门控单元均能提升 STC 模型的预测性能。

#### 4.2.5 DTW-STC 方法的验证

在 ITC、MIT 和 Asturias-er 机会网络数据集上, DTW-STC 方法与 7 种基线方法的性能对比如表 5 所示。从表 5 可知, 与基线方法的最优值相比, DTW-STC 的 AUC 和 PRAUC 在 ITC 上分别提升了

0.63%和 1.65%, 在 MIT 上分别提升了 0.03%和 1.47%, 在 Asturias-er 上分别提升了 0.64%和 3.27%。

CTDNE 在 ITC 和 Asturias-er 上的预测性能最差, 在 MIT 上 AUC 指标值最低, 说明基于随机游走的预测模型 CTDNE 不适用于拓扑变化频繁的机会网络; 与 E-LSTM-D 和 Dyngraph2vec 相比, DTW-STC 在 MIT 与 Asturias-er 上预测性能的提升幅度较大, 与最优值相比, AUC 和 PRAUC 分别提高了 1.35%和 3.83%, 这是因为 DTW-STC 提取了网络长短期时空特征, 对规模大、持续时间长的机会网络的预测更精准; Self-Attention 未考虑网络拓扑的演化, GCN-GAN、T-GCN 和 SE-GRU 忽视了网络短期时空特征, 导致它们的预测性能均低于 DTW-STC, 虽然 GCN-GAN 采用 GAN 增强模型的学习能力, 但在 MIT 上 DTW-STC 的 AUC 和 PRAUC 仍提高了 0.03%和 1.47%, 在其他数据集上, 与最优值相比, DTW-STC 的 AUC 和 PRAUC 提高了 0.64%和 2.77%。

为进一步验证拓扑预测方法对网络性能的影响, 在 ITC 数据集上模拟网络消息的转发过程, 选取 4 个不同活跃度的节点作为源节点, 剩余节点作为消息转发的目标节点, 选择预测值前三的节点作为转发节点, 统计消息由源节点转发至目标节点所经历的快照数量作为网络传输时延, 实验结果如

表 4 消融实验结果

预测方法	ITC		MIT		Asturias-er		平均值	
	AUC	PRAUC	AUC	PRAUC	AUC	PRAUC	AUC	PRAUC
移除时空图	0.940 8	0.853 8	0.960 2	0.847 6	0.968 4	0.959 8	0.956 4	0.887 0
移除拓扑变化矩阵	0.954 6	0.883 8	0.966 1	0.885 3	0.985 3	0.966 0	0.968 6	0.911 7
移除门控单元	0.953 1	0.880 6	0.964 8	0.877 9	0.986 5	0.966 5	0.968 1	0.908 3
DTW-STC	0.963 2	0.901 9	0.970 5	0.905 3	0.994 7	0.985 0	0.976 1	0.930 7

表 5 DTW-STC 方法与 7 种基线方法的性能对比

预测方法	ITC		MIT		Asturias-er	
	AUC	PRAUC	AUC	PRAUC	AUC	PRAUC
Self-Attention	0.955 9	0.755 5	0.962 9	0.764 7	0.971 8	0.858 6
CTDNE	0.736 8	0.760 7	0.827 5	0.850 8	0.691 6	0.767 9
Dyngraph2vec	0.956 9	0.885 4	0.938 1	0.842 0	0.965 3	0.905 5
E-LSTM-D	0.945 1	0.877 5	0.948 5	0.850 2	0.981 2	0.946 7
GCN-GAN	0.944 7	0.874 2	0.970 2	0.890 6	0.988 3	0.952 3
SE-GRU	0.954 0	0.849 2	0.940 2	0.851 6	0.976 8	0.911 5
T-GCN	0.912 0	0.820 1	0.874 3	0.812 2	0.911 8	0.858 2
DTW-STC	0.963 2	0.901 9	0.970 5	0.905 3	0.994 7	0.985 0

