DOI:10.11784/tdxbz202507027

基于社团优化的动态网络 Transformer 表示学习

李天鹏[1,2]，郭　翾[1]，张　旺[1]，陶润国[1]，廖浩然[1]，王文俊[1]
（1. 天津大学智能与计算学部，天津 300350；2. 天津大学新媒体与传播学院，天津 300350）

摘　要：现有动态网络表示学习方法对动态网络时序演化的建模大多服从网络平滑性假设与隐马尔可夫性假设，然而现实世界的数据往往并不严格遵循上述假设，部分动态网络在时序演化过程中可能出现周期性依赖或长程依赖，进而降低了现有动态网络表示学习方法的有效性和泛用能力.为解决这一问题，本文提出了基于社团优化的 Transformer 动态网络表示学习模型 CO-TDNE，该方法利用 Transformer 堆叠的注意力机制结合时间位置编码策略刻画高度可变的图结构和动态网络复杂的时间依赖关系，更加适应真实世界动态网络在时序维度的突变与噪声影响.另外为了缓解 Transformer 在大规模图数据上的高计算成本和有限可扩展性问题，通过在全局视角下识别稳定社团，并在社团内进行参数共享来提升效率. 这一策略在不影响模型效果的同时将训练速度提高了 30%～35%. 本文在 6 组真实世界数据对动态网络的隐马尔可夫性假设的有效性进行了实证验证，证明了现实世界的数据并不严格符合该假设. 在现实世界数据集上的新边链接预测与缺失边链接预测实验表明，CO-TDNE 对动态网络时序演化模式的建模以及拓扑结构的刻画优于对比方法. 所构建的大量消融实验也证明了本文所提出的全局稳定社团优化策略能够有效降低模型参数规模，并证明了基于网络层次结构优化策略的有效性.

关键词：动态网络；动态图；网络表示学习；动态链接预测
中图分类号：TP391.4　　**文献标志码**：A　　**文章编号**：0493-2137（2026）11-1219-12

Transformer-Based Dynamic Network Embedding via Community Optimization

Li Tianpeng[1,2]，Guo Xuan[1]，Zhang Wang[1]，Tao Runguo[1]，Liao Haoran[1]，Wang Wenjun[1]
（1. College of Intelligence and Computing，Tianjin University，Tianjin 300350，China；
2. School of New Media and Communication，Tianjin University，Tianjin 300350，China）

Abstract：Existing methods for dynamic network representation learning typically rely on assumptions of network smoothness and first-order Markovian dynamics to model temporal evolution. However，real-world dynamic networks often violate these assumptions，exhibiting periodic or long-range dependencies that undermine the effectiveness and generalizability of current techniques. To overcome this limitation，we introduce a community-optimized Transformer-based dynamic network embedding（CO-TDNE）model. The CO-TDNE model employs stacked Transformer attention mechanisms combined with a temporal positional encoding strategy to effectively capture diverse graph structures and complex temporal dependencies，thereby accommodating abrupt changes and noise inherent in real-world dynamic networks. To address the high computational cost and scalability challenges of Transformer on large-scale graphs，we propose a novel optimization strategy that identifies stable communities from a global perspective and implements parameter sharing within these communities. This strategy improves training efficiency by 30%—35% while maintaining model performance. Empirical validation on six real-world datasets confirms that the first-order Markovian assumption does not strictly hold in practice. In addition，experiments on new link and missing link prediction tasks demonstrate that CO-TDNE outperforms baseline methods in modeling temporal evolution patterns

收稿日期：2025-07-29；**修回日期**：2025-08-06.
作者简介：李天鹏（1995—　　），男，博士，助理教授，ltpnimeia@tju.edu.cn.
通信作者：王文俊，wjwang@tju.edu.cn.
基金项目：国家自然科学基金资助项目（6247072183）.
Supported by the National Natural Science Foundation of China（No. 6247072183）.

and topological structures. Comprehensive ablation studies further demonstrate the efficiency of the proposed global stable community optimization strategy in reducing model parameter complexity and highlight the effectiveness of the community-based hierarchical network optimization approach.

Keywords: dynamic network; dynamic graph; network representation learning; dynamic link prediction

在数据驱动时代,海量数据作为解析现实世界复杂系统的关键介质,其价值转化高度依赖于对复杂关联关系的系统性解构. 网络结构数据凭借其天然的实体关系建模能力,已成为社交网络分析[1]、论文合作分析[2]、交通流量预测[3]等领域的重要研究工具,并获得了广泛的研究与应用.

虽然静态网络能够有效捕捉网络的结构特征,却无法刻画节点和边随时间演化的动态模式. 现实中的网络本质上是动态演化的系统,其节点状态和交互关系会随突发事件、周期性规律等时变因素发生非平稳突变,这种动态特性在流行病传播网络、金融市场关联网络等场景中尤为显著[4]. 鉴于此,动态网络逐渐成为复杂系统建模的关键范式,其核心优势在于能够通过时空建模框架,同步捕获网络拓扑结构的瞬时特征和演化规律.

目前动态图表示学习的方法在捕获时间维度依赖关系方面已经做出了许多尝试,例如采用增量更新或循环神经网络[5],但基本都需要数据遵守网络平滑性假设及隐马尔科夫性假设,即动态快照网络中,相邻快照的网络拓扑变化较小,且当前快照的网络结构的生成只与前一个快照有关. 然而现实世界中动态网络各快照之间的时间依赖关系并不总是严格遵循这两种假设[4],大部分动态网络快照如论文引用网络、在线社交网络等虽大多数符合网络平滑性假设,但未必满足隐马尔可夫性假设;在网络呈现周期性变化(Email 网络)或不规则变化时(Bitcoin 信任网络),则基于上述假设的动态网络表示学习方法的实际效果将会出现较大波动,难以适用于真实世界场景. 特别是当节点集产生跨多个快照的演化且该演化过程是非平滑、不均匀、且频繁变化的,现有的方法往往缺乏有效捕捉此类不严格符合网络平滑性假设关系的能力[6].

近年来,针对动态网络偏离平滑性假设以及隐马尔可夫性假设的情况提出了基于注意力机制的动态网络表示学习方法. 例如,DySAT[7]通过图注意力模型提取节点的结构信息,同时利用自注意力机制捕获节点的时间依赖性. 而 DyFormer[8]则进一步引入了 Transformer 的多头注意力机制,将时序依赖信息以偏置项的形式融入模型. Transformer 架构的引入为动态网络建模带来了新的突破[6]. 其堆叠的自注意力机制通过时空解耦的计算方式,将时间维度的序列建模与空间维度的拓扑分析分离处理,在时间维度上可以建立任意步长的跨网络快照关联,在空间维度上独立计算每个时间切片内的节点关系,这种解耦机制理论上具备建模非平稳时空依赖的能力[9]. 更重要的是,Transformer 架构的并行计算特性使其天然适合作为预训练基座,其参数共享机制通过跨层权重复用提取跨领域的时空模式,多头注意力机制支持从微观节点交互到宏观社团迁移的多尺度特征学习,位置编码的灵活性则能融合时间戳编码与空间坐标嵌入,为动态网络提供统一的时空表示框架. 因此基于 Transformer 架构的动态网络表示学习模型能够为动态网络预训练模型提供基础模型框架支撑.

然而现有基于 Transformer 架构的动态网络表示学习方法仍然存在局限,即全局注意力机制虽能缓解长程依赖问题,但其堆叠的注意力机制导致其计算复杂度与图规模呈二次增长,难以支撑预训练所需的大规模动态图数据处理. 因此需要设计方法实现基于 Transformer 架构的动态网络表示学习模型的参数优化,提升其对真实世界数据的适配性.

为了解决上述问题,本文提出了基于社团检测优化 Transformer 的动态图表示学习模型(community optimization for transformer based dynamic network embedding, CO-TDNE),该模型利用 Transformer 架构结合时间位置编码捕捉动态图上的时序演化模式,可适用于图结构高度变化、网络快照之间依赖关系复杂的模型,依靠全局注意力机制来得到网络快照间的依赖关系. 此外,考虑到 Transformer 的高计算成本及其在大规模图数据上的有限可扩展性,本文引入了一种全局视角下稳定社团内部参数共享的优化策略,通过社团层级和节点层级双层级多头自注意力机制使得模型能够在不降低模型性能的情况下显著提升训练速度,最高可达 30% ~ 35%. 同时通过在真实世界数据集上的广泛实验表明 CO-TDNE 展现了出色的性能并在大多数数据集上优于其他对比方法.

