

用于社交网络链路预测的时频感知图卷积网络^{*}

何玉林^{1,2}, 赖俊龙², 常家乐^{1,2}, 崔来中², 黄哲学^{1,2}

¹(人工智能与数字经济广东省实验室(深圳), 广东 深圳 518107)

²(深圳大学 计算机与软件学院, 广东 深圳 518060)

通信作者: 崔来中, E-mail: cuilz@szu.edu.cn



摘 要: 社交网络链路预测旨在分析现有的网络信息来推断未来的链接情况. 这是一个极具挑战性的任务, 因为社交网络具有复杂的时空耦合特征, 表现为时间维度上的动态演化(即时间依赖性)和空间维度上的关联互耦(即空间依赖性). 现有方法主要集中在时域和空域建模上, 没有充分利用图快照序列数据的频域信息. 提出一种新的时频感知图卷积网络(time-frequency-aware graph convolutional network, TFAGCN)用于社交网络链路预测. TFAGCN的主要优点是在统一的网络框架中集成频域、时域和空域信息, 同时捕获社交网络数据中的全局时间依赖关系和局部时空依赖关系. 具体来说, TFAGCN引入频域模块与时空模块: 在频域模块中, 使用快速傅里叶变换完成图快照序列的域转换, 并在频域通过多层感知器学习频率分量的实部和虚部以捕获社交网络全局依赖关系; 在时空模块中, 联合图卷积神经网络和门控循环单元网络分别探索单个图快照的局部拓扑特征和局部时间特征. 同时, 设计先进的时频双向交叉注意力网络, 能够自适应地融合频域特征与时域特征. 此外, 为了有效应对大规模社交网络的链路预测问题, 给出 TFAGCN 的简化版本——TFAGS. 在 6 个真实社交网络数据集上进行一系列有说服力的实验验证, 结果显示所设计的时频感知图卷积网络获得了比先进的基线算法更优的链路预测表现, 证实其是一种高效的处理社交网络蕴含信息表达问题的新工具. TFAGCN 的代码可在公开的软件项目托管平台中获取: <https://github.com/junlonglai/TFAGCN>.

关键词: 动态图神经网络; 社交网络; 链路预测; 图学习; 多域特征融合学习

中图法分类号: TP183

中文引用格式: 何玉林, 赖俊龙, 常家乐, 崔来中, 黄哲学. 用于社交网络链路预测的时频感知图卷积网络. 软件学报, 2026, 37(8): 3293–3308. <http://www.jos.org.cn/1000-9825/7535.htm>

英文引用格式: He YL, Lai JL, Chang JL, Cui LZ, Huang ZX. Time-frequency-aware Graph Convolutional Network for Social Network Link Prediction. Ruan Jian Xue Bao/Journal of Software, 2026, 37(8): 3293–3308 (in Chinese). <http://www.jos.org.cn/1000-9825/7535.htm>

Time-frequency-aware Graph Convolutional Network for Social Network Link Prediction

HE Yu-Lin^{1,2}, LAI Jun-Long², CHANG Jia-Le^{1,2}, CUI Lai-Zhong², HUANG Zhe-Xue^{1,2}

¹(Guangdong Laboratory of Artificial Intelligence and Digital Economy (Shenzhen), Shenzhen 518107, China)

²(College of Computer Science and Software Engineering, Shenzhen University, Shenzhen 518060, China)

Abstract: Social network link prediction aims to analyze existing network information to infer future links. This is a highly challenging task because social networks exhibit complex spatio-temporal coupling, characterized by dynamic evolution over time (i.e., temporal dependency) and interdependent correlations across space (i.e., spatial dependency). Existing methods mainly focus on time-domain and space-domain modeling and do not fully utilize the frequency-domain information of graph snapshot sequence data. This study proposes a

* 基金项目: 广东省自然科学基金面上项目(2023A1515011667); 广东省基础与应用基础研究基金粤深联合基金重点项目(2023B1515120020); 深圳市科技重大专项(KJZD20230923114809020)

收稿时间: 2025-03-31; 修改时间: 2025-07-01; 采用时间: 2025-08-26; jos 在线出版时间: 2026-04-29

CNKI 网络首发时间: 2026-04-30

time-frequency-aware graph convolutional network (TFAGCN) for social network link prediction. The main advantage of TFAGCN is that frequency-, time-, and space-domain information is integrated together in a unified network framework, which captures both global temporal dependencies and local spatio-temporal dependencies in social network data. Specifically, this study introduces a frequency-domain module and a spatio-temporal module. In the frequency-domain module, the fast Fourier transform is used to transform the graph snapshot sequence, and the multilayer perceptron is used to learn the real and imaginary parts of the frequency components in the frequency domain to capture the global dependencies of social networks. In the spatio-temporal module, a graph convolutional neural network and a gated recurrent unit network are jointly used to explore the local topological features and local temporal features of individual graph snapshots, respectively. In addition, a time-frequency bidirectional cross-attention network is designed to adaptively fuse frequency-domain features with time-domain features. To address link prediction for large-scale social networks, a simplified version of TFAGCN, namely TFAGS, is designed. Extensive experiments conducted on six real-world social network datasets show that the proposed method outperforms state-of-the-art baseline methods in link prediction, thus confirming its effectiveness as an efficient new tool for social network information representation. The code of TFAGCN is available in this repository: <https://github.com/junlonglai/TFAGCN>.

Key words: dynamic graph neural network; social network; link prediction; graph learning; multi-domain feature fusion learning

现实世界中的各种社会实体及实体之间的关系形成了社交网络, 其中社会实体可以是个人、组织或国家, 实体之间的关系可以是不同类型的联结, 例如友谊、合作、邮件往来等^[1]. 近年来, 随着社交平台的迅速普及和复杂网络技术的快速发展, 社交网络的链路预测问题引起学术界和工业界越来越多的关注. 社交网络链路预测是根据已知的社交网络结构信息预测未来网络中的链接关系, 它在日常生活中有许多应用, 例如好友推荐^[2]、科研合作预测^[3,4]、社区结构识别^[5]等. 因此, 一个准确的社交网络链路预测模型对提升这些实际应用的用户体验感发挥着重要的作用.

早期的链路预测方法专注于构建相似性指数, 这类方法通常利用节点之间的相似性度量来预测它们之间是否存在链接. 代表性算法有共同邻居 (common neighbor, CN)^[6]、Katz^[7]和局部路径 (local path, LP)^[8]. 这些基于相似性指数的方法计算复杂度低, 但它们无法分析网络拓扑结构中的复杂非线性特征. 为了解决这个问题, 研究人员提出了 LPANMF^[9]和 RGNMF-AN^[10]等基于矩阵分解的链路预测方法, 这类方法将网络结构矩阵表示为基矩阵与系数矩阵的乘积, 并以系数矩阵作为网络的节点表示. 这些忽略了时间信息的链路预测算法仍然不适合社交网络等动态网络的链路预测. 为此, 许多研究者利用矩阵分解将时间信息建模到损失函数中, 从中提取动态网络的潜在特征^[11-16]. 尽管这样可以学习时间和空间特征, 但它们的特征提取能力有限.

随着深度学习技术的迅速发展, 其优秀的特征提取能力受到了广泛关注. 在链路预测领域, 基于深度学习的模型展现出了令人鼓舞的应用前景^[17]. 这些模型通常利用不同的特征表示技术建模网络快照序列的结构信息和时间信息, 如 DySAT^[18]、GC-LSTM^[19]和 SRG^[20]等, 它们取得了良好的预测效果. 然而, 这些研究主要集中在时域上, 许多复杂的模型被开发出来去捕获和利用动态网络时域中的信息, 而没有利用频域的信息. 对动态社交网络而言, 频域分析提供了对社交网络的新见解^[21,22], 比如每个频率分量都包含社交网络每个时间步的信号, 能更容易地捕获社交网络的长期时间依赖关系. 因此, 从频域中捕获动态网络的时序特征是一个非常前景的社交网络信息表达策略. 此外, 如何同时结合时域和频域的优势用于链路预测模型的构建仍然是一个极具挑战的研究课题.

为了综合考虑社交网络时间序列的长短期趋势和空间结构, 本文提出了一种新的时频感知图卷积网络 (time-frequency-aware graph convolutional network, TFAGCN) 来对社交网络中的频域、时域和空域信息进行整合. 具体地说, 本文的 TFAGCN 框架包括 3 个模块, 即: 频率模块、时空模块和时频注意力模块. (1) 在频率模块中, 利用离散傅里叶变换 (discrete Fourier transform, DFT) 完成时频转换, 在频域中使用多层感知机 (multi-layer perceptron, MLP) 学习社交网络的全局时间依赖性, 最后通过离散傅里叶反变换 (inverse discrete Fourier transform, IDFT) 将频域表示转换回时域. (2) 时空模块则联合图卷积神经网络和门控循环单元 (gated recurrent unit, GRU) 网络捕获局部的时空依赖性. (3) 时频注意力模块设计了时频双向交叉注意力网络来整合社交网络中节点的频域特征和时域特征, 提取对节点表示有用的时频特征信息. 经过这 3 个模块, TFAGCN 有效地实现了对社交网络节点信息的学习, 对下游准确的链接预测发挥了至关重要的作用. 本文在真实数据集上进行了系统性的实验验证, 结果证实了 TFAGCN 的优越性. 综上, 本文的主要贡献可以归纳为如下 4 点.