图 10 所示。对比基线方法，DTW-STC 具有更低的传输时延，比最短时延减少了 163 个快照。

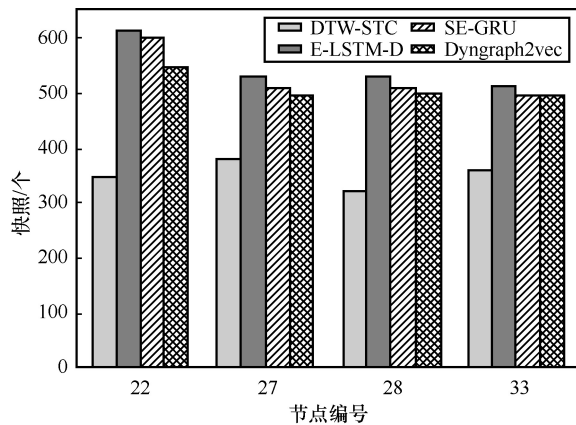


图 10 平均传输时延

此外，本文统计了 ITC 数据集上 DTW-STC 与基线方法的训练时间，实验结果如表 6 所示。从表 5 和表 6 可知，Dyngraph2vec 和 SE-GRU 的训练时间低于 DTW-STC，但预测性能较差。GCN-GAN 的训练最缓慢，这是因为对抗学习消耗了大量时间。本文方法牺牲了一定的训练时间，以得到更高的预测性能。

表 6 训练时间

方法	训练时间/s
E-LSTM-D	161.32
Dyngraph2vec	83.88
GCN-GAN	485.57
SE-GRU	68.61
DTW-STC	151.54

综上，本文提出的拓扑预测方法 DTW-STC 不仅具有更好的预测性能，还具有较低的传输时延，提升了网络性能。

## 5 结束语

DTW-STC 综合考虑机会网络长短期时空依赖关系，基于 DTW 算法将机会网络切分为快照，采用链路状态矩阵表征其拓扑信息，通过堆叠的时空卷积层提取长短期时空特征，基于自编码器结构预测机会网络的拓扑。DTW-STC 的快照表示方法和长短期时空特征的提取方法有效地提高了机会网络拓扑的预测性能。未来工作将专注于嵌入维度与预测性能关系的分析、模型结构的优化，进一步提升预测性能和预测效率。

## 参考文献:


- [1] 熊永平, 孙利民, 牛建伟, 等. 机会网络[J]. 软件学报, 2009, 20(1): 124-137.
- [2] XIONG Y P, SUN L M, NIU J W, et al. Opportunistic networks[J]. Journal of Software, 2009, 20(1): 124-137.
- [3] LI Q H, ZHANG L M, ZENG F, et al. Community clustering routing algorithm based on information entropy in mobile opportunity network[J]. IEEE Access, 2022, 10: 25755-25766.
- [4] SHAH H, KOSTA Y P. Exploiting wireless networks, through creation of opportunity network-wireless-mobile-adhoc-network (W-MAN) scheme[J]. International Journal of Ad hoc, Sensor & Ubiquitous Computing, 2011, 2(1): 99-110.
- [5] 毕俊蕾, 李致远. 机会社交网络中基于时变兴趣社区的查询消息路由算法[J]. 通信学报, 2019, 40(9): 86-94.
- [6] BI J L, LI Z Y. Time-variant interest community based query message routing algorithm in opportunity social network[J]. Journal on Communications, 2019, 40(9): 86-94.
- [7] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv Preprint, arXiv: 1803.01271, 2018.
- [8] SALVADOR S, CHAN P. Toward accurate dynamic time warping in linear time and space[J]. Intelligent Data Analysis, 2007, 11(5): 561-580.
- [9] NGUYEN G H, LEE J B, ROSSI R A, et al. Continuous-time dynamic network embeddings[C]//Proceedings of the Web Conference. New York: ACM Press, 2018: 969-976.
- [10] WANG Y, CHANG Y, LIU Y, et al. Inductive representation learning in temporal networks via causal anonymous walks[J]. arXiv Preprint, arXiv: 2101.05974, 2021.
- [11] KHOSHRAFTAR S, MAHDAVI S, AN A J, et al. Dynamic graph embedding via LSTM history tracking[C]//Proceedings of 2019 IEEE International Conference on Data Science and Advanced Analytics (DSAA). Piscataway: IEEE Press, 2020: 119-127.
- [12] GOYAL P, KAMRA N, HE X, et al. DynGEM: deep embedding method for dynamic graphs[J]. arXiv Preprint, arXiv: 1805.11273, 2018.
- [13] CHEN J Y, ZHANG J, XU X H, et al. E-LSTM-D: a deep learning framework for dynamic network link prediction[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(6): 3699-3712.
- [14] GOYAL P, CHHETRI S R, CANEDO A. Dyngraph2vec: capturing network dynamics using dynamic graph representation learning[J]. Knowledge-Based Systems, 2019: doi.org/10.1016/j.knosys.2019.06.024.
- [15] JIAO P F, GUO X, JING X, et al. Temporal network embedding for link prediction via VAE joint attention mechanism[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(12): 7400-7413.
- [16] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. arXiv Preprint, arXiv: 1710.10903, 2017.
- [17] CHEN J Y, WANG X K, XU X H. GC-LSTM: graph convolution embedded LSTM for dynamic network link prediction[J]. Applied Intelligence, 2022, 52(7): 7513-7528.
- [18] LEI K, QIN M, BAI B, et al. GCN-GAN: a non-linear temporal link prediction model for weighted dynamic networks[C]//Proceedings of IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2019: 388-396.