本文的贡献总结如下:

(1) 本文针对动态网络平滑性假设与隐马尔可夫性假设在非平稳突变下的失效问题,提出了基于社团优化的 Transformer 动态网络表示学习方法 CO-

TDNE；

（2）通过全局稳定社团检测模块，CO-TDNE 设计了基于社团结构的参数共享机制，有效地优化了模型编码器部分的参数量，在不降低模型性能的前提下显著提升了模型的训练速度，最高可达 30% ~ 35%；

（3）针对 6 组不同类型的真实世界动态网络的实验表明，CO-TDNE 的性能优于基线模型，消融实验也证明了所提方法各模块的有效性.

1　动态网络表示学习方法

动态网络表示学习将动态网络建模与下游任务进行分离，其本质还是对动态网络的拓扑结构和演化模式的捕获，其建模思路可以根据对时序信息的刻画思路划分为基于时序平滑的方法、基于递归的方法和基于注意力的方法.

1.1　基于时序平滑的方法

基于时序平滑的方法的核心是在网络平滑性假设以及隐马尔可夫性假设的基础上，将动态快照网络的时序演化作为惩罚项融入原有静态网络表示学习方法中. 例如，DynGEM[10]根据前一快照的嵌入，在考虑网络增量变化的前提下设计生成当前网络快照的增量嵌入以实现动态网络表示学习；COMMLP[11]通过结合动态网络的社团结构抽取动态网络局部、全局、准局部以及社团信息的特征集组成节点表示，利用评分的方式进行时序链接预测；类似地，SSLP[12]基于静态网络特征的时序堆叠获取动态网络节点表示，并在链接预测任务表现出了优秀的性能.

上述方法均严格依赖于网络的平滑性假设与隐马尔可夫性依赖，对于真实世界动态网络在时序存在的噪声、扰动以及剧烈变化的适应能力较差，但在动态网络演化分析任务因其表示向量具有一定的解释意义，或者网络演化过程进行启发式设计而具有一定优势.

1.2　基于递归的方法

基于递归的方法主要利用递归神经网络（recurrent neural network，RNN）及其变体来刻画网络的时序演化. VGRNN[5]结合了图卷积网络和变分循环神经网络，构建了基于变分自回归框架的动态网络表示学习模型. 该方法能够捕捉节点的时间依赖性和图结构的变化特性，在处理动态网络的时序信息方面表现出色. DGC-N[13]通过聚合节点的历史邻域信息，生成随时间变化的节点表示，其设计简单高效，适合处理具有稀疏边连接的动态网络. HGWaveNet[14]通过设计双曲扩张因果卷积和双曲扩散图卷积策略，捕捉动态网络中复杂的时空因果依赖关系，虽然没有利用 RNN 架构捕获时序依赖，但其因果卷积模块的本质还是根据前序节点的邻居信息进行时序信息聚合. SelfRGNN[15]则提出了变曲率黎曼自监督图神经网络框架，通过设计的黎曼空间时序编码模块刻画网络的时序演化，虽然该方法引入了黎曼时序注意力层以提升模型对于时序变化的刻画能力，但仍然服从动态网络的平滑性假设.

上述方法通过基于 RNN 或因果卷积等方式对动态网络的时序演化模式进行建模，一定程度上克服了动态网络的隐马尔可夫性假设的限制，但计算过程仍然需要按照快照的顺序进行，且模型依然建立在动态网络的平滑性假设基础上，因此并未从根本上提升模型对真实世界网络中的周期性变化、不规则扰动的有效刻画.

1.3　基于注意力的方法

基于注意力的方法则在基于递归的方法的基础上引入注意力机制以提升模型对于动态网络时序变化的捕获能力. DySAT[7]通过图注意力模型提取节点的结构信息，同时利用自注意力机制捕获节点的时间依赖性，双通道设计使其能够在结构和时间维度上分别建模，从而提升节点嵌入的质量. DyFormer[8]通过引入位置编码和多头注意力机制，通过将时序依赖信息以偏置项的形式融入 Transformer 架构中，有效捕获节点在时间序列中的长期依赖关系，在处理大规模动态网络时具有较高的效率和可扩展性. CPDG[16]则提出基于广度优先搜索采样策略获取节点在时序过程中的邻居信息，并利用深度优先搜索获取拓扑信息，利用对比学习架构进行动态网络预训练，以支撑多类下游任务，在微调环节则引入了注意力机制以提升模型对于时序演化信息的捕获能力.

基于注意力的方法通过引入注意力机制以提升模型对于动态网络时序演化的刻画能力，这种方式能够有效克服真实世界数据中不符合网络平滑性假设以及隐马尔可夫性假设所造成的模型性能下降问题，但注意力机制，特别是基于堆叠注意力层的 Transformer 架构在时间复杂度方面相较于其他方法存在劣势.

本文在 Dyformer 的启发下，首先引入时间位置编码，将动态网络时序演化信息直接输入到 Transformer 中，进一步提升模型对于动态网络时序演化的刻画能力，随后针对模型参数优化问题，提出了基于全局稳定社团检测模块的参数共享机制，在编码器结构中对模型参数进行优化，在保证模型效果的前提下提升模型迭代效率达 30% ~ 35%.

2 CO-TDNE 算法

2.1 问题定义

动态网络表示学习旨在通过建模图结构随时间的演化规律,将动态网络中的节点映射到低维向量空间. 给定动态网络序列 $G=\{G^{(1)},G^{(2)},\cdots,G^{(T)}\}$,其中每个快照 $G^{(t)}=(V^{(t)},E^{(t)})$ 由节点集 $V^{(t)}$ 和边集 $E^{(t)}$ 构成,目标是从历史快照中学习节点嵌入 $e_v^{(t)}\in\mathbf{R}^d$,使其既能捕捉图结构的时空演化模式,又能支持下游任务如链路预测和节点分类.

模型旨在解决以下核心问题:如何设计高效的动态网络表示学习框架,使其能够:①建模高度变化的图结构和非马尔可夫依赖关系;②在保证模型表达能力的同时,显著降低 Transformer 的计算复杂度. 本文的主要符号及其定义描述如表 1 所示.

表 1 本文的符号及定义

Tab.1 Symbols and definitions used in this paper

符号	定义及含义
G	动态网络序列,$G=\{G^{(1)},G^{(2)},\cdots,G^{(T)}\}$
$G^{(t)}$	第 t 个快照的图结构,$G^{(t)}=(V^{(t)},E^{(t)})$
$V^{(t)}$	第 t 个快照的节点集合,$\lvert V^{(t)}\rvert=n_t$
$E^{(t)}$	第 t 个快照的边集合,$\lvert E^{(t)}\rvert=m_t$
$\boldsymbol{A}^{(t)}$	第 t 个快照的邻接矩阵,$\boldsymbol{A}^{(t)}\in\{0,1\}^{n_t\times n_t}$
d	节点嵌入维度,$e_v\in\mathbf{R}^d$
$\phi(C)$	社团 C 的导通性
$\mathrm{PE}(t,i)$	时间位置编码第 i 维
c	全局稳定社团数量
h	Transformer 注意力头数
$\dim_{\mathrm{emb}}$	多头注意力隐空间维度
V'	联合时序图节点全集,$V'=\bigcup_{t=1}^{T}V^{(t)}$
E'	联合时序图边全集,$E'=\bigcup_{t=1}^{T}E^{(t)}$
$\boldsymbol{W}'$	联合时序图边的权重矩阵,$W'_{ii}=\sum_t \boldsymbol{A}_{ii}^{(t)}$

2.2 模型描述

CO-TDNE 主要由编码器层和解码器层组成,算法架构如图 1 所示,在编码器部分引入全局稳定社团检测算法寻找动态网络全局视角下的稳定社团结构,并在社团内部优化编码器模块中的参数数量以及训练策略,通过重构误差实现模型参数训练.