- 提出将社交网络的频域、时域和空域信息统一融合的 TFAGCN 网络框架, 充分挖掘社交网络中蕴含的复杂结构信息, 提高链路预测的性能.
- 设计先进的时频双向交叉注意力网络, 能够自适应地融合频域特征与时域特征, 充分利用频域分析和时域分析的优势, 达到有效表达社交网络中节点信息的目的.
- 给出 TFAGCN 的简化版本, 开发了专门应对大规模社交网络的链路预测问题的图神经网络模型——时频感知 GraphSAGE (time-frequency aware GraphSAGE, TFAGS).
- 在 6 个真实社交网络数据集上进行具有借鉴意义的对比实验, 系统性地验证模型组件的有效性, 有说服力的对比结果证实了 TFAGCN 在社交网络链路预测任务上的优越性.

本文第 1 节回顾相关工作. 第 2 节介绍社交网络链路预测的定义和关于所提模型的一些初步说明. 第 3 节详细介绍所提出的 TFAGCN 算法. 第 4 节与其他最先进的算法进行比较, 在真实社交网络数据集上对所提算法进行评估. 第 5 节总结全文.

1 相关工作

本节回顾了 3 类具有代表性的链路预测方法, 即基于相似性指数的方法、基于矩阵分解的方法和基于深度学习的方法^[23].

1.1 基于相似性指数的链路预测

相似性指数是链路预测领域的经典方法, 它通过计算节点对之间的相似性指标来预测链接存在情况. 这种方法通常基于社交网络的拓扑结构来定义局部、准局部和全局相似性指数: (1) 局部相似性指数只考虑节点的直接邻居, 如 CN^[6]、Jaccard^[24]、Adamic-Adar (AA)^[25]等; (2) 准局部相似性指数是介于局部和全局之间的相似性指数, 它考虑了节点的间接邻居, 但不考虑整个网络结构, LP^[8]是一种具有代表性的准局部相似性指数; (3) 全局相似性指数考虑整个网络的拓扑结构, 它通过分析节点在整个网络中的位置以及路径链接方式来计算相似性, 其计算成本较高, 代表性算法有 Katz^[7]和 SimRank^[26]. 在此基础上, 研究人员还开发了混合相似性指数, 例如, SSBS 指数^[27]结合节点行为同步指标和相似性指数完成链路预测. Charikhi^[28]结合 PageRank 算法和局部相似性指数, 以低复杂性提高预测性能. 近年来, 以多种相似性指数为输入特征, 并借助机器学习模型预测未来链路的方法逐渐成为研究热点. 例如, NC-LGBM^[29]采用 6 种节点中心性指标作为特征, 结合 LGBM 分类器完成链路预测. Chaubey 等人^[30]融合了多种拓扑相似性指数, 运用随机森林与 XG-Boost 算法完成链路预测. Choudhury 等人^[31]自定义多种不同相似度指标, 并构建多个机器学习分类器进行比较分析.

这类方法具备结构简洁、效率较高以及可解释性良好等优势. 然而, 其性能在很大程度上依赖于人工设计的节点相似性度量, 无法考虑动态网络时序特征, 预测能力有限.

1.2 基于矩阵分解的链路预测

基于相似性指数的链路预测方法的性能受到特征设计和特征选择的限制, 需要大量的专家知识. 为了克服这些局限性, 研究人员提出了基于矩阵分解的链路预测方法. 这类方法利用矩阵分解技术对网络表示矩阵进行分解, 通过迭代优化目标函数学习节点表示, 从而预测未来链接情况. Lv 等人^[32]提出了 DAMNFG-FC 算法, 构建深度非负矩阵分解模型, 并进一步考虑社交网络局部与全局特征. Chen 等人^[33]提出了 FSSDNMF 算法, 它结合 CN 相似性指数与深度非负矩阵模型, 并加入稀疏性约束进行链路预测. DM-MFAE-G^[34]则在邻接矩阵和构建的全局连接矩阵基础上使用深度矩阵分解, 从而联合学习全局与局部特征. 类似的例子还包括 NMF-CR^[35]、LPANMF^[9]、RGNMF-AN^[10]和 EG-DNMF^[36]. 然而, 这些方法只能建模静态网络, 现实中的网络往往都是动态网络, 例如社交网络、合作网络等. 为了解决这一问题, 一些研究者在此基础上引入动态网络的时间依赖性. GrNMF^[11]和 DeepEye^[12]使用非负矩阵分解学习网络快照的嵌入, 并通过线性组合构建动态网络时序特征. Lei 等人^[13]在线性组合的基础上, 引入了带自适应参数的 AM-NMF 算法. TMF^[14]和 LIST^[15]将动态网络作为时间函数建模, 并通过矩阵分解框架学习动态嵌入. Ma 等人^[16]提出了 MjFE, 他们构建基于多标签学习项、特征提取项和时间平滑性项的目标函数,

并采用交替优化策略进行求解.

尽管这类矩阵分解方法能够有效融合动态网络中的时空信息,且模型参数较少、计算效率较高,但其难以充分捕捉动态网络复杂的非线性关系.此外,由于分解过程涉及大量矩阵运算,也容易导致数值不稳定问题.

1.3 基于深度学习的链路预测

受深度学习在计算机视觉、自然语言处理等方面取得的成就的激励,研究者开始将深度学习应用于链路预测.基于深度学习的链路预测方法主要思路是将动态网络数据借助适宜的深度学习模型转化为节点特征表示,这类方法能有效提取动态网络时空特征,从而提升预测性能.Min 等人^[37]提出了 STGSN,利用图卷积神经网络(graph convolutional network, GCN)学习空间特征,并利用注意力网络学习动态网络时序特征.Tan 等人^[38]采用 3 种数据增强策略,构建 GCN 完成多视角嵌入,进而利用图对比学习得到更具判别性的节点表示.GC-LSTM^[19]将 GCN 嵌入长短期记忆网络(long short-term memory, LSTM)中,以学习节点局部空间特征与动态网络时间特征.GCN_MA^[39]利用多种关系来增强节点表示,结合 LSTM 和 GCN 提取时空特征,并利用注意力网络提升模型表征能力.类似的例子还包括 E-LSTM-D^[40]、EvolveGCN^[41]和 DynGEM^[42].随着越来越多生成模型的开发和使用,许多研究者开始从数据生成的视角来处理动态网络链接预测.Jiao 等人^[43]提出了 TVAE 算法,它利用变分自编码器建模链路预测问题,并结合注意力网络和 LSTM 来学习动态网络时空特征.Qin 等人^[44]基于 GAN (generative adversarial network) 提出了 IDEA,并设计了基于 GCN 和 GRU 的堆叠结构提取动态图的时空特征.基于 GAN 的代表性例子还有 GCN-GAN^[45]和 NetworkGAN^[46]等.Yin 等人^[20]提出了 SRG,他们借鉴图像超分辨率重建思路,将动态网络中每个时间步的邻接矩阵视为低分辨率图,将包含邻近时间步连接信息的图视为高分辨率图,通过学习二者转换关系来提升链接预测准确性.

这些方法直接从原始数据中学习节点的表示,并通过多层非线性变换来学习动态网络的非线性特征,在链接预测任务中展现出良好的预测性能.但遗憾的是,目前工作较少从频域视角探索链路预测.频域分析已经在多个领域展示了其巨大的应用潜力^[47,48],我们试图从频域视角来提取动态网络的长期依赖关系,进一步提高社交网络链接预测的性能.

2 基础知识

2.1 问题定义

社交网络是由节点之间的关系(通常表示为边或链接)组成的网络结构,它是动态变化的,形式化表示为一个由一系列网络快照构成的集合 $G = \{G_1, G_2, \dots, G_T\}$, 其中 $G_t = (V, E_t)$ 代表第 t 个时间步的网络快照, $t \in \{1, 2, \dots, T\}$. 所有网络快照共享同一节点集 V 且每个网络快照是无向无权网络.第 t 个时间步的网络快照 G_t 包含一组节点集 V 和一组边集 E_t , 使用邻接矩阵 $A_t \in \mathbb{R}^{N \times N}$ 描述其相应的静态拓扑, 其中 N 是节点集的数量.特别地, 当第 t 个时间步中的节点 i 和节点 j 之间存在一条边, 即: $(i, j) \in E_t$, 则 $(A_t)_{i,j} = (A_t)_{j,i} = 1$; 否则 $(A_t)_{i,j} = (A_t)_{j,i} = 0$. 社交网络链路预测定义为: 给定先前观察到的 l 个网络快照 $\{G_1, G_2, \dots, G_l\}$ 预测第 $l+1$ 个时间步的网络快照 G_{l+1} ^[23]. 形式化的描述如下:

$$\hat{G}_{l+1} = f(G_1, G_2, \dots, G_l) \quad (1)$$

其中, $\hat{G}_{l+1}$ 为网络快照 G_{l+1} 的预测值, $f(\cdot)$ 为社交网络链路预测方法.

2.2 离散傅里叶变换

离散傅里叶变换(DFT)是将离散时间域信号 x 转换为离散频率域信号 X 的一种数学工具.它通常用于信号处理和频谱分析领域,可以将时域信号转换为频域表示,以便进行频谱分析、滤波等操作.给定长度为 T 的时间序列 $x = \{x_t | t = 1, 2, \dots, T\}$, 其离散傅里叶变换 $X = DFT(x)$ 定义为:

$$X_k = \sum_{t=1}^T x_t \cdot e^{-2\pi j \frac{kt}{T}}, \quad \forall 1 \leq k \leq T \quad (2)$$

其中, X_k 表示频率索引 k 对应的频谱分量, $j = \sqrt{-1}$ 是虚数单位. DFT 输出的频谱序列 X 是一个复数序列, 通常来

说, 只有 $[1, N/2+1]$ 范围内的频谱分量是有意义的. 因为频谱序列具有对称性, 负频率的信息是由正频率决定的. 需要注意的是, 离散傅里叶变换的复杂度为 $O(T^2)$, 现实中常用复杂度为 $O(T \log T)$ 的快速傅里叶变换 (fast Fourier transform, FFT) 实现高效的计算.

