

基于深度学习和多特征融合的时序社交网络关键节点识别

张雪芹, 王智能, 李晋生, 陆一松, 罗飞

引用本文

张雪芹, 王智能, 李晋生, 陆一松, 罗飞. 基于深度学习和多特征融合的时序社交网络关键节点识别[J]. 计算机科学, 2026, 53(4): 143-154.

ZHANG Xueqin, WANG Zhineng, LI Jinsheng, LU Yisong, LUO Fei. [Key Node Identification in Temporal Social Networks Based on Deep Learning and Multi-feature Fusion](#) [J]. Computer Science, 2026, 53(4): 143-154.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[跨模态融合的少样本勒索软件分类器:基于预训练模型的多模态编码](#)

Cross-modal Fusion Few-sample Ransomware Classifier:Multimodal Encoding Based on Pre-trained Models

计算机科学, 2026, 53(4): 435-444. <https://doi.org/10.11896/jsjcx.250500078>

[知识辅助和强化句法驱动的方面级情感分析](#)

Knowledge-assisted and Reinforced Syntax-driven for Aspect-based Sentiment Analysis

计算机科学, 2026, 53(4): 406-414. <https://doi.org/10.11896/jsjcx.250600117>

[STWD-DLFRD:基于序贯三支决策与深度学习的多粒度虚假评论检测方法](#)

STWD-DLFRD:Multi-granularity Fake Review Detection via Sequential Three-way Decisions and Deep Learning

计算机科学, 2026, 53(4): 188-196. <https://doi.org/10.11896/jsjcx.250500088>

[KGMamba:基于Kolmogorov-Arnold网络优化图卷积网络和Mamba的基因调控网络预测模型](#)

KGMamba:Gene Regulatory Network Prediction Model Based on Kolmogorov-Arnold Network Optimizing Graph Convolutional Network and Mamba

计算机科学, 2026, 53(4): 101-111. <https://doi.org/10.11896/jsjcx.250500097>

[基于深度学习的GIFT-128与ASCON算法神经差分区分器研究](#)

Deep Learning-based Neural Differential Distinguishers for GIFT-128 and ASCON

计算机科学, 2026, 53(3): 453-458. <https://doi.org/10.11896/jsjcx.250600176>

基于深度学习和多特征融合的时序社交网络关键节点识别

张雪芹^{1,2} 王智能¹ 李晋生¹ 陆一松¹ 罗飞¹

1 华东理工大学信息科学与工程学院 上海 200237

2 上海市计算机软件评测重点实验室 上海 201112

(zxq@ecust.edu.cn)

摘要 社交网络是信息传播的主要渠道,识别社交网络中的关键节点对发现信息传播枢纽、进行信息传播控制等具有重要意义。现实社交网络具有时变性,合理建模时序网络,并对节点的空间和时间关系进行全面描述和深度挖掘,是准确识别网络关键节点的重要因素。为了提高关键节点识别的精度,提出了一种基于深度学习和多特征融合的时序社交网络关键节点识别方法 MCNN(Multidimensional CNN)。该方法首先将时序网络建模为基于快照的多维关系网络,对于一个节点,在每个快照,分别从空间结构、时间耦合和三类时空传播关系,提取节点的空间、时间和时空上下文,并构建节点特征矩阵。为了深度分析节点在每个快照中的时空关系,使用卷积神经网络 CNN 分别提取 3 类节点特征,并使用自注意力机制融合形成节点快照特征。为了捕捉节点行为在快照间的演变,组合所有快照的节点快照特征作为时间序列,采用长短期记忆网络 LSTM 挖掘快照序列特征。最后,使用全连接层预测节点的影响力。在 6 个真实时序社交网络上的实验结果表明,MCNN 在时序社交网络关键节点识别方面优于基线方法。

关键词: 时序社交网络;节点影响力;网络表示;时空特征;深度学习

中图分类号 TP181

Key Node Identification in Temporal Social Networks Based on Deep Learning and Multi-feature Fusion

ZHANG Xueqin^{1,2}, WANG Zhineng¹, LI Jinsheng¹, LU Yisong¹ and LUO Fei¹

1 Department of Information Science and Engineering, East China University of Science and Technology, Shanghai 200237, China