2.2.1 全局稳定社团检测

现有的动态网络表示学习方法主要关注节点级别的嵌入,这带来了可扩展性和计算效率的问题,尤其是在处理大规模图数据时尤为明显. 为了解决这一问题,模型从社团检测角度出发,提出了一种检测稳定且时间不变的全局社团结构的方法.

如图 2 所示. 首先基于联合时序图和 PageRank 算法[17-18]寻找动态网络全局影响力节点,再以这些节点作为中心节点基于导通性的启发式算法寻找局部社团结构,最终得到全局稳定社团结构. 这些社团由具有相似结构和特征的节点组成,促进了参数共享并提升模型效率.

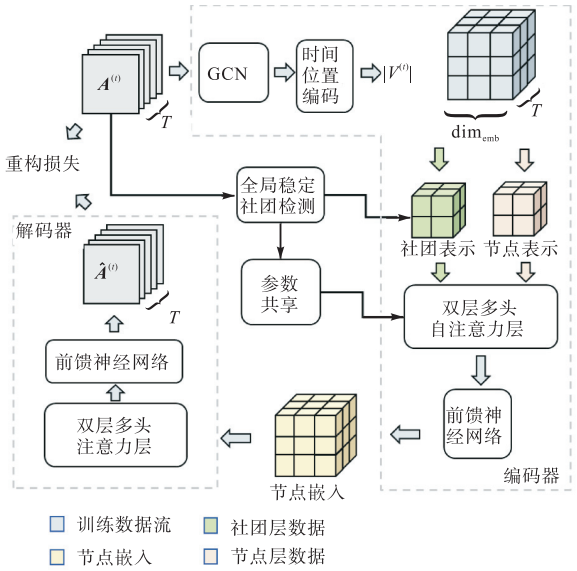


图 1 CO-TDNE 模型架构

Fig.1 Framework of CO-TDNE

全局稳定社团检测算法的整体思路如图 2 所示,为了高效地识别动态网络中的社团结构,首先将动态网络 $G=\{G^{(1)},G^{(2)},\cdots,G^{(T)}\}$ 聚合为一个联合时序图 $G_{\mathrm{union}}=(V',E')$. 在该联合图中,$V'$ 包含出现在任何时间快照中的所有节点,即:

$$V'=\{i\mid\exists i\in V^{(t)},t\in T\} \tag{1}$$

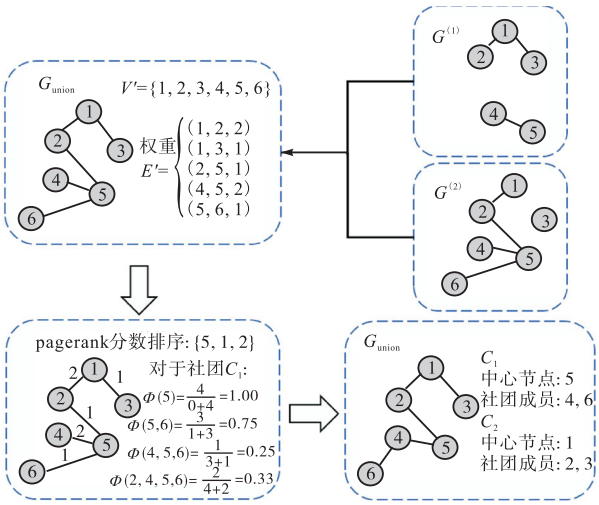


图 2 全局稳定社团检测计算流程

Fig.2 Calculation process of global stable community detection

类似地，E' 包含出现在任何时间快照中的所有边，即

$$E'=\{(i,j)\mid \exists (i,j)\in E^{(t)},t\in T\} \tag{2}$$

联合图中任意边 (i,j) 的权重定义为

$$\boldsymbol{W}'_{ij}=\sum_t \boldsymbol{A}_{ij}^{(t)} \tag{3}$$

从全局角度来看，本模块的目标是识别具有高度影响力的节点作为局部社团发现的中心点，这些节点在其所属社团中同时最具影响力. 全局影响力反映一个节点对全局结构的维持作用，而社团内影响力则反映了其代表整个社团的能力.

为找到具有最高全局影响力的前 k 个节点，模型在联合图 G_{union} 上执行随机游走. 从任意节点 i 转移到其邻居节点 j 的概率 $p(i,j)$ 由边 (i,j) 的归一化权重决定，随机游走转移矩阵的具体表达式为

$$p(i,j)=\frac{\boldsymbol{W}'_{ij}}{\sum\limits_{k\in N(i)}\boldsymbol{W}'_{ik}} \tag{4}$$

式中 $N(i)$ 表示节点 i 的所有邻居节点集合.

计算出联合图中任意两个节点之间的转移概率后，进一步计算 G_{union} 上所有节点的 PageRank 分数. 具有最高 PageRank 分数的前 k 个节点被选为全局稳定社团发现的中心点[1].

设无向图 $G=(V,E)$ 包含 $n=|V|$ 个节点和 $G=(V,E)$ 条无向边，邻接矩阵 $\boldsymbol{A}$ 满足对称性 $\boldsymbol{A}_{uv}=\boldsymbol{A}_{vu}$，即假设所处理的图为无向图. 经典 PageRank 向量 $r\in\mathbf{R}^n$ 满足如下的线性系统.

$$r=(1-\alpha)e+\alpha\boldsymbol{M}r \tag{5}$$

式中：$\alpha\in(0,1)$ 为阻尼因子；$e\in\mathbf{R}^n$ 为均匀分布向量（即 $e_i=1/n$）；$\boldsymbol{M}\in\mathbf{R}^{n\times n}$ 为状态转移矩阵，在本文中 $\boldsymbol{M}_{ij}=p(i,j)$.

得到全局影响力的节点后，将这些点作为中心点形成初始社团结构，并将所有邻居节点纳入社团中. 模型使用导通性来衡量社团结构，对于一个社团 C，其导通性定义为

$$\phi(C)=\frac{\sum\limits_{i\in C,k\notin C,(i,k)\in E'}\boldsymbol{W}'_{ik}}{\min\left(\sum\limits_{i,j\in C,(i,j)\in E'}\boldsymbol{W}'_{ij},\sum\limits_{i\in C,k\notin C,(i,k)\in E'}\boldsymbol{W}'_{ik}\right)} \tag{6}$$

式(6)中的分子表示社团 C 与外部的连边数量，对于加权图则为权重求和，分母则为社团内与社团间连边权重的最小值. 如果将某个节点纳入局部社团可以降低该社团的导通性，则认为这加强了该局部社团，正式将该节点纳入局部社团. 因此，每次从局部社团中选取存在社团外邻居节点的节点，计算该节点所有社团外邻居节点加入该社团后的导通性，若导通性降低则将该邻居节点加入社团，否则舍弃. 迭代该过程直至社团内所有节点的社团外邻居节点无法使得社团导通性下降则得到一个全局稳定社团结构. 这些社团结构将在模型的编码器部分中使用，在设计中可以通过多层级逐步聚合节点信息，从而实现从节点级别到社团级别的转换. 层级的数量可以根据性能和效率的需求进行选择，以达到平衡.

2.2.2　图特征提取模块

在该部分模型首先使用图卷积网络聚合动态网络每个时间快照的特征. 对于时间 t 的快照，提取特征生成大小为 $n\times\dim_{\text{emb}}$ 的特征矩阵 $\boldsymbol{F}_t=\text{GCN}(\boldsymbol{X}(t),\boldsymbol{A}(t))$，式中 n 表示节点数量，$\dim_{\text{emb}}$ 表示节点嵌入维度. 式中属性矩阵与拓扑矩阵的行数均为 n，而属性矩阵的列则设置为节点嵌入维度 $\dim_{\text{emb}}$. 在聚合所有快照的特征后，获得一个大小为 $t\times n\times\dim_{\text{emb}}$ 的时间级节点特征矩阵. 该矩阵随后作为编码器层的输入.

为了区分不同快照之间的时间信息，使用 Transformer 模型中位置编码来为每个快照编码时间信息.

$$\begin{cases}\text{PE}(t,2i)=\sin\left(t/1\,000^{2i/\dim_{\text{emb}}}\right)\\ \text{PE}(t,2i+1)=\cos\left(t/1\,000^{2i/\dim_{\text{emb}}}\right)\end{cases} \tag{7}$$

式中：PE 表示位置编码；t 表示快照的编码；i 表示节点嵌入的特定维度. 例如，当 $\dim_{\text{emb}}=32$ 时，$i=0,1,\cdots,15$. 动态网络快照的位置编码矩阵与动态网络表示矩阵以相加的方式进行结合，以注入时序位置信息.