离散傅里叶反变换 (IDFT) 是傅里叶变换的逆运算, 用于从频域回到时域. 它将频域表示的信号转换回原始时域表示. 离散傅里叶反变换的数学表达式如下:

$$x_t = \frac{1}{T} \sum_{k=1}^T X_k \cdot e^{2\pi j \frac{kt}{T}}, \forall 1 \leq t \leq T \quad (3)$$

3 提出的 TFAGCN 算法

本节提出了框架结构如图 1 所示的 TFAGCN 算法, 它主要由 3 个模块组成. (1) 频率模块, 从频域分析的视角捕获社交网络的全局时间依赖性. (2) 时空模块, 从时域和空域的视角分别捕获社交网络的局部时间依赖性和空间依赖性. (3) 时频注意力模块, 利用注意力融合机制将频域特征和时域特征结合.




图 1 TFAGCN 的模型架构

首先, 利用 DFT 将社交网络转换到频域, 利用 FreMLP^[22] 建模动态图的全局时间依赖性, 完成频域的学习后再使用 IDFT 将频谱转换回时域. 然后, 利用 GCN 来捕获每个社交网络快照的局部拓扑特征, 并将 GCN 学习得到的综合表示输入 GRU 网络中, 以捕获动态图的局部时间依赖性. 此外, 我们设计了时频双向交叉注意力网络, 在每个时间步自适应地融合来自不同域的特征. 最后引入稀疏惩罚损失函数, 以提升链路预测准确性.

3.1 频率模块

在以往的链路预测研究中, 许多工作采用时域分析学习动态网络的时序特征^[37-42], 通过循环神经网络或注意力网络来建模时间依赖性. 然而, 这些方法在时域上逐个时间步学习时间特征, 只能看到有限的窗口, 受限于局部感受野, 难以建模长期时间依赖关系. 而频谱将社交网络时间序列信号转换为频域后, 由于它天然地反映了社交网络中任一用户所有时间步的综合信息, 从而更容易地学习到社交网络的全局时间变化模式. 在这里, 本文引入 FreMLP 模型^[22], 通过将社交网络时间序列信号转换成频谱的实部和虚部, 通过分别学习频谱实部和虚部的特定模式以捕获社交网络长期时间依赖性. 具体地说, 该过程包括两个阶段: 域变换和频率学习.

对于给定长度为 I 的社交网络快照序列 $\{G_1, G_2, \dots, G_I\}$, 其对应的邻接矩阵序列表示为 $A = \{A_1, A_2, \dots, A_I\} \in R^{I \times N \times N}$, 其中 N 是社交网络中节点的个数. 由于直接使用社交网络邻接矩阵作为特征输入会因维度极高导致样本在空间中变得稀疏, 不利于模型学习有效规律. 因此, 在域变换之前, 我们先使用非线性变换对社交网络进行降维, 用以压缩特征空间, 提升数据密度, 以较低的维度表示网络中的每一个节点. 具体转换公式如下:

$$x = \text{ReLU}(AW + b) \quad (4)$$

其中, $W \in R^{N \times D}$, $b \in R^D$ 是可学习的参数, D 是约简维数. $x \in R^{I \times N \times D}$ 表示社交网络的时域信号. 特别地, 对 x 进行了

维度重排操作, 使得 $x \in \mathbb{R}^{N \times l \times D}$. 在域变换阶段, 使用 DFT 算法将时域信号转换到频域, 表示如下:

$$X = \text{DFT}(x) \quad (5)$$

其中, $X \in \mathbb{C}^{N \times (l/2+1) \times D}$ 是频域信号.

在频率学习阶段, 构建频域 MLP 对频域信号进行处理, 具体计算公式如下:

$$Y = \text{ReLU}(XW^{\text{temp}} + b^{\text{temp}}) \quad (6)$$

其中, $W^{\text{temp}} = W_r^{\text{temp}} + jW_i^{\text{temp}} \in \mathbb{C}^{D \times D}$ 是复数权重矩阵, $b^{\text{temp}} = b_r^{\text{temp}} + jb_i^{\text{temp}} \in \mathbb{C}^D$ 是复数偏置, 且有 $W_r^{\text{temp}}, W_i^{\text{temp}} \in \mathbb{C}^{D \times D}$, $b_r^{\text{temp}}, b_i^{\text{temp}} \in \mathbb{C}^D$, $Y \in \mathbb{C}^{N \times (l/2+1) \times D}$ 是频域 MLP 的输出结果. 根据复数乘法的规则, 公式 (6) 可以进一步表示如下:

$$Y = \text{ReLU}(\text{Re}(X)W_r^{\text{temp}} - \text{Im}(X)W_i^{\text{temp}} + b_r^{\text{temp}}) + j \cdot \text{ReLU}(\text{Re}(X)W_i^{\text{temp}} + \text{Im}(X)W_r^{\text{temp}} + b_i^{\text{temp}}) \quad (7)$$

其中, $\text{Re}(\cdot)$ 表示实部, $\text{Im}(\cdot)$ 表示虚部. 根据公式 (7), 就可以通过分别计算频率分量的实部和虚部来实现频域 MLP. 在完成频域特征的学习后, 使用 IDFT 算法将频域信号转换回时域, 表示如下:

$$\tilde{x} = \text{IDFT}(Y) \quad (8)$$

其中, $\tilde{x} \in \mathbb{R}^{l \times N \times D}$ 表示频域特征. 为了提高模型的训练速度和泛化能力, 在该模块中添加了残差连接, 即:

$$\mathcal{X}^{\text{fre}} = \tilde{x} + x \quad (9)$$

其中, $\mathcal{X}^{\text{fre}} \in \mathbb{R}^{l \times N \times D}$ 是该模块最终输出的频域特征.

3.2 时空模块

为了捕获社交网络的局部网络结构信息和局部时间信息, 本文联合图卷积网络和 GRU 来模拟不同时间步长的空间属性和时间属性, 以更好地学习动态社交网络中节点的嵌入向量表示. 具体来说, 对每个时间步的图快照使用图卷积操作学习社交网络的空间结构; 对相邻时间步的快照使用 GRU 学习短期的社交网络演化模式.

考虑到社交网络中用户的属性往往是难以获取的, 受注意力机制中的位置编码的启发^[49], 本文使用位置编码作为区分社交网络中不同节点的特征. 本文定义社交网络中第 i 个节点的特征 pos_emb_i 如下:

$$\begin{cases} \text{pos_emb}_{i,2k} = \sin(i/10000^{2k/D_p}) \\ \text{pos_emb}_{i,2k+1} = \cos(i/10000^{2k/D_p}) \end{cases} \quad (10)$$

其中, $1 \leq i \leq N$, D_p 是位置嵌入的维度, $2k < D_p$, $k \geq 0$ 且 k 为整数. 特别地, 社交网络中所有节点的特征可以简洁地表示为 $\text{pos_emb} \in \mathbb{R}^{N \times D_p}$.

社交网络常用图结构来表示和分析, GCN 能够有效地处理这种非欧几里得数据, 通过学习节点之间的复杂关系和特征来实现各种任务. 因此, 我们利用 GCN 来捕获节点之间的隐藏特征和相互作用模式. 具体来说, 对每个图快照 A_t ($1 \leq t \leq l$), 利用特征矩阵 pos_emb 进行图卷积的操作如下所示:

$$x_t^G = \text{ReLU}(\hat{D}^{-1/2} \hat{A}_t \hat{D}^{-1/2} \cdot \text{pos_emb} \cdot W_G) \quad (11)$$

其中, $\hat{A}_t = A_t + I$, I 是单位矩阵, $\hat{D}$ 是 $\hat{A}_t$ 的度矩阵, $W_G \in \mathbb{R}^{D_p \times D_G}$ 是可学习的权重参数. $x_t^G \in \mathbb{R}^{N \times D_G}$ 表示图快照的空间结构特征. 此外, 本文将每个图快照 A_t 经过 GCN 单元的输出 x_t^G 作为 GRU 单元的输入信息, 以模拟现实中社交网络结构随时间演化的情况. 该过程用公式表示如下:

$$z_t = \sigma([h_{t-1}, x_t^G] \cdot W_z + b_z) \quad (12)$$

$$r_t = \sigma([h_{t-1}, x_t^G] \cdot W_r + b_r) \quad (13)$$

$$\tilde{h}_t = \tanh([r_t * h_{t-1}, x_t^G] \cdot W_h + b_h) \quad (14)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (15)$$

其中, $z_t \in \mathbb{R}^{N \times f}$ 和 $r_t \in \mathbb{R}^{N \times f}$ 分别表示更新门和重置门, $h_{t-1} \in \mathbb{R}^{N \times f}$ 是第 $t-1$ 个时间步的隐藏状态, $\tilde{h}_t \in \mathbb{R}^{N \times f}$ 是第 t 个时间步的候选隐藏状态, $h_t \in \mathbb{R}^{N \times f}$ 是第 t 个时间步的隐藏状态, $W_z, W_r, W_h \in \mathbb{R}^{(f+D_G) \times f}$ 和 $b_z, b_r, b_h \in \mathbb{R}^f$ 是可学习的参数, $\sigma(\cdot)$ 为 Sigmoid 激活函数, $*$ 表示逐元素乘法. 值得注意的是, 所有图快照共享同一 GCN 单元和 GRU 单元, 以减少模型的参数量.