2 Shanghai Key Laboratory of Computer Software Testing & Evaluating, Shanghai 201112, China

Abstract Social network is the main channel of information dissemination, and identifying key nodes in social networks is important for discovering information dissemination hubs and performing information dissemination control. Realistic social networks are time-varying, and reasonable modeling of temporal networks with comprehensive description and deep mining of the spatial and temporal relationships of nodes is an important factor for accurately identifying key nodes in the network. In order to improve the accuracy of key node identification, a deep learning and multi-feature fusion based method MCNN(Multidimensional CNN) for key node identification in temporal social networks is proposed. The method firstly models the temporal network as a multidimensional relational network based on snapshots, and for a node, in each snapshot, the spatial, temporal, and spatio-temporal contexts of the node are extracted from the spatial structure, temporal coupling, and three types of spatio-temporal propagation relations, respectively, and the node feature matrix is constructed. In order to deeply analyze the spatio-temporal relationships of nodes in each snapshot, three types of node features are extracted using CNN, respectively, and fused to form the node snapshot features using the self-attention mechanism. To capture the evolution of node behaviors between snapshots, node snapshot features of all snapshots are combined as a time sequence, and LSTM is used to mine the snapshot sequence features. Finally, the influence of nodes is predicted using a fully connected layer. Experiments on six real temporal social networks show that MCNN outperforms the baseline approaches for key node identification in temporal social networks.

Keywords Temporal social network, Node influence, Network representation, Spatio-temporal characteristics, Deep learning

到稿日期:2025-03-27 返修日期:2025-06-12

基金项目:国家自然科学基金重大项目(23&-ZD142)

This work was supported by the Major Program of the National Social Science Foundation of China(23&-ZD142).

通信作者:王智能(wangzhineng2022@163.com)

1 引言

社交网络^[1-3]是一个复杂的信息传播系统。在社交网络的众多用户中,部分用户由于具有较大的影响力,在信息传播和用户互动中起到举足轻重的作用,这些特殊用户被称为关键节点^[4-5]。检测和识别关键节点具有广泛的应用价值,包括抑制谣言传播、营销推广产品以及控制传染病蔓延等^[6-7]。准确识别社交网络中的关键节点,对于研究社交网络传播行为具有重要意义。

目前,研究者已经提出了许多方法来衡量节点的重要性。传统方法主要基于节点的拓扑结构来评估节点影响力,包括度中心性 DC(Degree Centrality)^[8]、中间中心性 BC(Betweenness Centrality)^[9]、重力模型方法 AOGC(Gravity Centrality Method based on An Adaptive Truncation Radius and Omni-channel Paths)^[10]等。由于特征维度的单一性或者组合维度的主观性,该类方法存在无法准确衡量节点拓扑特征的问题^[11]。近年来,随着深度学习技术在多领域的成功应用^[12],研究者也开始将深度学习方法应用到关键节点识别中,采用图神经网络(GNN)或卷积神经网络(CNN)等来学习节点影响力,如 CGNN^[13],GMAT^[14]和 GLSTM^[15]等方法。基于深度学习的节点识别方法可以自动学习和挖掘网络节点的深度特征,相比于传统方法,在一定程度上提高了识别的准确性。然而,这些方法将社交网络看成静态网络进行分析,而在现实世界中,社交网络往往是随时间变化的时序网络^[16],在静态网络分析中由于缺乏时间信息,这些方法对信息传播过程的刻画不够精确,因此识别精度受到影响。现有的大多数时序网络研究方法可分为基于拓扑的方法^[17-20]、基于超邻接矩阵的方法^[21-23]和基于网络嵌入的方法^[24-28]3种。基于拓扑的方法将静态中心性扩展到时序版本,一类是将时序网络视为聚合静态图,通过计算该图的中心性指标,得到节点的影响力;另一类将时序网络视为快照序列,即以快照表示网络在特定时刻的静态状态,通过计算每个快照的中心性指标,并求平均值作为节点的影响力。基于拓扑的方法虽然计算复杂度低,但其中第一类方法忽略了节点的交互次数,第二类方法则忽略了节点发生交互的时间顺序,因而存在较大的识别误差。基于超邻接矩阵的方法通常将整个时序网络建模为一个超邻接矩阵 SAM(Super-Adjacency Matrix),该矩阵的维度为 $NT \times NT$,其中 N 代表时序网络的节点数量, T 代表时序网络的快照数量。该矩阵既包含一个快照内不同节点的结构关系,即每一时刻的邻接矩阵,又包含了不同快照间相同节点的时间关系,即不同时刻间的时间耦合矩阵。相比于基于拓扑的方法,该类方法考虑了节点的交互次数和顺序,且额外考虑了不同时间层的耦合关系,识别精度得到了有效提升。但对于规模较大的网络,该方法的计算复杂度较高。基于网络嵌入的方法是当前的新兴研究热点,该类方法通常通过构建节点的特征矩阵并输入到神经网络中进行学习来提取节点特征,得到节点的影响力,从而进行关键节点识别。该方法可以自动提取时空特征,从而得到更高的识别精度。但目前,该类方法对空间特征和时间特征的处理方式较为单一,通常先提取快照的空间特征,再提取快照序列的时间特征,在初始特征