图特征矩阵的时间维度进入编码器层并经历维度变换，从 $t\times n\times\dim_{\text{emb}}$ 矩阵转换为 $n\times t\times\dim_{\text{emb}}$ 矩阵. 此变换后的矩阵对应于所有节点在不同快照的嵌入. 接下来，模型利用全局稳定结构社团的信息优化模型. 对于社团 C，中心节点 i 使用 GCN 聚合周围节点的信息，这一过程还聚合了社团内其他节点的嵌入，并将其信息传播到中心节点 i. 因此，社团 C 中其他节点的嵌入可以在所有快照中被中心节点 i 的嵌入 $\text{emb}_i^{\text{node}}$ 替代. 基于这一思想，模型将中心节点 i 的嵌入视为社团 C 的嵌入 $\text{emb}_C^{\text{comm}}$，从而引入了与节点级编码器并行的社团级编码器.

2.2.3　编解码模块

由于全局社团检测不会为所有节点分配社团归属，从全局角度来看，仍然存在一些孤立节点位于所有社团之外. 这些孤立节点需要通过编码器-解码器结构在节点级别进行嵌入. 每个快照的孤立节点嵌入和社团嵌入被用作两个层次级别的输入，由于两个层次中的嵌入维度相同，因此编码器结构不需要任何

额外修改,这意味着编码器结构可以在两个层次之间复用.

在编码器中,将嵌入模块生成的节点嵌入 $\mathrm{emb}_{\mathrm{node}}$ 和社团嵌入 $\mathrm{emb}_{\mathrm{comm}}$ 分别作为节点级和社团级的输入. 由于编码器结构的可复用性,这两个层次的输入统称为 $\mathrm{emb}_{\mathrm{enc}}$. $\mathrm{emb}_{\mathrm{enc}}$ 作为多头注意力层中查询(Key)、键(Query)和值(Value)的输入,允许多个头创建不同的子空间,从而使模型能够关注信息的不同方面. 第 l 层的多头注意力可以表示为

$$\begin{aligned}&\mathrm{MultiHead}(\mathrm{emb})=\\&\quad\mathrm{Concat}(\mathrm{head}_1,\cdots,\mathrm{head}_h)\boldsymbol{W}^{\mathrm{O}}\end{aligned}\tag{8}$$

式中 $\boldsymbol{W}^{\mathrm{O}}$ 为输出的注意力参数.

$$\mathrm{head}_i=\mathrm{softmax}\left(\frac{\boldsymbol{Q}\cdot\boldsymbol{K}^{\mathrm{T}}}{\sqrt{\dim_{\mathrm{emb}}}}\right)\boldsymbol{V}\tag{9}$$

式中:head_i 表示多头注意力第 i 个头,每个头根据 Query 和 Key 的相似性选择 Value;$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 分别表示查询、键、值矩阵,$\boldsymbol{Q}=\mathrm{emb}_{\mathrm{enc}}\boldsymbol{W}^{Q}$,$\boldsymbol{K}=\mathrm{emb}_{\mathrm{enc}}\boldsymbol{W}^{K}$,$\boldsymbol{V}=\mathrm{emb}_{\mathrm{enc}}\boldsymbol{W}^{V}$,其中 $\boldsymbol{W}^{Q}$、$\boldsymbol{W}^{K}$、$\boldsymbol{W}^{V}$ 为第 i 层多头注意力独立学习的参数矩阵,用于将输入数嵌入映射到查询、键、值 3 个不同的子空间. 所有头通过拼接操作组合在一起,形成最终的多头注意力机制.

多头注意力层的输出经过归一化层后,作为全连接前馈层的输入,遵循以下公式:

$$\mathrm{FFN}(\mathrm{emb})=\max(0,\mathrm{emb}\cdot\boldsymbol{W}_1+b_1)\boldsymbol{W}_2+b_2\tag{10}$$

所得输出随后经过另一个归一化层,以获得所有快照中所有孤立节点和社团的嵌入. 归一化层由 LayerNorm 和残差连接操作组成.

在编码器结构中,引入社团级别的视角确实可以显著节省训练时间. 假设在全局范围内发现稳定结构社团的阶段,当发现有 c 个社团,每个社团包含 m 个成员,孤立节点的数量为 $|V'|-cm$. 则与不使用优化策略相比,整个编码器部分的整体优化率可以计算为 $\dfrac{c(m-1)}{|V'|}$.

在实际实验设置中,优化编码器部分对提高模型的整体训练速度起着至关重要的作用. 这种优化策略利用全局发现的稳定社团结构来减少计算负担,从而实现更高效的训练.

在解码器部分,模型从节点为中心的视角解决问题,计算每个节点的嵌入. 此外,解码器层包含两个多头注意力层.

第 1 个多头注意力层与编码器中的多头注意力层类似,但模型对其进行了 2 项改进. 首先,引入了类似于自然语言处理(natural language processing, NLP)中使用的“句子起始”(beginning of sentence, BOS)标记的概念. 在 CO-TDNE 中,BOS 标记的具体体现是初始图嵌入. 其在训练阶段通过随机初始化获得,在下游任务阶段则从训练阶段编码器的输出中派生,同时移除最后一个快照以保持输入大小的一致性. 这种设计旨在确保当前时刻的训练数据不会影响当前快照节点嵌入的计算;其次,在解码器中引入一个额外的序列掩码机制,以确保在计算节点嵌入时,模型仅依赖于前序快照的信息,防止信息泄露. 通过这两种方法,在重建任意时刻 t 的快照时仅依赖于快照 0 ~ $t-1$ 的信息($t>1$). 快照 0 对应的网络拓扑从可学习或随机初始化的初始图嵌入中重建.

第 2 个多头注意力层将第 1 个多头注意力层的输出作为查询,并将编码器的输出重新用于计算节点嵌入矩阵 $\mathrm{emb}'_{\mathrm{enc}}$,其维度为 $n\times t\times\dim_{\mathrm{emb}}$,用作键和值. $\mathrm{emb}'_{\mathrm{enc}}$ 中任意节点 i 的嵌入,记为 $\mathrm{emb}'_{\mathrm{enc},i}$,可以表示如下:

$$\mathrm{emb}'_{\mathrm{enc},i}=\begin{cases}\mathrm{emb}'_{\mathrm{node},i} & \nexists m\ \text{s.t.}\ i\in m\\ \mathrm{emb}'_{\mathrm{comm},m} & \exists m\ \text{s.t.}\ i\in m\end{cases}\tag{11}$$

与编码器类似,解码器中第 2 个多头注意力层的输出经过归一化和前馈层,以获得所有快照中每个节点的嵌入. 这些嵌入被组合并转换为矩阵 $\mathrm{emb}_{\mathrm{dec}}$. 经过线性层后,$\mathrm{emb}_{\mathrm{dec}}$ 进一步转换为动态网络的拓扑结构重构 $\hat{\boldsymbol{A}}$.

2.2.4 模型训练

模型的目标函数来源于每个快照的重建误差. 时间 t 的重建误差 Loss_t 的计算式为

$$\begin{aligned}\mathrm{Loss}_t=-\frac{1}{|V^{(t)}|^2}\sum_{i=1}^{|V^{(t)}|}\sum_{j=1}^{|V^{(t)}|}&\Big(\boldsymbol{A}(t)_{ij}\cdot\ln\big(\hat{\boldsymbol{A}}(t)_{ij}\big)+\\&\big(1-\boldsymbol{A}(t)_{ij}\big)\cdot\ln\big(1-\hat{\boldsymbol{A}}(t)_{ij}\big)\Big)\end{aligned}\tag{12}$$

式中:$\boldsymbol{A}(t)_{ij}$ 表示时间 t 的原始邻接矩阵中边 $\{i,j\}$ 的值;$\hat{\boldsymbol{A}}(t)_{ij}$ 表示时间 t 的重建快照中对应边 $\{i,j\}$ 的值. $\hat{\boldsymbol{A}}(t)_{ij}$ 的值是通过将时间 t 的嵌入 $\mathrm{emb}_{\mathrm{dec}}(t)$ 传递到线性层获得的. 整个模型的总损失通过对每个快照的损失求和得到,表示为

$$\mathrm{Loss}=\sum_{t=1}^{T}\mathrm{Loss}_t\tag{13}$$

在模型训练阶段,编码器学习获取更好的节点表示,而解码器学习如何有效利用节点表示和历史信息来重建动态图.