3.3 时频注意力模块

为有效融合频域与时域特征, 即长期和短期演化趋势, 本文提出时频双向交叉注意力网络 (time-frequency bidirectional cross-attention network, TF-att), 用于学习社交网络中节点的动态表示. 图 2 展示了 TF-att 的网络结构. 从中可以观察到, TF-att 首先将频域特征作为时域注意力神经网络中的查询, 通过交叉注意力机制从时域特征中提取出有用的时域信息. 类似地, TF-att 将时域特征作为频域注意力神经网络中的查询, 从频域特征中提取出有用的频域信息. 最后, 将注意力网络提取出的时域信息和频域信息进行求和并作为最终的隐藏状态传递到下一个 GRU 单元.




图 2 TF-att 网络示意图

给定社交网络中的频域特征 $\mathcal{X}^{\text{fre}} \in \mathbb{R}^{l \times N \times D}$ 和时域特征 $h_t \in \mathbb{R}^{N \times f}$ ($1 \leq t \leq l$), 在构建时域注意力神经网络时, 对时域特征 h_t 进行线性变换, 得到 K^t 和 V^t . 在此基础上, 对相应时间步的频域特征 $\mathcal{X}_t^{\text{fre}}$ 进行线性变换, 得到 Q^t . 计算如公式 (16) 所示:

$$\begin{cases} Q^t = \mathcal{X}_t^{\text{fre}} \cdot W^{Q^t} \\ [K^t, V^t] = h_t [W^{K^t}, W^{V^t}] \end{cases} \quad (16)$$

其中, $Q^t, K^t, V^t \in \mathbb{R}^{N \times d}$ 分别是时域注意力神经网络的查询、键和值, $W^{Q^t} \in \mathbb{R}^{D \times d}$ 和 $W^{K^t}, W^{V^t} \in \mathbb{R}^{f \times d}$ 是可学习的权重参数. 类似地, 构建频域注意力神经网络时, 对频域特征 $\mathcal{X}_t^{\text{fre}}$ 进行线性变换, 得到 K^f, V^f ; 对相应时间步的时域特征 h_t 进行线性变换, 得到 Q^f , 该过程表示如下:

$$\begin{cases} Q^f = h_t \cdot W^{Q^f} \\ [K^f, V^f] = \mathcal{X}_t^{\text{fre}} \cdot [W^{K^f}, W^{V^f}] \end{cases} \quad (17)$$

其中, $Q^f, K^f, V^f \in \mathbb{R}^{N \times d}$ 分别是频域注意力神经网络的查询、键和值, $W^{Q^f} \in \mathbb{R}^{f \times d}$ 和 $W^{K^f}, W^{V^f} \in \mathbb{R}^{D \times d}$ 是可学习的权重参数.

随后, 通过交叉注意力机制分别计算时域信息和频域信息的上下文表示, 计算过程如下所示:

$$\begin{cases} \text{att}(Q^t, K^t, V^t) = \text{Softmax}(Q^t (K^t)^T / \sqrt{d}) V^t \\ \text{att}(Q^f, K^f, V^f) = \text{Softmax}(Q^f (K^f)^T / \sqrt{d}) V^f \end{cases} \quad (18)$$

其中, $\text{att}(Q^t, K^t, V^t) \in \mathbb{R}^{N \times d}$ 和 $\text{att}(Q^f, K^f, V^f) \in \mathbb{R}^{N \times d}$ 分别表示时域注意力神经网络和频域注意力神经网络的输出. 然后将它们进行相加得到社交网络的时频特征并作为当前时间步的最终隐藏状态 h_t , 计算如下所示:

$$h_t = \text{att}(Q^t, K^t, V^t) \oplus \text{att}(Q^f, K^f, V^f) \quad (19)$$

其中, $h_t \in \mathbb{R}^{N \times d}$, $\oplus$ 表示逐元素相加.

最后, 将最后一个隐藏状态 $h_l \in \mathbb{R}^{N \times d}$ 作为社交网络的最终节点表示, 并将其输入到全连接层中以生成预测结果 $\hat{A}_{l+1}$, 具体如下所示:

$$\hat{A}_{l+1} = \text{MLP}(h_l) \quad (20)$$

其中, $\hat{A}_{l+1} \in \mathbb{R}^{N \times N}$ 表示第 $l+1$ 个时间步预测的邻接矩阵. 特别地, 除输出层采用 Sigmoid 激活函数外, 其余层均使用 ReLU 激活函数.

3.4 模型的训练

在现实世界的社交网络中,网络结构通常呈现出稀疏特性.由于网络中实际存在的边远少于所有可能的连接,导致整体连接密度较低.这种稀疏性容易使模型训练过程被大量负样本(即不存在链接的节点对)所主导,从而削弱对正样本(即真实存在的链接)的学习效果,导致模型倾向于将所有预测结果判定为无链接关系.为缓解该问题,在模型训练中需通过损失函数的设计对稀疏性加以考虑.为此,本文引入损失函数 $\mathcal{L}^{[40]}$,具体形式如下所示:

$$\mathcal{L} = \left\| P * (\hat{A}_{l+1} - A_{l+1}) \right\|_F^2 \quad (21)$$

其中, A_{l+1} 是第 $l+1$ 个时间步真实社交网络图快照 G_{l+1} 的邻接矩阵,*表示逐元素乘法, P 是惩罚矩阵,具体表示如下:

$$P = \begin{cases} \beta, & (A_{l+1})_{i,j} > 0 \\ 1, & (A_{l+1})_{i,j} = 0 \end{cases} \quad (22)$$

其中, $\beta > 1$ 为惩罚系数,通过对非零元素施加更强的约束以应对社交网络的稀疏性问题.算法1提供了本文模型的伪代码.

算法 1. TFAGCN 算法.

输入: 社交网络图快照序列 $G = \{G_1, G_2, \dots, G_l\}$ 和未来社交网络图快照 G_{l+1} ;

输出: 社交网络目标图快照 $\hat{G}_{l+1}$.

1. /* 训练 TFAGCN 模型 */
 2. 基于公式 (4)–(6) 和公式 (8) 完成频域学习
 3. 使用公式 (9) 的残差连接生成频域特征 $\mathcal{X}^{\text{fre}}$
 4. 基于位置编码生成社交网络中节点的特征
 5. **for** l steps **do**
 6. 使用 GCN 单元来捕获节点空域特征 x_l^G
 7. 使用 GRU 单元从捕获节点的时域特征 h_l
 8. 基于时频双向交叉注意力网络更新 GRU 单元隐藏状态, 即: $h_l = \text{TF-att}(h_l, \mathcal{X}_l^{\text{fre}})$
 9. 使用公式 (20) 的全连接层预测目标邻接矩阵, 即: $\hat{A}_{l+1} = \text{MLP}(h_l)$
 10. 使用公式 (21) 的稀疏惩罚损失函数迭代更新模型的参数
 11. /* 通过 TFAGCN 模型预测 */
 12. 基于频率模块捕获图快照序列 $G = \{G_1, G_2, \dots, G_l\}$ 的频域特征
 13. 基于时空模块捕获社交网络的时空特征
 14. 从时频注意力模块中构建时频特征
 15. 使用公式 (20) 完成推理过程, 从 h_l 生成 $\hat{G}_{l+1}$
-

3.5 针对大型图的 TFAGS

当前的链路预测模型已经具备了良好的推理能力,然而,由于其较高的计算复杂度,它难以应用于大型图数据.具体来说,在社交网络链路预测领域,由于现有方法都是在整个图快照上进行训练与预测,模型的理论时间复杂度至少是关于节点数的平方级别,甚至更高.下面将对前文所提到的3类链路预测方法的时间复杂度进行简要分析.

(1) 基于相似性指数的方法: 这些方法以节点对之间的相似性指数或中心性指标作为特征进行后续的预测.在实现计算过程中,需要2层循环来计算节点对之间的相似性指数,涉及 $N(N-1)/2$ 次循环,其中 N 表示网络节点数.因此,这类方法的时间复杂度是 $O(N^2)$.

(2) 基于矩阵分解的方法: 这些方法通过构建目标函数学习社交网络节点的低维表示,在构建目标函数时,涉及的目标函数可以简洁地表示为 $\min \|A - WH\|_F^2$,其中 $A \in \mathbb{R}^{N \times N}$ 是社交网络的邻接矩阵, $W \in \mathbb{R}^{N \times d}$ 和 $H \in \mathbb{R}^{d \times N}$ 分别是系数矩阵与基矩阵.系数矩阵表示的是网络节点的低维嵌入, d 是嵌入维度.不同的矩阵分解方法在优化目标函

数时, 通常会考虑额外的因素, 从而构建更加复杂的目标函数. 从上述提及的最基础的目标函数出发, 因为 WH 的计算复杂度是 $O(dN^2)$, 所以这类方法的时间复杂度是 $O(N^2)$.

(3) 基于深度学习的方法: 深度学习模型通过学习图快照序列获得节点的低维嵌入, 即将社交网络的邻接矩阵 $A \in R^{N \times N}$ 转化为图嵌入表示 $X \in R^{N \times D}$, 该过程涉及邻接矩阵与权重矩阵进行乘法, 该权重参数矩阵可表示为 $W \in R^{N \times D}$, AW 的计算复杂度是 $O(DN^2)$, 因此, 这类方法的时间复杂度同样是 $O(N^2)$.

通过上述分析, 可知 3 类链路预测方法的理论时间复杂度至少是 $O(N^2)$, 这也是在大型社交网络数据集上进行实验容易结果产生内存溢出问题的原因. 在此, 我们将在 TFAGCN 的基础上, 对其从 4 个方面进行改进, 构建出 TFAGS 模型, 将其应用到对大型图数据的处理中, 具体操作如下.