矩阵构建的维度上还不够全面,预测精度有待提高。

为了提高时序社交网络关键节点识别的准确性,本文提出了一个基于深度学习和多特征融合的关键节点识别方法 MCNN。本文的主要贡献如下:

1)根据快照内的不同节点、快照间的相同节点和快照间的不同节点间的关系,将时序网络建模为基于快照的多维关系网络,从而更全面地捕捉节点在时间和空间上的关系。

2)对于一个节点,在每个快照中,分别考虑空间结构关系、时间耦合关系和三类时空传播关系,提取节点的空间、时间和时空上下文并构建节点特征矩阵。采用 CNN、自注意力机制和 LSTM 构建的动态注意力卷积网络预测节点影响力。

3)在 6 个真实时序社交网络数据集上,围绕 3 个指标,基于 SIR(Susceptible Infected Recovered)模型对 MCNN 和基线方法进行对比实验,实验表明,MCNN 能够有效提高时序社交网络关键节点识别的准确性。

2 相关工作

时序网络的拓扑结构随着时间的推移而变化,由于需要同时考虑时间和空间属性,在时序网络中识别关键节点比在静态网络中更具挑战性。

基于拓扑的时序网络关键节点识别研究方法主要是在静态中心性方法的基础上融入时间信息。Kim 等^[17]提出了多种时间中心性,如时间度中心性 TDC(Temporal Degree Centrality)、时间中间中心性 TBC(Temporal Betweenness Centrality)和时间接近中心性 TCC(Temporal Closeness Centrality)等。该方法求得每个快照的中心性(如度中心性)后,将所有快照的平均中心性值作为节点的影响力。Ye 等^[18]提出了时序 K-shell 分解法 TK(Temporal K-shell),该方法比较每个快照中节点与其各个邻居的 K-shell 值,取较小值进行累加,得到节点的快照重要性,然后将所有快照的重要性之和作为节点影响力。为了解决传统时间中心性忽略节点交互时间顺序的缺点,Bi 等^[19]提出了时间重力模型 TGC(Temporal Gravity Centrality),该方法使用 TDC, TBC 等时间中心性作为节点质量,使用满足时间顺序的路径长度,如时间最短距离,作为节点关系,将重力模型扩展应用到了时序网络。Tao 等^[20]提出了一种中心性度量方法 SPT-C(Sequential-Path Tree-based Centrality),该方法基于顺序路径树建模时序网络,并同时考虑了 3 种不同的时间特征(传播时间、跳数和可达路径),多维计算节点的中心性来识别关键节点。上述方法中,TDC 等传统中心性方法忽略了节点交互的次数或顺序,TGC, SPT-C 等中心性方法缺少对同一节点在时序网络中关系的考量,因而在关键节点识别的精度上存在一定误差。

基于超邻接矩阵的时序网络研究方法主要聚焦于构建邻接矩阵和层间耦合矩阵。Taylor 等^[21]采用多层耦合网络分析方法,结合层间和层内关系将时序网络建模为超邻接矩阵,并基于特征向量中心性衡量节点的重要性。Yin 等^[22]提出了基于 SAM 的改进方法 SSAM(Similarity-based Supra-Adjacency Matrix),该方法使用节点的邻居拓扑重叠系数度量相邻层间的关系,从而反映不同节点层间耦合关系的差异。Jiang 等^[23]提出了一种基于层间耦合强度衰减的 ASAM(At-

tenuation-based Supra-Adjacency Matrix)时序网络建模方法,采用一种新的相似度指数来考虑非相邻层之间的层间耦合关系,并引入衰减因子描述时间层的衰减关系,基于 ASAM 计算节点的特征向量中心性。上述方法的性能相较于基于拓扑的方法有一定提升,但存在超邻接矩阵规模较大,面对节点数和快照数较多的时序网络时复杂度较高的问题,而且该方法忽略了快照间不同节点的关系,因此精度仍待有提升。