2.3 复杂度分析

对于网络快照数量为 t、最大节点数为 v、最大边数为 e、嵌入维度为 d、Transformer 层为 n、注意力

头数为 h 的动态网络，忽略全局社团优化时，CO-TDNE 的时间复杂度为 $O(etd+nvt^2d)$，其中，基于自注意力机制的计算复杂度为 $O(nvt^2d)$，GCN 部分的迭代时间复杂度为 $O(etd)$. 考虑到社团优化能够将编码器部分参数进行优化，对于总社团数量为 c，每个社团平均成员为 m，则编码器整体优化率为 $c(m-1)/v$. 空间复杂度为 $O(hnvd^2t^2)$，其中 GCN 部分的参数量为 $O(vdt)$，编码器部分的参数量为 $O(hndt)$.

3 实　验

3.1 实验设置

为了验证 CO-TDNE 的性能，本文在 6 个真实世界动态网络数据集中开展了广泛的实验，主要利用缺失边链接预测以及新边链接预测验证模型对于动态网络拓扑结构以及时序演化模式的建模能力，并通过消融实验与参数敏感性分析验证模型各模块的有效性.

3.1.1 数据集

通过对相关文献中的标准数据集的比对，本文最终选取了 6 个广泛使用的真实世界动态网络数据，包括公司内部关系网络 Enron[19]、文献引用网络 DBLP[5]、学校交友网络 HighSchool[13]、在线社交网络 FaceBook[20]、邮件网络 Email[13]以及比特币交易平台的用户信任评分网络 BitcoinOTC[13]，各数据集的统计信息以及测试快照数量设置如表 2 所示.

表 2　数据集统计信息

Tab.2　Dataset statistics

数据集	节点数	边数	快照数量	测试快照数量
Enron	184	4 784	11	3
DBLP	315	5 104	10	3
HighSchool	327	26 870	9	3
FaceBook	663	23 394	9	3
Email	2 029	28 090	29	3
BitcoinOTC	5 053	11 651	12	3

3.1.2 对比模型和评价指标

本文选取了近年来动态网络表示学习任务中具有代表性的方法作为基线模型.

VGRNN[5]：一种基于变分自回归框架的动态网络嵌入模型. 该方法结合图卷积网络和变分循环神经网络以捕捉节点的时间依赖性和图结构的变化特性，在处理网络时序信息方面表现出色.

DySAT[7]：一种融合结构和时间特征的动态网络嵌入方法. 该方法通过图注意力网络(GAT)提取节点的结构信息，同时利用自注意力机制捕获节点的时间依赖性. DySAT 的双通道设计能够在结构和时间维度上分别建模，提升嵌入质量.

DyFormer[8]：一种基于 Transformer 的动态网络建模方法. 该方法通过引入位置编码和多头注意力机制，有效捕获节点在时间序列中的长期依赖关系，在处理大规模动态网络时具有较高的效率和可扩展性.

DGCN[13]：一种基于图卷积网络的动态网络嵌入方法. 该方法通过聚合节点的历史邻域信息，生成随时间变化的节点表示. DGCN 的设计简单高效，适合处理具有稀疏边连接的动态网络.

HGWaveNet[14]：一种结合图神经网络和 WaveNet 架构的动态网络建模方法. 该方法通过双曲扩张因果卷积和双曲扩散图卷积策略，捕捉动态网络中复杂的时空依赖关系，在时间序列预测任务中表现出较强的性能.

SSLP[12]：一种基于静态网络特征时序堆叠的动态网络连接预测算法. 该方法证明了通过静态网络特征的时序堆叠集成方式能够达到近乎理论最优的性能，且具有优越的可解释性.

为了评价 CO-TDNE 算法与基线方法的优劣，本文以 ROC 曲线下面积(area under ROC curve，AUC) a_{UC} 和平均精度(average precision，AP) P_{a}[14]作为性能评估的核心指标. AUC 能够更好地体现模型的整体性能，而 AP 则反映了稀疏场景下的预测效果，二者综合对比能够全面地衡量动态网络表示学习模型对于网络拓扑以及时序演化建模的能力.

AUC 衡量的是 ROC 曲线下的面积，用于评估模型在不同分类阈值下的性能，对于二分类问题，定义真正例率 r_{TP} 和假正例率 r_{FP} 为

$$r_{\mathrm{TP}}=\frac{P_{\mathrm{T}}}{P_{\mathrm{T}}+N_{\mathrm{F}}},\ r_{\mathrm{FP}}=\frac{P_{\mathrm{F}}}{P_{\mathrm{F}}+N_{\mathrm{T}}} \tag{14}$$

式中：P_{T} 为真正例数；P_{F} 为假正例数；N_{T} 为真负例数；N_{F} 为假负例数.

ROC 曲线在 FPR-TPR 坐标系中描绘分类器的判别性能. a_{UC} 通过积分计算得到，即

$$a_{\mathrm{UC}}=\int_0^1 r_{\mathrm{TP}}\left(r_{\mathrm{FP}}^{-1}(r)\right)\mathrm{d}r \tag{15}$$

在离散情况下，AUC 通常通过梯形法则近似计算，即

$$a_{\mathrm{UC}}\approx\sum_{i=1}^{n-1}\frac{r_{\mathrm{TP}_i}+r_{\mathrm{TP}_{i+1}}}{2}\cdot\left(r_{\mathrm{FP}_{i+1}}-r_{\mathrm{FP}_i}\right) \tag{16}$$

平均精度 P_{a} 量化准确率-召回率曲线 PRC 下的面积，适用于类别分布不均衡的场景. 令准确率 Pr 与召回率 Re 定义为

$$\mathrm{Pr}=\frac{P_{\mathrm{T}}}{P_{\mathrm{T}}+P_{\mathrm{F}}},\ \mathrm{Re}=\frac{P_{\mathrm{T}}}{P_{\mathrm{T}}+N_{\mathrm{F}}} \tag{17}$$

相较于 a_{UC}，P_a 对类别分布更敏感，能够直接反映检索系统的排列质量.

3.1.3　参数设置

本文所有实验均在 Ubuntu 20.04.1 版本的 Linux 系统下进行，该实验环境配备了 Intel(R) Xeon (R) Silver 4210R CPU @ 2.40 GHz 和 4 张显存为 24 GB 的 NVIDIA GeForce RTX 3090 GPU.

在本文的实验过程中，考虑到效率和性能，沿用 VGRNN 中的参数设置，将测试网络快照数量设置为 4，从每个快照中随机选择 5% 和 10% 的边作为链接预测任务的验证集和测试集评估性能.

为了保证公平，本文所有任务的嵌入维度均设置为 32，CO-TDNE 注意力头数量设置为 8，前馈神经网络隐藏层维度设置为 16. 在实验中，CO-TDNE 默认采用 70% 节点使用全局稳定社团优化策略，并利用所有节点进行计算. 在训练阶段，采用 Adam 优化算法来进行模型训练，为了防止模型过拟合丢弃率设置为 0.1，所有数据集学习率设置为 0.01. 对于其他对比方法，本章遵循了原文献中描述的最优参数设置，并统一将嵌入维度均设置为 32，前馈神经网络隐藏层维度设置为 16.

3.2　动态网络快照时序依赖性分析

为了验证本文提出的动态快照网络中，连续快照的隐马尔可夫性假设失效的普遍性，本节针对实验所使用的 6 个不同类型的真实世界动态网络数据集进行了全局网络快照时序依赖性分析. 通过计算网络快照之间的依赖关系进行了热图可视化及其分析.