(1) 随机映射代替全连接网络完成社交网络图快照初步嵌入. 为了以较低的维度表示社交网络中的每一个节点, 公式 (4) 采用 MLP 对社交网络进行非线性变换, 但该操作会产生平方级别 (时间复杂度为 $O(N^2)$) 的运算. 针对大规模图数据, 我们引入高斯随机投影进行初步嵌入, 这是一种有效的降维技术, 可以从理论上最大限度地保留原始特征的性质. 虽然这会损失部分非线性表达能力, 但显著降低了计算复杂度且无需参数学习^[50]. 这里的关键是以低复杂度完成社交网络节点的低维嵌入, 更细致的节点表示学习将由后续模块完成. 可将公式 (4) 改写为:

$$x = \text{ReLU}(AW_{\text{rand}} + b) \quad (23)$$

其中, $A \in R^{l \times N \times N}$ 是时间跨度为 l 的社交网络快照序列, $W_{\text{rand}} \in R^{N \times D}$ 是随机映射矩阵, D 是节点嵌入维数, $x \in R^{l \times N \times D}$ 是社交网络的节点表示.

(2) 使用 GraphSAGE^[51] 代替 GCN 完成空间特征的学习. 相比于对整个图快照进行学习的 GCN, GraphSAGE 对每个节点采样一定数量的邻接节点, 然后把每个节点和它们的邻居拼接在一起进行批训练, 更适用于大规模的图数据, 从而避免大型图数据计算时产生的内存溢出问题. 具体来说, 对每个图快照 A_t ($1 \leq t \leq l$), 利用节点特征 pos_emb 进行图卷积的操作如下所示:

$$x_t^G = \text{SAGEConv}(A_t, pos_emb) \quad (24)$$

其中, $x_t^G \in R^{N \times D_G}$ 表示图快照的空间结构特征.

(3) 使用全连接网络代替时频双向交叉注意力网络完成不同域特征融合. 注意力机制具有平方级的计算复杂度, 虽然目前已经有降低其复杂度的技术, 例如稀疏注意力等, 但这些技术的复杂度仍较高. 采用简单高效的全连接网络是一种更明智的选择. 因此, 公式 (19) 改写如下:

$$h_t' = FC([\mathcal{X}_t^{\text{fre}}, h_t]) \quad (25)$$

其中, $\mathcal{X}_t^{\text{fre}}$ 是社交网络中的频域特征, h_t 是时域特征, h_t' 是融合后的时频特征.

(4) 在模型的训练与推断过程中, 使用均匀随机采样技术构建负样本, 并与所有的正样本组合进行训练与推断. 对于大型图而言, 对所有正、负样本进行学习与预测计算开销巨大, 时间复杂度是 $O(N^2)$. 于是, 可以通过采样得到均匀的正负样本, 从而在子图上进行训练学习. 此时, 由于正负样本的平衡, TFAGS 不再使用稀疏惩罚损失函数进行训练, 而是使用二元交叉熵损失函数, 公式 (21) 改写如下:

$$L = \text{BCE}(\hat{a}_{l+1} - a_{l+1}) \quad (26)$$

其中, a_{l+1} 是第 $l+1$ 个时间步真实社交网络的链接子集, $\hat{a}_{l+1}$ 是预测的链接子集.

至此, 完成了对 TFAGS 模型的构建, 算法 2 清晰地展示了该算法的执行过程.

算法 2. TFAGS 算法.

输入: 社交网络快照序列 $G^l = \{G_1^l, G_2^l, \dots, G_l^l\}$ 和未来边集合 $\varepsilon_{l+1} = \{(u, v, label)\}$;

输出: 社交网络目标边集合 $\varepsilon_{\text{total}} = \{(u, v, label) \mid (u, v) \in V \times V, u \neq v\}$.

1. /* 训练 TFAGS 模型 */

2. 基于公式 (23) 完成对社交网络的随机映射降维

3. 使用公式 (6) 和公式 (8) 完成频域学习得到时间特征
4. 使用公式 (9) 的残差连接生成频域特征 $\mathcal{X}^{\text{fe}}$
5. **for** l steps **do**
6. 使用 GraphSAGE 单元来捕获节点的空域特征 x_l^G
7. 使用 GRU 单元来捕获节点的时域特征
8. 基于全连接网络更新 GRU 单元的隐藏状态 h_l
9. 使用点积计算节点对的连接强度
10. 使用公式 (26) 的二元交叉熵损失函数迭代更新模型的参数
11. /* 通过 TFAGS 模型预测 */
12. 基于频率模块捕获图快照序列 $G = \{G_1, G_2, \dots, G_l\}$ 的频域特征
13. 基于时空模块捕获社交网络的时空特征
14. 从时频注意力模块中构建时频特征
15. 使用点积完成推理过程, 从 h_l 生成 $\varepsilon_{\text{total}}$

3.6 时间复杂度分析

首先分析 TFAGCN 训练过程的时间复杂度. 其主要依赖对频率模块、时空模块和时频注意力模块这 3 部分的计算. (1) 在频率模块中, 主要计算的是公式 (4) 和公式 (6), 相应的计算复杂度分别为 $O(N^2 l D)$ 和 $O(N(l/2 + 1)D^2)$, 其中 N 是社交网络节点数, l 是社交网络图快照序列的长度, D 是约简维数. (2) 在时空模块中, 该模块的计算复杂度由 GCN 和 GRU 组成, GCN 部分的计算复杂度为 $O(N^2 l D_p + N l D_p D_G)$, D_p 是位置嵌入的维度, D_G 是 GCN 输出特征的维度. GRU 部分的计算复杂度为 $O(N l (f + D_G) f)$, f 是隐藏状态的维度. (3) 在时频注意力模块中, 主要计算的是公式 (18), 计算复杂度为 $O(N^2 d)$, 其中 d 是时频双向交叉注意力网络的输出维度. 由于社交网络节点数 N 总是大于其他参数, 因此, TFAGCN 的整体时间复杂度为 $O(N^2)$.

在 TFAGS 模型中, 主要的计算量集中在 GraphSAGE、GRU 和预测阶段. (1) 在 GraphSAGE 中使用均值聚合, 该部分计算复杂度为 $O(B N_e D_p D_G)$, B 是批训练次数, N_e 是批数据节点集大小. (2) GRU 计算复杂度为 $O(N l (f + D_G) f)$. (3) 预测阶段的复杂度主要集中在对所有正负样本点积的计算上, 为 $O(2 d M)$, 其中 d 是融合后时频特征的维数, M 均匀随机采样的样本数. 由于社交网络节点数 N 和采样样本数 M 总是大于其他参数, 因此, TFAGS 的整体复杂度可简洁地表示为 $O(\max(N, M))$. 可见, TFAGS 模型的计算开销远小于 TFAGCN 模型, 理论上具备了处理大规模社交网络链路预测问题的能力, 其性能将通过下文的实验得到进一步的证实.

4 实验验证与结果分析

4.1 数据集

本文在 6 个公开数据集^[52-54]上进行实验验证, 包括 Huggle、LH10、InVS13、Email、Enron 和 wiki, 其中 Huggle 是以无线设备记录的人际接触关系网络; LH10 是采集自医院的人员接触关系网络; InVS13 记录了现实世界中人员的互动关系; Email 是欧洲一家大型研究机构的电子邮件数据; Enron 由安然公司的员工之间发送的电子邮件组成; wiki 是维基百科用户编辑彼此的讨论页组成的时间网络. 所有数据集均按 7:1:2 的比例划分为训练集、验证集和测试集, 其详细统计信息见后文表 1.

4.2 实验设置

本文采用 AUC、Recall 和 MR^[45]这 3 种通用指标评估链路预测模型. 其中, AUC 衡量整体预测准确率, Recall 反映对正样本的识别能力, 二者值越大性能越优; MR 则代表预测错误的比例, 其值越小越好. 为全面对比, 我们选取了以下 3 类方法的代表性工作: 在基于相似性指数的方法中, 包括混合指标 PR-CN^[28]以及将相似性指数作为分

类器特征的 NC-LGBM^[29]; 在基于矩阵分解的方法中, 涵盖了面向静态图的 LPANMF^[9] 与动态图的 MljFE^[16]; 在基于深度学习的方法中, 则选取了用于时空特征提取的 GC-LSTM^[19] 与 GCN_MA^[39], 以及基于图像生成视角的 SRG 算法^[20].

表 1 数据集的统计信息

数据集	节点数	链接总数	快照数量
Haggle	274	28 244	70
LH10	687	150 126	71
InVS13	973	394 247	114
Email	1 005	332 334	75
Enron	87 273	1 148 072	28
wiki	1 140 149	7 833 140	26

所有实验均在配备了 NVIDIA V100 32 GB 的 GPU 和 10 vCPU 的 Intel Xeon 工作站上进行. 实验使用 10 个历史时间步作为网络图快照的序列长度, 并报告 5 次随机实验的平均结果. 对于静态图链路预测模型, 其输入为最后一个时间步的图快照. 所有基线模型的超参数均遵循其原论文中的最优配置. 针对本文模型 TFAGCN, 约简维度、GCN 输出特征维度、GRU 隐藏状态维度及注意力网络输出维度均设置为 32; 位置嵌入维度为 16; 预测模块采用两层结构, 除输出层维度等于节点数外, 其余隐藏层维度均为 64. 优化方面, 使用 Adam 优化器, 学习率设为 0.0005, 损失函数中的惩罚系数设为 2. 本节所有实验均在 PyTorch 2.0.0 框架下完成.