基于网络嵌入的方法将网络节点的复杂关系转换为低维度的向量表示。Qu 等^[24]提出一种时间信息收集 TIG(Temporal Information Gathering)过程,该方法以邻域的重要性定义节点的重要性,节点影响力由不同阶邻居的重要性函数、距离索引矩阵和节点初始分数相乘后累加得到。Song 等^[25]使用一种深度自编码高斯混合模型 DAGMM(Deep Autoencoding Gaussian Mixture Model),基于深度自编码器生成节点的低维表示,并将其应用于时序网络中的节点排序。Yu 等^[26]将每个时间层的节点特征矩阵以固定权重合并,并使用 CNN 学习每个节点的影响力,实现了一种基于网络嵌入和深度学习的算法 MLI(Machine Learning Index)。Yu 等^[27]提出一种结合特殊图卷积网络和长短期记忆网络的深度学习时序网络关键节点识别框架 DGCN(Dynamic Graph Convolutional Network),特殊图卷积网络用于嵌入每个加权快照的节点,长短期记忆网络则用于提取时间特征。Yan 等^[28]提出了一种基于节点特征初始化的流图学习模型来识别时序网络中的关键节点,该方法通过多尺度特征向量和注意力机制来全面表示和提取节点特征。该类方法的优势在于,可以自动学习




图 1 聚合静态图和时间快照图

Fig. 1 Aggregated static and time snapshot graphs

3.2 时间路径

在时间区间 $[t_{\text{start}}, t_{\text{end}}]$ 中,时序网络 $G^T = (V, E^T)$ 的时间路径集合可表示为 P ,时间路径表示为一个节点序列 $P = \langle v_1, v_2, \dots, v_k, v_{k+1} \rangle$,序列中相邻的节点间存在一个时间事件 $(v_i, v_{i+1}, t_i) \in E^T$,其中 $1 \leq i \leq k$ 且 $t_i \leq t_{i+1}$ 。设时间路径的起始时间为 $t_{\text{initial}}(P) = t_1$,结束时间为 $t_{\text{final}}(P) = t_k$,则时间间隔为 $\Delta t(P) = t_k - t_1 + 1$,时间距离为 $d(P) = k$ 。

时间路径被分为两类,即最快到达路径和时间最短路径^[34]。时间路径 P 成为最快到达路径的条件为 $t_{\text{final}}(P) = \min\{t_{\text{final}}(P') \mid P' \in \mathbf{P}\}$,时间路径 P 成为时间最短路径的条件为 $\Delta t(P) = \min\{\Delta t(P') \mid P' \in \mathbf{P}\}$ 。最快到达距离和时间最短距离则被视为两类时间路径对应的时间距离^[19]。例如,在图 1 所示的时序网络中,节点 A 到节点 C 的最快到达时间路径为 $P = \langle A, B, C \rangle$,此时 $t_{\text{final}}(P) = 2$,而节点 A 到节点 C 的时间最短路径为 $P = \langle A, C \rangle$,此时 $\Delta t(P) = 1$ 。

网络结构和节点关系特征,很大程度上提升了关键节点识别的准确性,但还存在节点的特征矩阵构造未全面表示节点的时空关系,提取时空特征的方式比较单一的问题。

因此,将时序网络进行合理建模,充分表征节点间的时空关系并进行多维度特征提取,仍然是时序网络关键节点识别的重要研究内容。

3 MCNN

3.1 时序网络表示

通常,一个网络可以表示为 $G = (V, E)$,其中 $V = \{v_1, v_2, \dots, v_{|V|}\}$ 和 $E = \{e_1, e_2, \dots, e_{|E|}\}$ 分别表示网络中的节点和边,设节点数量 $|V| = n$,边的数量 $|E| = m$ ^[29]。

对于时序社交网络,在时间区间 $[1, T]$ 中,一个时序网络可以表示为 $G^T = (V, E^T)$,其中 $V = \{v_1, v_2, \dots, v_{|V|}\}$ 和 $E^T = \{e_1, e_2, \dots, e_{|E^T|}\}$ 分别表示时序网络中的节点集合和时间联系事件集合^[30]。 $e \in E^T$ 可表示为一个三元组 (v_i, v_j, t) ,代表节点 v_i 和节点 v_j 在时刻 t 发生联系。在每个 $t \in [1, T]$,快照网络可以用邻接矩阵 A_t 来表示,其中 $A_t(i, j) = 1$ 表示 v_i 和 v_j 在时刻 t 连接, $A_t(i, j) = 0$ 表示 v_i 和 v_j 在时刻 t 不连接。