如图 3 所示，6 组热图分别呈现了 6 个真实世界动态网络数据集各时刻网络快照之间的关联关系，颜色越浅表示关联关系越强，对角线表示动态网络各快

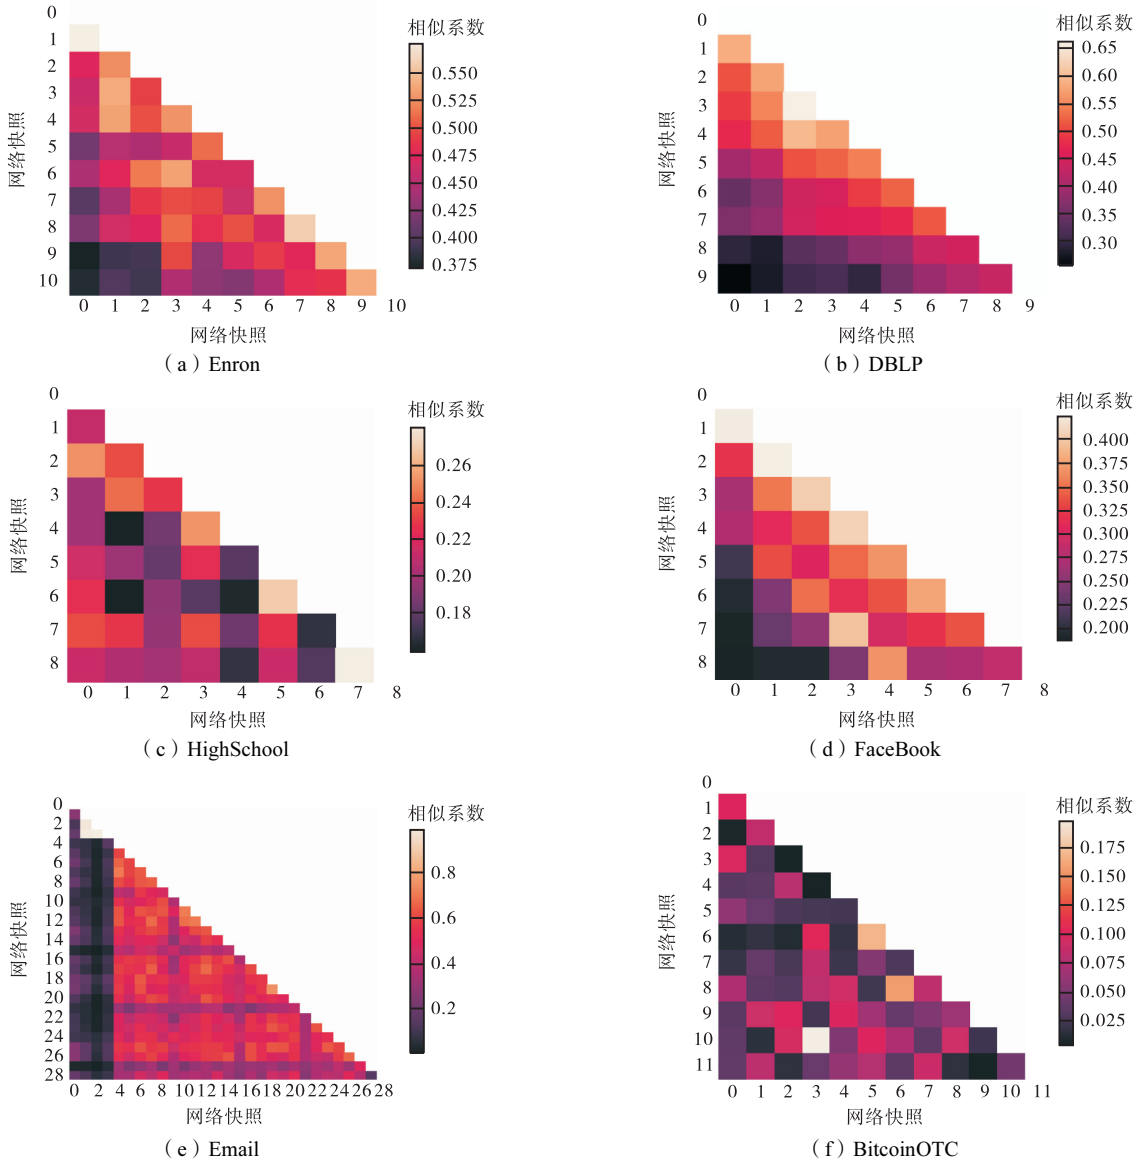


图 3　动态网络快照间的关联性可视化热图

Fig.3　Heat map of correlations between snapshots in different dynamic networks

照的自相关性，图中将其剔除.

Enron、DBLP 和 FaceBook 数据均大体呈现出了较强的隐马尔可夫性，即对角线的块颜色最浅，但注意到仍然存在部分较浅的块不在对角线；反观 HighSchool 与 BitcoinOTC 数据则呈现出了不规律的关联性，且 HighSchool 数据中出现了相邻快照关联性极差的情况；Email 数据则呈现出了一定的周期性，这与邮件网络的工作性质有一定关联.

总的来说，动态快照网络的隐马尔可夫性假设在真实世界数据中仍然有效且符合直觉，但违反隐马尔可夫性假设的情况也普遍存在于真实世界中，这大大限制了动态网络表示学方法的实际应用.

3.3　链接预测

为了验证 CO-TDNE 模型在动态网络表示学习中的有效性，本文将 CO-TDNE 模型与基线模型在缺失边链接预测与新边链接预测任务中进行了对比. 缺失边链接预测指的是通过对 $\leqslant t$ 时刻动态网络拓扑信息的捕获，来预测 $t+1$ 时刻的网络结构 G^{t+1}；而新边链接预测则更具挑战性，需要预测在 G^t 中不存在，但在 G^{t+1} 中新产生的边，这要求模型能够准确捕获动态网络的时序演化模式[21].

3.3.1　缺失边链接预测

缺失边链接预测结果如表 3 所示，CO-TDNE 模型在几乎所有数据中均表现出了最优或次优的 a_{UC} 与 P_{a} 值. 注意到 CO-TDNE 在 Enron 数据以及 DBLP 数据中的效果略落后于 HGWaveNet 与 VGRNN，其中在 Enron 数据集中，CO-TDNE 与 HGWaveNet 表现相当，在 DBLP 数据集中约落后 HGWaveNet 1.3%. 这是因为 Enron 与 DBLP 数据相较于其他数据集更加符合隐马尔可夫性假设，HGWaveNet 由于其设计的双曲卷积机制，能够有效地捕获 DBLP 数据中的层次结构. 而 VGRNN 的变分图自编码器架构能够有效捕获动态网络各快照的拓扑结构，RNN 的时序建模则能够有效地捕获符合隐马尔可夫性假设的 Enron 数据，对于不符合隐马尔可夫性假设的部分数据，也能够通过长短时记忆机制进行一定程度的刻画.

表 3　CO-TDNE 与基线模型的缺失边链接预测结果

Tab.3　Missing link prediction results of CO-TDNE compared with baselines

评价指标	模型	Enron	DBLP	HighSchool	FaceBook	Email	BitcoinOTC
a_{UC}	VGRNN	93.42 ± 0.70	85.80 ± 0.78	89.66 ± 0.32	89.79 ± 0.34	91.92 ± 1.18	81.34 ± 3.25
	DySAT	88.81 ± 1.10	86.74 ± 1.51	91.51 ± 0.48	88.88 ± 0.89	90.42 ± 0.91	83.06 ± 2.71
	Dyformer	90.35 ± 0.45	77.74 ± 0.63	85.01 ± 0.29	83.74 ± 0.76	91.08 ± 0.44	83.62 ± 1.01
	DGCN	85.27 ± 0.85	72.03 ± 0.54	66.18 ± 0.53	68.65 ± 0.29	95.12 ± 0.30	84.35 ± 4.88
	HGWaveNet	94.45 ± 0.26	88.95 ± 0.47	91.64 ± 0.22	86.98 ± 0.66	92.49 ± 0.36	80.06 ± 1.27
	SSLP	86.54 ± 1.11	67.39 ± 1.26	79.01 ± 1.33	83.88 ± 0.55	96.16 ± 1.01	92.02 ± 3.13
	CO-TDNE	94.67 ± 0.51	87.64 ± 0.92	94.33 ± 0.80	90.05 ± 0.50	95.83 ± 1.01	89.23 ± 1.97
P_{a}	VGRNN	94.50 ± 0.66	88.64 ± 0.58	88.71 ± 0.65	89.14 ± 0.41	93.34 ± 0.70	88.62 ± 2.37
	DySAT	87.30 ± 1.54	89.64 ± 1.00	89.17 ± 1.12	88.61 ± 0.96	89.19 ± 1.17	81.18 ± 2.59
	Dyformer	90.78 ± 0.44	78.94 ± 0.51	84.25 ± 0.34	81.16 ± 0.72	92.39 ± 0.49	84.54 ± 1.74
	DGCN	84.51 ± 0.79	73.14 ± 0.69	66.09 ± 0.56	68.78 ± 0.34	95.32 ± 0.31	81.42 ± 3.74
	HGWaveNet	94.37 ± 0.32	91.72 ± 0.38	90.86 ± 0.25	85.96 ± 0.71	94.02 ± 0.32	81.15 ± 1.24
	SSLP	16.88 ± 5.13	15.93 ± 1.64	77.63 ± 2.18	37.47 ± 1.98	55.37 ± 2.89	63.94 ± 2.14
	CO-TDNE	93.87 ± 0.39	90.52 ± 0.48	94.10 ± 0.83	89.84 ± 0.56	96.65 ± 0.42	88.63 ± 2.70