4.3 对比实验分析

本节在 4 个社交网络数据集上, 将 TFAGCN 模型与现有基准方法在 AUC、MR 和 Recall 这 3 项指标上进行了全面对比. 表 2 报告了实验结果, 其中加粗部分表示最优结果 (下同). 总的来说, 提出的 TFAGCN 基本上在所有数据集上获得了最优的性能表现. 特别地, 虽然在 LH10 数据集上, 该模型的 MR 表现比基线 GC-LSTM 稍弱, 但就平均性能而言, TFAGCN 优于 GC-LSTM.

表 2 TFAGCN 与其他基线算法在小规模社交网络上的对比实验结果

方法	Haggle			LH10			InVS13			Email		
	AUC	MR	Recall	AUC	MR	Recall	AUC	MR	Recall	AUC	MR	Recall
PR-CN	0.864	0.107	0.791	0.806	0.091	0.691	0.891	0.054	0.805	0.825	0.120	0.715
NC-LGBM	0.851	0.124	0.814	0.810	0.261	0.876	0.859	0.126	0.833	0.772	0.088	0.615
LPANMF	0.867	0.105	0.824	0.853	0.092	0.770	0.836	0.090	0.789	0.673	0.152	0.523
MljFE	0.804	0.283	0.734	0.896	0.112	0.821	0.851	0.027	0.715	0.682	0.157	0.452
GC-LSTM	0.902	0.043	0.826	0.896	0.107	0.824	0.902	0.025	0.820	0.795	0.090	0.641
SRG	0.887	0.062	0.802	0.831	0.083	0.719	0.857	0.006	0.718	0.887	0.109	0.818
GCN_MA	0.887	0.072	0.824	0.911	0.091	0.854	0.927	0.076	0.904	0.832	0.183	0.781
TFAGCN	0.924	0.050	0.871	0.940	0.081	0.898	0.976	0.005	0.955	0.900	0.087	0.836

与基于相似性指数的方法相比, TFAGCN 在 AUC 和 Recall 上分别平均提升了 10.0% 和 12.2%, 在 MR 上平均降低了 6.5%. 预测性能的显著提升源于模型架构的不同, 尽管 PR-CN 和 NC-LGBM 算法综合了多种相似性指数, 但其本质仍依赖于人工设计的线性或浅层特征, 难以充分刻画真实社交网络中动态演化带来的复杂非线性特性. 相比之下, TFAGCN 摒弃了人工特征工程, 利用深度学习模型自适应地从数据中学习并捕获其内在的时空动态模式.

与基于矩阵分解的方法相比, TFAGCN 在 AUC、MR 和 Recall 上平均取得了 12.7%、7.1% 和 18.6% 的性能提升. LPANMF 只考虑了社交网络的稀疏性和空间结构, 然而, 社交网络存在明显的时间依赖关系, 这导致其预测性能相对较差. 此外, MljFE 虽考虑动态性, 但简单的矩阵分解还是难以适应动态社交网络的复杂非线性特性. TFAGCN 基于数据驱动的方式学习社交网络的节点表示, 因此可以捕获社交网络的复杂时空关系. 在 4 个数据集上, TFAGCN 的预测效果均优于这类方法, 特别是在 AUC 上的表现.

与基于深度学习的方法相比, TFAGCN 取得了更加优秀的预测性能. 尽管 GC-LSTM、SRG 和 GCN_MA 模

型已展现出深度学习模型处理非线性问题的优势,但它们各自存在局限: GC-LSTM 因依赖 LSTM 而难以捕捉长期时间依赖; SRG 虽精心设计了学习图快照序列信息传输模式的 DGFlow 模块,却缺乏对空间依赖关系的建模; GCN_MA 融合了社交网络的时空特征,但未能建模频域信息,且未考虑网络稀疏性. 与此不同, TFAGCN 同时考虑了频谱、空间和时间信息,并结合稀疏惩罚损失考虑网络的稀疏性,使模型能够全面捕获社交网络中有价值的信息,这使得本文的模型预测性能比基线模型表现更好.

对于大规模的社交网络数据 Enron、wiki, 由于上述方法都是在整个图上进行训练与推理, 会出现内存不足的问题. 考虑到 TFAGS 的子图学习特性, 此处选取同样可以对子图进行训练和推断的 DynamicTriad^[55]、DySAT^[18]和 TF-GCL^[38]作为对比方法. 由于不是对整个图进行推理, MR 指标不再适用, 这里使用 AUC 和 Recall 进行评估. 实验结果如表 3 所示, 其中 N/A 表示计算时间过长, 无法获取结果.

表 3 TFAGS 与其他基线算法在大规模社交网络上的对比实验结果

方法	Enron		wiki	
	AUC	Recall	AUC	Recall
DynamicTriad	0.826	0.888	N/A	N/A
DySAT	0.852	0.893	N/A	N/A
TF-GCL	0.822	0.876	0.843	0.885
TFAGS	0.870	0.926	0.915	0.954

总的来说, TFAGS 在 AUC 和 Recall 两个指标上都是优于其他模型的. 特别在 wiki 中, DynamicTriad、DySAT 因数据量过大而不适用, 而 TFAGS 仍表现优异. 在 Enron 中, TF-GCL 比其他方法更差, 这是因为 TF-GCL 仅简单地通过时间衰减函数来标记数据的时间特征, 无法自适应地从数据中提取出社交网络的时间特征. DynamicTriad 使用时间平滑项捕获时间特征, 预测性能不如基于时间注意力的 DySAT. 相比于 DySAT, TFAGS 不仅能够学习社交网络的时空特征, 还加入了频域信息, 节点表示更加全面. 此外, 优化改进的 TFAGS, 其时间复杂度也低于基于注意力机制的 DySAT.

4.4 消融实验

本节在 4 个真实的数据集上进行了消融实验用以分析 TFAGCN 不同子模块的贡献. 此处研究了不同配置下的算法预测性能. (1) 删除频率模块的 TFAGCN (记作 w/o FreMLP), 研究频域特征对链接预测的重要性. (2) 移除 GCN 的 TFAGCN (记作 w/o GCN), 研究社交网络空间结构对预测性能的影响. (3) 使用全连接网络取代 TF-att 网络 (记作 w/o TF-att), 测试时频注意力模块是否有利于链路预测任务. 虽然这些变体删除或替换了一些子模块, 但其余模块的参数设置与实验设置保持一致.

消融实验的结果如表 4 所示, 所有变体模型的表现都不如 TFAGCN, 实验证明了 TFAGCN 各个子模块在模型中的重要性. 从结果中可以观察到, w/o FreMLP 预测性能比 TFAGCN 要差. 这表明频谱特征对模型链路预测性能有一定贡献, 这是因为频谱特征有效地捕获了社交网络的全局时间依赖. 相比原始模型, w/o GCN 在 AUC、MR 和 Recall 上的预测性能平均下降了 1.6%、3.0% 和 2.0%. 原因是 w/o GCN 中没有考虑社交网络中的空间结构信息, 导致预测性能不理想. 本文引入了一个全连接网络来融合来自时域与频域的特征, 即 w/o TF-att. 然而, 它的性能也要比 TFAGCN 差, 这说明了 TF-att 的重要性, 这种时域特征和频域特征的自适应融合机制明显优于简单的全连接输出.

表 4 针对 TFAGCN 的消融实验结果

方法	Haggle			LH10			InVS13			Email		
	AUC	MR	Recall	AUC	MR	Recall	AUC	MR	Recall	AUC	MR	Recall
w/o FreMLP	0.907	0.066	0.848	0.923	0.086	0.873	0.964	0.006	0.932	0.873	0.096	0.790
w/o GCN	0.893	0.144	0.852	0.919	0.105	0.864	0.962	0.006	0.927	0.899	0.088	0.835
w/o TF-att	0.892	0.085	0.818	0.889	0.133	0.884	0.968	0.005	0.940	0.830	0.323	0.832
TFAGCN	0.924	0.050	0.871	0.940	0.081	0.898	0.976	0.005	0.955	0.900	0.087	0.836

4.5 案例研究

本节利用真实社交网络数据集 MalPilot2^[56]作为案例生动地展示了新模型的链接预测能力. MalPilot2 是一个关于马拉维村庄中社区之间联系的数据集, 它记录了马拉维村庄社区之间的不同类型的联系, 包括社交关系、经济交流、资源共享等. 在这里, 将 MalPilot2 数据集按照 7:3 的比例划分成训练集和测试集, 并从测试集中随机选择预测结果用热图进行可视化. 本节将不同方法生成的邻接矩阵与基真值 (Ground-truth) 进行了比较, 结果展示在图 3 中. 直观地说, TFAGCN 可以预测出与基真值相似的邻接矩阵. PR-CN 和 NC-LGBM 的预测结果过于稠密, 与真实结果相差较大. 基于矩阵分解的 LPANMF 和 MljFE 预测结果有所改进, 但与真实结果仍有差距. SRG、GCN_MA 等基于深度学习的模型预测结果令人满意, 然而, 这些方法仍不如 TFAGCN. 相比之下, 本文的方法通过提取全面的社交网络链路特征有效地生成了高质量的预测结果.