通常,时序网络可以采用 3 种形式表示:基于聚合静态图的表示^[31]、基于流路径的表示^[32]和基于时间快照图的表示^[33]。时间快照表示一系列按时间顺序排列的快照,基于时间快照图的表示可以更清晰地捕捉时序网络在每个时刻的结构变化,本文基于时间快照进行时序网络分析,如图 1 所示。

3.3 SIR 模型

为了衡量节点的真实影响力,采用 SIR 模型^[35]模拟信息在时序社交网络中的传播。

基于 SIR 模型,对于节点 v ,分别以 $t \in [1, n]$ 为开始时间感染节点 v ,得到节点感染规模集合 $R^T = \{R_1, R_2, \dots, R_n\}$ 。节点真实影响力的计算式如下^[19]:

$$R_{\text{norm}} = \frac{1}{n} \sum_{t=1}^n \frac{R_t}{n-t+1} \quad (1)$$

其中, R_{norm} 为节点的平均归一化感染规模。

基于 SIR 模型,时序网络关键节点识别问题可以定义为^[36]:

$$v^* = \arg \max_{v \in V} \sigma(v) \quad (2)$$

其中, v^* 表示关键节点, σ 表示 SIR 模型下节点的传播规模。

3.4 技术路线

为了提高时序网络节点影响力预测的准确性,本文提出

了一种基于深度学习和多维特征融合的时序网络关键节点识别方法 MCNN。

MCNN 将时序网络建模为基于快照的多维关系网络,该网络包含 3 类节点关系:快照内不同节点的空间结构关系、快照间同一节点的时间耦合关系和快照间不同节点的时空传播关系。对于快照 $G_t \in G^T$ 中的节点 v ,空间结构关系指的是在快照 G_t 中,节点 v 和邻域节点间的连接关系,它可以描述当前时间节点的拓扑特征。时间耦合关系指的是快照 $G_t, G_{t+1}, G_{t+2}, \dots$ 间,节点 v 之间的连续关系,它可以刻画节点在不同

时间邻域的动态变化。时空传播关系指的是从快照 G_t 开始,节点 v 和其他节点间的时间路径关系,它反映了不同时间节点间的交互关系。如图 2 所示,快照 1 中节点 A 和节点 B 的黑色实线表示空间结构关系,快照 1 和快照 2 中节点 A 之间的黑色虚线表示相邻的时间耦合关系,快照 1 和快照 4 节点 D 之间的黑色虚线表示非相邻的时间耦合关系,快照 1 和快照 4 中节点 A 和节点 C 之间的红色实线表示时空传播关系,该关系对应的时间路径为 $A \xrightarrow{1} B \xrightarrow{2} D \xrightarrow{3} A \xrightarrow{4} C$ 。

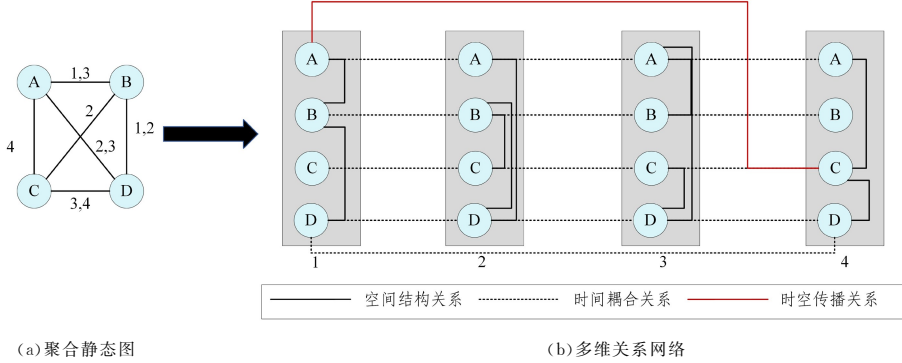


图 2 多维关系网络(电子版为彩图)

Fig. 2 Multi-dimensional relationship network

MCNN 的技术框架如图 3 所示。对于一个节点,在时序网络的每个快照中,根据空间结构、时间耦合和时空传播三类关系,分别提取对应的节点上下文并构建特征矩阵。其次,使用 3 个 CNN 分别提取空间结构、时间耦合和时空传播特征

向量,采用自注意力机制融合三类特征得到融合特征向量。然后,组合所有快照的融合特征向量作为时间序列,采用 LSTM 挖掘快照序列特征。最后,使用全连接层预测节点的影响力。