注意到 SSLP 方法在 Email 数据中取得了最优的 a_{UC}，证明该方法所设置的网络静态特征对于网络拓扑的可解释性建模对周期性变化的动态网络更有优势. 另外，Dyformer 同样利用 Transformer 架构刻画动态网络的时空模式，但整体效果弱于 CO-TDNE 约 4.1%，这是因为其将时间与空间特征作为自注意力的偏置项融入 Transformer 架构中，这是的模型对于网络拓扑与时序演化特征的刻画相对间接，这会损失一定的动态网络时空信息.

3.3.2　新边链接预测

新边链接预测结果如表 4 所示，CO-TDNE 与各基线方法在新边链接预测任务中均呈现出不同程度的效果下降，特别是 SSLP 方法在 BitcoinOTC 数据上的 a_{UC} 以及 P_{a} 下降幅度超过了 50%，这说明该方法对于动态网络演化模式的建模能力较差. CO-TDNE 仍然在大部分数据集中呈现出了最好的 a_{UC} 及 P_{a} 值，这证明了本文所提出的多层注意力机制结合时间位置编码策略对于动态网络快照间复杂相关

关系建模的有效性,也证明了基于时间位置编码的方式相较于 Dyformer 的时序信息捕获策略更加有效. 注意到 HGWaveNet 仍然在 Enron 数据以及 HighSchool 数据中取得了次优的效果,且在 DBLP 数据中取得了最优的效果,这证明了论文引用网络以及真实世界交友网络可能存在潜在的层级结构,使得双曲编码能够取得较好地建模效果. VGRNN 也在 FaceBook 数据中取得了次优的效果,这得益于变分自编码器对于噪声的鲁棒性. DGCN 则通过改进 GCN 对邻居聚合的同质性问题,其相似性度量对于 Email 网络具有较好的效果,取得了次优的结果.

表 4 CO-TDNE 与基线模型的新边链接预测结果

Tab.4 New link prediction results of CO-TDNE compared with baselines

评价指标	模型	Enron	DBLP	HighSchool	FaceBook	Email	BitcoinOTC
a_{UC}	VGRNN	87.41 ± 0.96	75.87 ± 1.65	88.09 ± 0.28	86.76 ± 0.54	90.37 ± 1.28	80.22 ± 2.78
	DySAT	82.58 ± 3.00	76.57 ± 2.30	90.42 ± 0.78	85.97 ± 1.21	81.71 ± 3.97	83.09 ± 2.61
	Dyformer	87.35 ± 0.52	74.76 ± 0.66	84.23 ± 0.33	81.58 ± 0.69	90.62 ± 0.68	81.31 ± 1.69
	DGCN	81.87 ± 0.70	62.48 ± 1.54	62.08 ± 0.28	64.98 ± 0.43	93.21 ± 0.40	83.50 ± 1.83
	HGWaveNet	89.38 ± 0.36	83.73 ± 0.55	89.63 ± 0.24	83.97 ± 0.61	92.05 ± 0.38	79.97 ± 0.99
	SSLP	50.55 ± 7.23	55.63 ± 2.85	94.02 ± 3.21	61.15 ± 1.00	77.82 ± 5.34	48.94 ± 4.16
	CO-TDNE	90.46 ± 0.59	80.41 ± 0.88	91.35 ± 0.78	88.37 ± 0.46	94.36 ± 0.49	88.72 ± 1.55
P_a	VGRNN	88.76 ± 0.70	78.38 ± 1.21	86.81 ± 0.54	85.30 ± 0.66	92.22 ± 0.77	84.85 ± 3.45
	DySAT	83.07 ± 2.89	78.81 ± 2.13	88.76 ± 1.56	84.78 ± 1.79	74.96 ± 3.13	82.24 ± 2.94
	Dyformer	88.00 ± 0.46	73.96 ± 0.73	84.25 ± 0.31	80.66 ± 0.55	91.24 ± 0.76	80.02 ± 2.06
	DGCN	82.03 ± 0.57	64.72 ± 1.52	62.15 ± 0.37	65.65 ± 0.534	93.36 ± 0.43	81.38 ± 1.15
	HGWaveNet	87.71 ± 0.33	86.89 ± 0.47	88.48 ± 0.27	82.30 ± 0.67	93.29 ± 0.38	79.86 ± 1.25
	SSLP	9.88 ± 3.72	17.50 ± 1.44	57.48 ± 5.20	23.56 ± 1.75	34.89 ± 3.11	14.39 ± 2.81
	CO-TDNE	89.74 ± 0.71	83.39 ± 0.64	90.09 ± 0.72	87.91 ± 0.45	95.75 ± 0.53	87.11 ± 2.01

3.4 运行效率对比

表 5 对比了 CO-TDNE 与其他深度学习算法的每个轮次运行时间(此处省略了 VGRNN 与 DGC-N,二者的模型架构与 DySAT 较相似,运行时间也相差不大),可以注意到效果次优的 HGWaveNet 受限于双曲空间计算的复杂性,运行效果最差,而 DySAT 与 Dyformer 的运行效率相较于 CO-TDNE 更好,但其对动态网络时序建模的设计相对简单,对于动态网络的建模效果相较于 CO-TDNE 也更差,因此在整体性能上来看不如 CO-TDNE. SSLP 的运行速度则依赖于对网络特征的计算,面向稀疏网络时运行效率会下降,且相较于 CO-TDNE 仍然较差.

表 5 各算法运行时间对比

Tab.5 Running time comparison

s/轮次

算法	Enron	DBLP	HighSchool	FaceBook	Email
DySAT	2.240	2.268	2.274	4.622	8.620
Dyformer	1.123	2.474	4.728	6.822	17.774
HGWaveNet	67.740	95.316	127.335	262.109	683.212
SSLP	14.991	15.262	25.467	27.197	11.784
CO-TDNE	2.267	3.319	2.945	5.972	25.719

3.5 消融实验

为了验证本文所提出的社团优化的可靠性,本文进一步探讨了,加入社团优化与未加入社团优化的 CO-TDNE 算法的 a_{UC} 效果,如图 4 所示,在 Enron、FaceBook 和 HighSchool 数据集中分别测试加入社团优化以及不加入社团优化的模型的链接预测 a_{UC} 值随训练轮次的收敛情况.

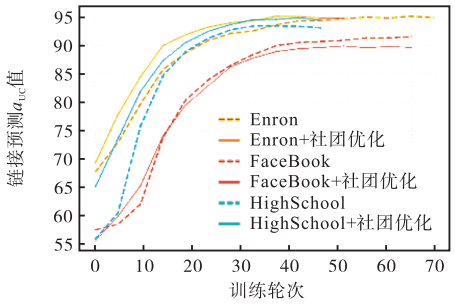


图 4 CO-TDNE 社团优化模块有效性对比

Fig.4 Effectiveness comparison of the community optimization module

可以看到对于 Enron 数据,加入社团优化对模型效果影响不大. 而对于 FaceBook 数据,加入社团优化会使链接预测 a_{UC} 值下降 1.6% 左右. 而对于 HighSchool 数据则出现了加入社团优化模块后模型的链接预测效果提升了 1.8% 的现象,这是因为 HighSchool 数据的高中学生交友网络的边变化与网络内成员所在的社团关联性较大. 总的来说,加入社团优化模块后,在提升模型运行效率的同时,对于最终模型运行效果影响不大,针对特定数据还能够轻微提升效果.