- [17] PAREJA A, DOMENICONI G, CHEN J, et al. EvolveGCN: evolving graph convolutional networks for dynamic graphs[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(4): 5363-5370.
- [18] SANKAR A, WU Y H, GOU L, et al. DySAT: deep neural representation learning on dynamic graphs via self-attention networks[C]// Proceedings of the 13th International Conference on Web Search and Data Mining. New York: ACM Press, 2020: 519-527.
- [19] YIN Y T, WU Y J, YANG X B, et al. SE-GRU: structure embedded gated recurrent unit neural networks for temporal link prediction[J]. IEEE Transactions on Network Science and Engineering, 2022, 9(4): 2495-2509.
- [20] MA X K, SUN P G, QIN G M. Nonnegative matrix factorization algorithms for link prediction in temporal networks using graph communitability[J]. Pattern Recognition, 2017, 71: 361-374.
- [21] GAO H Y, JI S W. Graph u-nets[C]//Proceedings of IEEE Transactions on Pattern Analysis and Machine Intelligence. Piscataway: IEEE Press, 2021: 4948-4960.
- [22] Dartmouth College Libraries. CRAWDAD: a community resource for archiving wireless data[EB]. 2020.
- [23] JUNUTHULA R R, XU K S, DEVABHAKTUNI V K. Evaluating link prediction accuracy in dynamic networks with added and removed edges[C]//Proceedings of 2016 IEEE International Conferences on Big Data and Cloud Computing (BDCloud), Social Computing and Networking (SocialCom), Sustainable Computing and Communications (SustainCom) (BDCloud-SocialCom-SustainCom). Piscataway: IEEE Press, 2016: 377-384.
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2017: 5998-6008.
- [25] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [26] GU W W, TANDON A, AHN Y Y, et al. Principled approach to the selection of the embedding dimension of networks[J]. arXiv Preprint, arXiv: 2004.09928, 2020.
- [27] WU Z H, PAN S R, LONG G D, et al. Graph wavenet for deep spatial-temporal graph modeling[C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2019: 1907-1913.
- [28] ZAYANI M H, GAUTHIER V, SLAMA I, et al. Tracking topology dynamics for link prediction in intermittently connected wireless

networks[C]//Proceedings of 2012 8th International Wireless Communications and Mobile Computing Conference (IWCMC). Piscataway: IEEE Press, 2012: 469-474.

- [29] 舒坚, 张学佩, 刘琳岚, 等. 基于深度卷积神经网络的多节点间链路预测方法[J]. 电子学报, 2018, 46(12): 2970-2977.
- SHU J, ZHANG X P, LIU L L, et al. Multi-nodes link prediction method based on deep convolution neural networks[J]. Acta Electronica Sinica, 2018, 46(12): 2970-2977.

#### [作者简介]



舒坚 (1964- ), 男, 江西南昌人, 南昌航空大学教授、硕士生导师, 主要研究方向为物联网、深度学习、软件工程等。



史佳伟 (1997- ), 男, 江西南昌人, 南昌航空大学硕士生, 主要研究方向为复杂网络等。



刘琳岚 (1968- ), 女, 湖南东安人, 南昌航空大学教授、硕士生导师, 主要研究方向为物联网、深度学习等。



Manar Al-Kali (1986- ), 男, 伊拉克人, 博士, 南昌航空大学讲师, 主要研究方向为机会网络、深度学习等。