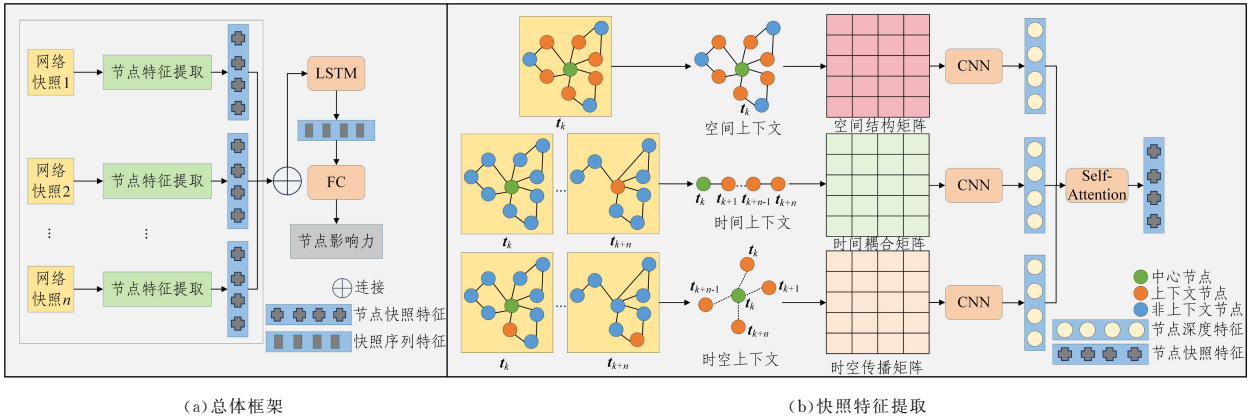


图 3 时序社交网络关键节点识别技术框架 MCNN

Fig. 3 Technical framework MCNN for key node identification in temporal social networks

3.4.1 节点特征矩阵构建

1) 空间结构矩阵

为了揭示在同一快照下不同节点的空间结构关系,对于网络快照 $G_t \in G^T$,按照以下规则提取空间上下文:对于节点 v ,设 L_{space} 代表其空间上下文的大小,首先按跳数升序搜索其 $L_{space} - 1$ 个邻居,如果两个邻居的顺序相同,则优先考虑度中心性更高的节点^[37-38]。这样,节点 v 及其 $L_{space} - 1$ 个邻居构成空间上下文 C_{space} 。

为了有效表示在空间上下文 C_{space} 中每个节点的局部结构特征,捕捉每个节点在邻域内的重要性及差异,构造空间特征矩阵 F_{space}^v ^[26],其元素 $F_{space_ij}^v$ 的计算方式如下:

$$F_{space_ij}^v = \begin{cases} k_i, & i=j=0,1,\dots,L_{space}-1 \\ A_{ij}^v, & \text{otherwise} \end{cases} \quad (3)$$

其中, k_i 表示节点 $v_i \in C_{space}$ 的度, A_{ij}^v 表示 C_{space} 构成的邻接矩阵 A^v 的元素。

2) 时间耦合矩阵

在时序网络中,同一个节点在不同快照中的邻居节点是变化的,不同时间层的关系又受到时间间隔的影响。为了准确描述节点间关系的动态变化,揭示不同快照下同一节点的时间耦合关系,从时间 t 开始,设 L_{time} 代表时间上下文的大小,按时间升序搜索 L_{time} 个节点构成时间上下文 C_{time} ,参考文献^[23],采用带有衰减的增强相似度指数(ESI),定义时间 t_1

和 $t_2 (t_1 < t_2)$ 时刻节点 v_i 的层间耦合度为:

$$s_i^{(t_1, t_2)} = e^{\lambda(t_1 - t_2)} \times \left[0.5 + \frac{\sum_j a_{ij}^{t_1} + \sum_j a_{ij}^{t_2}}{2N} + \frac{|\text{CN}_i^{(t_1, t_2)}|}{N} \right] \quad (4)$$

其中, N 表示时序网络中节点的个数; λ 是指定衰减率的参数, 本文取 $\lambda = 1$; $a_{ij}^{t_k}$ 表示 t_k 时刻快照对应的邻接矩阵元素; $\text{CN}_i^{(t_1, t_2)}$ 表示 t_1 和 t_2 时刻快照节点 v_i 的共同邻居集合。

基于层间耦合度, 为了观察每个快照中相同节点的邻域结构变化, 构造 $L_{\text{time}} \times L_{\text{time}}$ 的时间特征矩阵 F_{time}^v , 其元素 $F_{\text{time}_{ij}}^v$ 的计算式如下:

$$F_{\text{time}_{ij}}^v = \begin{cases} k_i, & i = j = 0, 1, \dots, L_{\text{time}} - 1 \\ s_i^{(t_i, t_j)}, & \text{otherwise} \end{cases} \quad (5)$$