图3 MalPilot2 的一个图快照的 Ground-truth 以及不同算法的预测结果

5 总结

为了更好地利用图快照序列的时频特性, 本文提出了一种新的能够将频域、时域和空域信息统一融合的 TFAGCN 网络框架, 用于处理社交网络的链路预测问题. TFAGCN 引入了频域 MLP 提取反映社交网络全局时间依赖关系的频率特征, 并联合 GCN 和 GRU 捕获社交网络的局部时空依赖关系. 另外, 设计了时频双向交叉注意力网络来构建社交网络的时频特征, 更加有效地利用了不同域特征之间的互补性. 此外, 针对大规模社交网络的链路预测问题, 针对性地设计了 TFAGCN 的简化版本 TFAGS. 在 6 个真实的数据集上, 执行了消融实验验证 TFAGCN

中重要子模块的有效性, 并与先进的链路预测模型进行了性能对比, 证实了 TFAGCN 的高效性. 由于社交网络中的节点和链接并不是静态的, 而是随着时间的推移发生动态变化的, 在未来工作中, 将在 TFAGCN 的基础上进一步考虑社交网络中的节点数动态变化的情形, 以求更好地模型化社交网络的实际演变过程, 如在每个图快照之间构建一个节点数对齐网络来对不同时间步之间节点的增加或删除进行建模. 同时, 积极挖掘新算法在实际应用中的潜能, 如敏感链接隐私保护^[57]和用户行为轨迹追踪^[58].

References

- [1] He YL, Lai JL, Cui LZ, Huang ZX, Yin JF. Multi-evolutionary features based link prediction algorithm for social network. *Pattern Recognition and Artificial Intelligence*, 2024, 37(7): 597–612 (in Chinese with English abstract). [doi: [10.16451/j.cnki.issn1003-6059.202407003](https://doi.org/10.16451/j.cnki.issn1003-6059.202407003)]
- [2] Zhu HR, Xiong F, Chen HS, Xiong X, Wang L. Incorporating a triple graph neural network with multiple implicit feedback for social recommendation. *ACM Trans. on the Web*, 2024, 18(2): 23. [doi: [10.1145/3580517](https://doi.org/10.1145/3580517)]
- [3] Vital A, Amancio DR. A comparative analysis of local similarity metrics and machine learning approaches: Application to link prediction in author citation networks. *Scientometrics*, 2022, 127(10): 6011–6028. [doi: [10.1007/s11192-022-04484-6](https://doi.org/10.1007/s11192-022-04484-6)]
- [4] Orzechowski KP, Mrowinski MJ, Fronczak A, Fronczak P. Asymmetry of social interactions and its role in link predictability: The case of coauthorship networks. *Journal of Informetrics*, 2023, 17(2): 101405. [doi: [10.1016/j.joi.2023.101405](https://doi.org/10.1016/j.joi.2023.101405)]
- [5] Ma ZM, Nandy S. Community detection with contextual multilayer networks. *IEEE Trans. on Information Theory*, 2023, 69(5): 3203–3239. [doi: [10.1109/TIT.2023.3238352](https://doi.org/10.1109/TIT.2023.3238352)]
- [6] Newman MEJ. Clustering and preferential attachment in growing networks. *Physical Review E*, 2001, 64(2): 025102. [doi: [10.1103/PhysRevE.64.025102](https://doi.org/10.1103/PhysRevE.64.025102)]
- [7] Katz L. A new status index derived from sociometric analysis. *Psychometrika*, 1953, 18(1): 39–43. [doi: [10.1007/BF02289026](https://doi.org/10.1007/BF02289026)]
- [8] Lü LY, Jin CH, Zhou T. Similarity index based on local paths for link prediction of complex networks. *Physical Review E*, 2009, 80(4): 046122. [doi: [10.1103/PhysRevE.80.046122](https://doi.org/10.1103/PhysRevE.80.046122)]
- [9] Mahmoodi R, Seyedi SA, Tab FA, Abdollahpouri A. Link prediction by adversarial nonnegative matrix factorization. *Knowledge-based Systems*, 2023, 280: 110998. [doi: [10.1016/j.knsys.2023.110998](https://doi.org/10.1016/j.knsys.2023.110998)]
- [10] Nasiri E, Berahmand K, Li YF. Robust graph regularization nonnegative matrix factorization for link prediction in attributed networks. *Multimedia Tools and Applications*, 2023, 82(3): 3745–3768. [doi: [10.1007/s11042-022-12943-8](https://doi.org/10.1007/s11042-022-12943-8)]
- [11] Ma XK, Sun PG, Wang Y. Graph regularized nonnegative matrix factorization for temporal link prediction in dynamic networks. *Physica A: Statistical Mechanics and its Applications*, 2018, 496: 121–136. [doi: [10.1016/j.physa.2017.12.092](https://doi.org/10.1016/j.physa.2017.12.092)]
- [12] Ahmed NM, Chen L, Wang YL, Li B, Li Y, Liu W. DeepEye: Link prediction in dynamic networks based on non-negative matrix factorization. *Big Data Mining and Analytics*, 2018, 1(1): 19–33. [doi: [10.26599/BDMA.2017.9020002](https://doi.org/10.26599/BDMA.2017.9020002)]
- [13] Lei K, Qin M, Bai B, Zhang G. Adaptive multiple non-negative matrix factorization for temporal link prediction in dynamic networks. In: *Proc. of the 2018 Workshop on Network Meets AI & ML*. Budapest: ACM, 2018. 28–34. [doi: [10.1145/3229543.3229546](https://doi.org/10.1145/3229543.3229546)]
- [14] Yu WC, Aggarwal CC, Wang W. Temporally factorized network modeling for evolutionary network analysis. In: *Proc. of the 10th ACM Int'l Conf. on Web Search and Data Mining*. Cambridge: ACM, 2017. 455–464. [doi: [10.1145/3018661.3018669](https://doi.org/10.1145/3018661.3018669)]
- [15] Yu WC, Cheng W, Aggarwal CC, Chen HF, Wang W. Link prediction with spatial and temporal consistency in dynamic networks. In: *Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence*. Melbourne: IJCAI.org, 2017. 3343–3349. [doi: [10.24963/ijcai.2017/467](https://doi.org/10.24963/ijcai.2017/467)]
- [16] Ma XK, Tan SY, Xie XH, Zhong XX, Deng JJ. Joint multi-label learning and feature extraction for temporal link prediction. *Pattern Recognition*, 2022, 121: 108216. [doi: [10.1016/j.patcog.2021.108216](https://doi.org/10.1016/j.patcog.2021.108216)]
- [17] Qin M, Yeung DY. Temporal link prediction: A unified framework, taxonomy, and review. *ACM Computing Surveys*, 2023, 56(4): 89. [doi: [10.1145/3625820](https://doi.org/10.1145/3625820)]
- [18] Sankar A, Wu YH, Gou L, Zhang W, Yang H. DySAT: Deep neural representation learning on dynamic graphs via self-attention networks. In: *Proc. of the 13th Int'l Conf. on Web Search and Data Mining*. Houston: ACM, 2020. 519–527. [doi: [10.1145/3336191.3371845](https://doi.org/10.1145/3336191.3371845)]
- [19] Chen JY, Wang XK, Xu XH. GC-LSTM: Graph convolution embedded LSTM for dynamic network link prediction. *Applied Intelligence*, 2022, 52(7): 7513–7528. [doi: [10.1007/s10489-021-02518-9](https://doi.org/10.1007/s10489-021-02518-9)]
- [20] Yin YT, Wu YJ, Yang XB, Zhang WS, Yuan XJ. Super resolution graph with conditional normalizing flows for temporal link prediction. *IEEE Trans. on Knowledge and Data Engineering*, 2024, 36(3): 1311–1327. [doi: [10.1109/TKDE.2023.3295367](https://doi.org/10.1109/TKDE.2023.3295367)]
- [21] Ye HY, Chen JD, Gong SJ, Jiang FX, Zhang TY, Chen JJ, Gao XF. ATFNet: Adaptive time-frequency ensembled network for long-term