为了验证社团优化模块对 CO-TDNE 模型运行效率的提升，本文测试了剔除社团优化模块与未剔除社团优化模块的 CO-TDNE 模型随动态网络 BitcoinOTC 数据节点总数的运行时间，如图 5 所示，随着节点数的增加，融合了社团优化策略的 CO-TDNE 模型相对未进行社团优化的模型的运行时间提升了约 30% ~ 35%，且数据集中的社团结构越明显，效率提升越高.

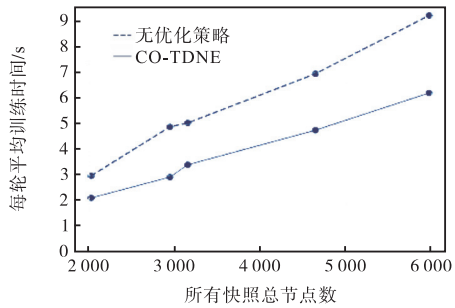


图 5　CO-TDNE 的社团优化模块的运行效率随节点数变化

Fig.5　Efficiency of the CO-TDNE community optimization module as a function of the number of nodes

针对不同社团检测方法效果的消融对比，本文将所提出的全局社团结构识别模块与经典社团检测算法谱聚类(spectral clustering)和 Louvain 算法进行了对比，如图 6 所示，谱聚类与 Louvain 算法所识别的社团结构进行参数优化会使 CO-TDNE 效果呈现出不同程度的下降，这验证了本文所提出的全局社团识别方法对于模型参数优化的有效性.

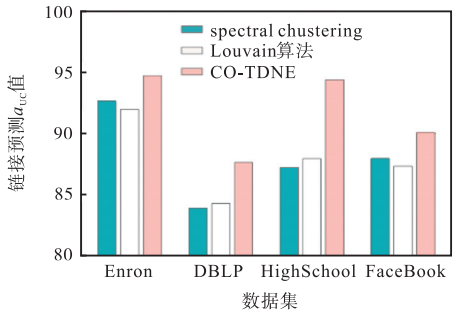


图 6　不同社团检测算法对 CO-TDNE 模型效果的影响

Fig.6　Effect of different community detection algorithms on CO-TDNE model performance

4　结　语

本文介绍了面向动态网络结构高度可变性与时间快照间复杂依赖关系的 CO-TDNE 模型. 针对传统方法的局限性，首先提出了结合时间位置编码策略的动态网络表示学习 Transformer 架构；随后从模型参数优化的角度设计了一种基于全局视角的优化策略，通过稳定社团内部的参数共享机制，在保持模型精度的同时显著提升了训练效率. 实验结果表明，相较于当前主流动态网络表示学习方法，本框架在多个基准数据集上展现出更优的有效性和泛化能力，证明了 CO-TDNE 对动态网络时序演化与拓扑结构的建模能力. 消融实验也证明了所提出的动态网络表示学习方法的有效性以及基于网络层次结构的优化策略的有效性，为后续动态图预训练模型的大规模数据应用提供了优化思路.

参考文献：

[1] 赵琳琳，吴安彪，袁　野，等. 位置社交网络上的图表示学习[J]. 计算机学报，2022，45(4)：838-857.
Zhao Linlin，Wu Anbiao，Yuan Ye，et al. Graph representation learning on location-based social networks[J]. Chinese Journal of Computers，2022，45(4)：838-857(in Chinese).

[2] Guo X，Li J，Jiao P F，et al. Counterfactual learning for higher-order relation prediction in heterogeneous information networks[J]. Neural Networks，2025，183：107024.

[3] Zhang Q R，Yang P，Yu J L，et al. A survey on point-of-interest recommendation：Models，architectures，and security[J]. IEEE Transactions on Knowledge and Data Engineering，2025，37(6)：3153-3172.

[4] Goyal P，Chhetri S R，Canedo A. Dyngraph2vec：Capturing network dynamics using dynamic graph representation learning[J]. Knowledge-Based Systems，2020，187(1)：104816.

[5] Hajiramezanali E，Hasanzadeh A，Narayanan K，et al. Variational graph recurrent neural networks[C]//Proceedings of the Advances in Neural Information Processing Systems. Vancouver，Canada，2019，32：1-11.

[6] Karita S，Chen N X，Hayashi T，et al. A comparative study on transformer *vs* RNN in speech applications [C]//Proceedings of the 2019 IEEE Automatic Speech Recognition and Understanding Workshop. Singapore，2019：449-456.

[7] 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. Houston，USA，2020：519-527.

[8] Cong W L，Wu Y H，Tian Y D，et al. DyFormer：A scalable dynamic graph transformer with provable bene-

fits on generalization ability[C]//Proceedings of the 2023 SIAM International Conference on Data Mining. Paul Twin Cities, USA, 2023: 442-450.

[9] Zhou H Y, Zhang S H, Peng J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Austin, USA, 2021, 35(12): 11106-11115.

[10] Goyal P, Nitin N, He X R, et al. DynGEM: Deep embedding method for dynamic graphs[EB/OL]. https://arxiv.org/abs/1805.11273, 2018-05-29.

[11] Kumar M, Mishra S, Singh S S, et al. Community-enhanced link prediction in dynamic networks[J]. ACM Transactions on the Web, 2024, 18(2): 1-32.

[12] He X, Ghasemian A, Lee E, et al. Sequential stacking link prediction algorithms for temporal networks[J]. Nature Communications, 2024, 15: 1364.

[13] Gao C, Zhu J Y, Zhang F, et al. A novel representation learning for dynamic graphs based on graph convolutional networks[J]. IEEE Transactions on Cybernetics, 2023, 53(6): 3599-3612.

[14] Bai Q J, Nie C L, Zhang H W, et al. HGWave Net: A hyperbolic graph neural network for temporal link prediction[C]//Proceedings of the ACM Web Conference. Austin, USA, 2023: 523-532.

[15] Sun L, Ye J D, Peng H, et al. A self-supervised Riemannian GNN with time varying curvature for temporal graph learning[C]//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Atlanta, USA, 2022: 1827-1836.

[16] Bei Y C, Xu H, Zhou S, et al. CPDG: A contrastive pre-training method for dynamic graph neural networks [C]//Proceedings of the IEEE 40th International Conference on Data Engineering. Utrecht, Netherlands, 2024: 1199-1212.

[17] 李 琪, 李虎雄, 钟 将, 等. 异构计算环境中图划分算法的研究[J]. 计算机学报, 2021, 44(8): 1751-1766.
Li Qi, Li Huxiong, Zhong Jiang, et al. Research on graph partitioning in heterogeneous computing environment[J]. Chinese Journal of Computers, 2021, 44(8): 1751-1766(in Chinese).

[18] 张良富, 李翠平, 陈 红. 大规模图上的 SimRank 计算研究综述[J]. 计算机学报, 2019, 42(12): 2665-2682.
Zhang Liangfu, Li Cuiping, Chen Hong. Research progress of SimRank computation on big graph: A survey [J]. Chinese Journal of Computers, 2019, 42(12): 2665-2682(in Chinese).

[19] Benson A R, Abebe R, Schaub M T, et al. Simplicial closure and higher-order link prediction[J]. Proceedings of the National Academy of Sciences, 2018, 115(48): 11221-11230.

[20] Rossi R, Ahmed N. The network data repository with interactive graph analytics and visualization[C]// Proceedings of the AAAI Conference on Artificial Intelligence. Austin, USA, 2015: 4292-4293.

[21] 唐 晨, 赵杰煜, 叶绪伦, 等. 动态图的链接预测模型[J]. 计算机科学与探索, 2022, 16(10): 2365-2376.
Tang Chen, Zhao Jieyu, Ye Xulun, et al. Link prediction model for dynamic graphs[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(10): 2365-2376(in Chinese).

(责任编辑: 王晓燕)