其中, k_i 表示节点 $v_i \in C_{\text{time}}$ 的度, $s_i^{(t_i, t_j)}$ 表示时间 t_i 和 t_j 下节点 v 的层间耦合度。

3) 时空传播矩阵

时序网络中的信息传播与传播时间、传播距离和传播路径数量有关。其中, 传播时间描述信息传播的速率, 传播距离揭示了节点间的结构接近性, 而传播路径的数量刻画了信息传播的稳定性。为了揭示不同快照下不同节点的时空传播关系, 可以分别从传播时间、传播距离、传播路径数量^[20] 3 个角度描述节点的时空上下文。

以时间 t 为开始时间, 设 L_{st} 为时空上下文的大小, 首先求节点 v 到其他节点的最快到达路径 $P^{[34]}$ 。基于该路径的到达时间 $t_{\text{final}}(P)$ 、时间距离 $d(P)$ 和路径数量 $n(P)$, 搜索 L_{st} 个节点, 构成时空上下文 C_{st} 。同时, 为了更好地表示节点 v 和不同上下文节点在传播关系上的差异性, 构造一个时间关系加权矩阵, 即时空特征矩阵 F_{st}^v , 其元素 $F_{\text{st}_{ij}}^v$ 的计算式如下:

$$F_{\text{st}_{ij}}^v = \begin{cases} k_i, & i = j = 0, 1, \dots, L_{\text{st}} - 1 \\ A_{ij}^v \times e^{-|f(i) - f(j)|}, & \text{otherwise} \end{cases} \quad (6)$$

其中, k_i 表示节点 $v_i \in C_{\text{st}}$ 的度, $f(i)$ 可根据传播时间、传播距离和传播路径数量分别表示为节点 v 到节点 v_i 的最快到达路径的到达时间 $t_{\text{final}}(i)$ 、时间距离 $d(i)$ 、路径数量 $n(i)$ 。

3.4.2 快照特征

在得到节点 v 的空间、时间和时空特征矩阵后, 为了进一步分析节点在网络快照中的状态, 对节点进行快照特征提取。卷积神经网络 CNN^[39] 可以有效捕捉节点间的局部依赖性和层次结构, 深度分析节点在不同时间和空间上的行为模式, 因此, 本文使用 3 个 CNN 分别深度挖掘节点的空间、时间和时空特征。得到的节点空间、时间和时空特征向量如下:

$$\begin{cases} f_{\text{space}}^v = \text{CNN}_1(F_{\text{space}}^v) \\ f_{\text{time}}^v = \text{CNN}_2(F_{\text{time}}^v) \\ f_{\text{st}}^v = \text{CNN}_3(F_{\text{st}}^v) \end{cases} \quad (7)$$

其中, f_{space} , f_{time} 和 f_{st} 表示通过 CNN 提取的深度空间、时间和时空特征向量。

在得到 3 类特征向量后, 对其进行充分利用和整合尤为重要。因此, 在模型中引入了一个自注意力层^[40]。通过这种方式, 模型能够自适应地强调对预测结果影响更大的特征, 而抑制其他贡献较少的特征。融合特征向量的表示如下:

$$f_{\text{fus}} = \text{SelfAttention}(f_{\text{space}}, f_{\text{time}}, f_{\text{st}}) \quad (8)$$

其中, f_{fus} 表示融合后的特征向量, 即节点快照特征向量。

3.4.3 快照序列特征

时序网络节点的关系是随着时间的变化而变化的, 捕捉节点行为在快照间的演变情况有助于提高关键节点识别的准确性。LSTM^[41] 可以有效捕捉数据中的长期依赖关系, 因此, 组合所有快照特征向量后, 采用 LSTM 进行进一步深度挖掘, 得到快照序列特征 g^T :

$$g^T = \text{LSTM}(\{f_{\text{fus}_1}, f_{\text{fus}_2}, \dots, f_{\text{fus}_n}\}) \quad (9)$$