- time series forecasting. arXiv:2404.05192, 2024.
- [22] Yi K, Zhang Q, Fan W, Wang SJ, Wang PY, He H, Lian DF, An N, Cao LB, Niu ZD. Frequency-domain MLPs are more effective learners in time series forecasting. In: Proc. of the 37th Int'l Conf. on Neural Information Processing Systems. New Orleans: Curran Associates Inc., 2023. 76656–76679.
 - [23] He YL, Lai JL, Cui LZ, Yin JF, Huang ZX. Multi-granularity link prediction algorithm based on spatiotemporal attention. Ruan Jian Xue Bao/Journal of Software, 2025, 36(9): 4311–4326 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/7286.htm> [doi: 10.13328/j.cnki.jos.007286]
 - [24] Jaccard P. Étude comparative de la distribution florale dans une portion des Alpes et du Jura. Bulletin de la Société Vaudoise des Sciences Naturelles, 1901, 37: 547–579. [doi: 10.5169/SEALS-266450]
 - [25] Adamic LA, Adar E. Friends and neighbors on the Web. Social Networks, 2003, 25(3): 211–230. [doi: 10.1016/S0378-8733(03)00009-1]
 - [26] Jeh G, Widom J. SimRank: A measure of structural-context similarity. In: Proc. of the 8th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. Edmonton: ACM Press, 2002. 538–543. [doi: 10.1145/775047.775126]
 - [27] Jiang SY, Xu XK, Xiao J. Link prediction by combining local structure similarity with node behavior synchronization. IEEE Trans. on Computational Social Systems, 2024, 11(3): 3816–3825. [doi: 10.1109/TCSS.2023.3335295]
 - [28] Charikhi M. Association of the PageRank algorithm with similarity-based methods for link prediction in complex networks. Physica A: Statistical Mechanics and its Applications, 2024, 637: 129552. [doi: 10.1016/j.physa.2024.129552]
 - [29] Kumar S, Mallik A, Panda BS. Link prediction in complex networks using node centrality and light gradient boosting machine. World Wide Web, 2022, 25(6): 2487–2513. [doi: 10.1007/s11280-021-01000-3]
 - [30] Chaubey VP, Sharma A, Sharma T, Sharma S, Kumar A. Link prediction for social network analysis using random forest and XG-Boost algorithm. In: Proc. of the 2nd Int'l Conf. on Informatics. Noida: IEEE, 2023. 1–6. [doi: 10.1109/ICI60088.2023.10421655]
 - [31] Choudhury N. Community-aware evolution similarity for link prediction in dynamic social networks. Mathematics, 2024, 12(2): 285. [doi: 10.3390/math12020285]
 - [32] Lv LS, Bardou D, Liu YQ, Hu P. Deep autoencoder-like non-negative matrix factorization with graph regularized for link prediction in dynamic networks. Applied Soft Computing, 2023, 148: 110832. [doi: 10.1016/j.asoc.2023.110832]
 - [33] Chen GF, Wang HB, Fang YL, Jiang L. Link prediction by deep non-negative matrix factorization. Expert Systems with Applications, 2022, 188: 115991. [doi: 10.1016/j.eswa.2021.115991]
 - [34] Lin XY, Chen XY, Zheng ZW. Deep manifold matrix factorization autoencoder using global connectivity for link prediction. Applied Intelligence, 2023, 53(21): 25816–25835. [doi: 10.1007/s10489-023-04887-9]
 - [35] Yan LP, Yu WR. Non-negative matrix factorization for link prediction preserving row and column spaces. In: Proc. of the 2023 IEEE Int'l Conf. on Data Mining. Shanghai: IEEE, 2023. 1451–1456. [doi: 10.1109/ICDM58522.2023.00190]
 - [36] Yao YB, He YY, Huang ZT, Xu ZP, Yang F, Tang JX, Gao K. Deep non-negative matrix factorization with edge generator for link prediction in complex networks. Applied Intelligence, 2024, 54(1): 592–613. [doi: 10.1007/s10489-023-05211-1]
 - [37] Min SJ, Gao Z, Peng J, Wang L, Qin K, Fang B. STGSN—A spatial-temporal graph neural network framework for time-evolving social networks. Knowledge-based Systems, 2021, 214: 106746. [doi: 10.1016/j.knosys.2021.106746]
 - [38] Tan SY, You JY, Li DY. Temporality- and frequency-aware graph contrastive learning for temporal network. In: Proc. of the 31st ACM Int'l Conf. on Information & Knowledge Management. Atlanta: ACM, 2022. 1878–1888. [doi: 10.1145/3511808.3557469]
 - [39] Mei P, Zhao YH. Dynamic network link prediction with node representation learning from graph convolutional networks. Scientific Reports, 2024, 14(1): 538. [doi: 10.1038/s41598-023-50977-6]
 - [40] Chen JY, Zhang J, Xu XH, Fu CB, Zhang D, Zhang QP, Xuan Q. E-LSTM-D: A deep learning framework for dynamic network link prediction. IEEE Trans. on Systems, Man, and Cybernetics: Systems, 2021, 51(6): 3699–3712. [doi: 10.1109/TSMC.2019.2932913]
 - [41] Pareja A, Domeniconi G, Chen J, Ma TF, Suzumura T, Kanezashi H, Kaler T, Schardl T, Leiserson C. EvolveGCN: Evolving graph convolutional networks for dynamic graphs. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI Press, 2020. 5363–5370. [doi: 10.1609/aaai.v34i04.5984]
 - [42] Goyal P, Kamra N, He XR, Liu Y. DynGEM: Deep embedding method for dynamic graphs. arXiv:1805.11273, 2018.
 - [43] Jiao PF, Guo X, Jing X, He DX, Wu HM, Pan SR, Gong MG, Wang WJ. Temporal network embedding for link prediction via VAE joint attention mechanism. IEEE Trans. on Neural Networks and Learning Systems, 2022, 33(12): 7400–7413. [doi: 10.1109/TNNLS.2021.3084957]
 - [44] Qin M, Zhang CR, Bai B, Zhang G, Yeung DY. High-quality temporal link prediction for weighted dynamic graphs via inductive embedding aggregation. IEEE Trans. on Knowledge and Data Engineering, 2023, 35(9): 9378–9393. [doi: 10.1109/TKDE.2023.3238360]
 - [45] Lei K, Qin M, Bai B, Zhang G, Yang M. GCN-GAN: A non-linear temporal link prediction model for weighted dynamic networks. In:

- Proc. of the 2019 IEEE Conf. on Computer Communications. Paris: IEEE, 2019. 388–396. [doi: 10.1109/INFOCOM.2019.8737631]
- [46] Yang M, Liu JH, Chen L, Zhao Z, Chen XJ, Shen Y. An advanced deep generative framework for temporal link prediction in dynamic networks. *IEEE Trans. on Cybernetics*, 2020, 50(12): 4946–4957. [doi: 10.1109/TCYB.2019.2920268]
- [47] Jia ZY, Lin YF, Cai XY, Chen HB, Gou HJ, Wang J. SST-EmotionNet: Spatial-spectral-temporal based attention 3D dense network for EEG emotion recognition. In: Proc. of the 28th ACM Int'l Conf. on Multimedia. Seattle: ACM, 2020. 2909–2917. [doi: 10.1145/3394171.3413724]
- [48] Zhang CL, Zhou T, Wen QS, Sun L. TFAD: A decomposition time series anomaly detection architecture with time-frequency analysis. In: Proc. of the 31st ACM Int'l Conf. on Information & Knowledge Management. Atlanta: ACM, 2022. 2497–2507. [doi: 10.1145/3511808.3557470]
- [49] Waswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser Ł, Polosukhin I. Attention is all you need. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 6000–6010.
- [50] Arriaga RI, Vempala S. An algorithmic theory of learning: Robust concepts and random projection. *Machine Learning*, 2006, 63(2): 161–182. [doi: 10.1007/s10994-006-6265-7]
- [51] Hamilton WL, Ying R, Leskovec J. Inductive representation learning on large graphs. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 1025–1035.
- [52] Paranjape A, Benson AR, Leskovec J. Motifs in temporal networks. In: Proc. of the 10th ACM Int'l Conf. on Web Search and Data Mining. Cambridge: ACM, 2017. 601–610. [doi: 10.1145/3018661.3018731]
- [53] Rossi R, Ahmed N. The network data repository with interactive graph analytics and visualization. In: Proc. of the 29th AAAI Conf. on Artificial Intelligence. Austin: AAAI, 2015. 4292–4293. [doi: 10.1609/aaai.v29i1.9277]
- [54] Kunegis J. KONECT: The Koblenz network collection. In: Proc. of the 22nd Int'l Conf. on World Wide Web. Rio de Janeiro: ACM, 2013. 1343–1350. [doi: 10.1145/2487788.2488173]
- [55] Zhou LK, Yang Y, Ren X, Wu F, Zhuang YT. Dynamic network embedding by modeling triadic closure process. In: Proc. of the 32nd AAAI Conf. on Artificial Intelligence. New Orleans: AAAI, 2018. 571–578. [doi: 10.1609/aaai.v32i1.11257]
- [56] Ozella L, Paolotti D, Lichand G, Rodríguez JP, Haenni S, Phuka J, Leal-Neto OB, Cattuto C. Using wearable proximity sensors to characterize social contact patterns in a village of rural Malawi. *EPJ Data Science*, 2021, 10(1): 46. [doi: 10.1140/epjds/s13688-021-00302-w]
- [57] Han XB, Wang LE, Huang SM, Liu P, Li XX. Privacy protection method to defend against link prediction attacks. *Computer Engineering and Design*, 2022, 43(1): 18–25 (in Chinese with English abstract). [doi: 10.16208/j.issn1000-7024.2022.01.003]
- [58] Lei TL, Ji LX, Wang GR, Liu SX, Wu L. User trajectory identification based on expandable self-attention spatio-temporal graph convolutional neural networks. *Acta Electronica Sinica*, 2024, 52(11): 3741–3750 (in Chinese with English abstract). [doi: 10.12263/DZXB.20221225]

附中文参考文献

- [1] 何玉林, 赖俊龙, 崔来中, 黄哲学, 尹剑飞. 基于多演化特征的社交网络链路预测算法. *模式识别与人工智能*, 2024, 37(7): 597–612. [doi: 10.16451/j.cnki.issn1003-6059.202407003]
- [23] 何玉林, 赖俊龙, 崔来中, 尹剑飞, 黄哲学. 基于时空注意力的多粒度链路预测算法. *软件学报*, 2025, 36(9): 4311–4326. <http://www.jos.org.cn/1000-9825/7286.htm> [doi: 10.13328/j.cnki.jos.007286]
- [57] 韩学波, 王利娥, 黄丝曼, 刘鹏, 李先贤. 防御链接预测攻击的隐私保护方法. *计算机工程与设计*, 2022, 43(1): 18–25. [doi: 10.16208/j.issn1000-7024.2022.01.003]
- [58] 雷天亮, 吉立新, 王庚润, 刘树新, 巫岚. 基于可拓展自注意力时空图卷积神经网络的用户轨迹识别模型. *电子学报*, 2024, 52(11): 3741–3750. [doi: 10.12263/DZXB.20221225]

作者简介

何玉林, 博士, 研究员, 高级工程师, CCF 专业会员, 主要研究领域为大数据系统计算技术, 多样本统计分析方法, 数据挖掘与机器学习算法及应用.

赖俊龙, 硕士生, 主要研究领域为图数据挖掘, 时空序列分析, 链路预测.

常家乐, 硕士生, 主要研究领域为图数据挖掘, 子图匹配.

崔来中, 博士, 教授, 博士生导师, CCF 杰出会员, 主要研究领域为互联网体系结构, 边缘计算, AI 驱动的新型网络优化设计.

黄哲学, 博士, 教授, 博士生导师, CCF 专业会员, 主要研究领域为大数据系统计算技术, 数据挖掘与机器学习算法及应用.