在得到节点的快照序列特征后, 采用全连接层预测节点 v 的影响力 I :

$$I = \text{FC}(g_n) \quad (10)$$

计算完所有节点影响力后, 根据影响力排序, 得到时序网络的关键节点:

$$v^* = \arg \max(I(G^T, v)) \quad (11)$$

3.4.4 模型架构

MCNN 框架包括 3 个卷积神经网络 CNN、1 个自注意力机制模块、1 个长短期记忆网络和 1 个全连接层。CNN 包括 2 个卷积层、2 个最大池化层和 1 个全连接层: 第一个卷积层的输入通道为 1, 输出通道为 16; 第二个卷积层的输入通道为 16, 输出通道为 32; 卷积层的内核大小为 5×5 , 步幅为 1, 填充为 2; 最大池化层的内核大小为 2×2 ; 全连接层输入和输出维度分别为 $32 * (L/4) * (L/4)$ 和 1^[42]。自注意力机制模块的输入和输出维度都为 1。长短期记忆网络的输入维度为 3, 输出维度为 64, 包含两层 LSTM。全连接层的输入和输出维度分别为 64 和 1。激活函数为 ReLU。

4 实验和讨论

4.1 数据集

为了便于比较, 参考基线方法, 采用 InVS15^[43], HC^[44], HS2013^[45], HT2009^[46], PS^[47] 和 SFHH^[46] 这 6 个真实网络作为时序网络数据集。其中, InVS15 是一个工作场所中人与人联络的时序网络; HC 是一个描述 2010 年 12 月 6 日至 10 日法国里昂一家医院中, 病人和医护人员之间互动情况的时序网络; HS2013 是一个描述 2013 年法国马赛一所高中学生之间的联系和友谊的关系网络; HT2009 描述了 ACM Hypertext 2009 会议的参会者之间的联系; PS 描述了发表在 *BMC Infectious Diseases* 上的文章中研究的学生和教师之间的交流信息; SFHH 描述了 2009 年在法国尼斯举行的 SFHH 会议的参与者之间的互动关系。表 1 列出了这些时序网络的属性描述。其中, n 表示节点数量, T 表示原采样快照数, $|C|$ 表示节点联系的总数, $|E|$ 表示聚合静态图的边数量。

表 1 6 个真实网络的统计属性

Table 1 Statistical properties of six real networks

网络	n	T	$ C $	$ E $
InVS15	219	21536	1283195	16725
HC	75	9453	32424	1139
HS2013	327	7375	188508	5818
HT2009	113	5246	20819	2196
PS	242	3100	125773	8317
SFHH	403	3509	70261	9565

4.2 评价指标

本文采用以下评价指标评估时序社交网络关键节点识别方法的性能。

1) 肯德尔系数(Kendall's τ coefficient)

肯德尔系数^[48]用来衡量节点预测分数和真实分数排序序列的关联程度。

$$\tau(\mathbf{X}, \mathbf{Y}) = \frac{2(n_+ - n_-)}{N(N-1)} \quad (12)$$

其中, $\mathbf{X} = (x_1, x_2, \dots, x_N)$ 和 $\mathbf{Y} = (y_1, y_2, \dots, y_N)$ 是两个长度为 N 的排名序列, n_+ 和 n_- 分别为 \mathbf{X} 和 \mathbf{Y} 之间的正序对和逆序对数量。

2) 前 10% 命中率(Top10% HR)

前 10% 命中率^[49]用来衡量预测的影响力前 10% 节点和真实的影响力前 10% 节点的重合率。

$$acc = \frac{|pre \cap real|}{10} \times 100\% \quad (13)$$

其中, pre 代表预测影响力前 10% 节点集合, $real$ 代表通过 SIR 模型得到的真实影响力前 10% 节点集合。

3) 皮尔森相关性系数(Pearson Correlation Coefficient)

皮尔森相关性系数^[50]用于度量两个预测分数和真实分数之间的线性相关程度。

$$r = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (14)$$

其中, \mathbf{X} 和 \mathbf{Y} 分别表示预测分数和真实分数, \bar{X} 和 \bar{Y} 分别表示两者的均值。

4.3 基线和实验环境

基线方法包括 TDC^[17], TK^[18], TGC^[19], SPT-C^[20], ASAM^[23], TIG^[24], MLI^[26] 和 DGCN^[27]。其中 TDC 是局部中心性的时序版本; TK 是全局中心性的时序版本; TGC 是重力模型的时序版本; SPT-C 是基于顺序路径树的中心性方法; ASAM 是基于超邻接矩阵的方法; TIG, MLI 和 DGCN 是基于网络嵌入的方法。相关介绍见第 2 章。

实验配置如下: CPU 为 Core i9-12900H, 内存 16GB, GPU 为 NVIDIA GeForce RTX 3060, 显存为 6GB。

所有深度学习模型训练轮次为 500, 学习率为 0.001, 权重衰减为 0.001。损失函数为均方误差(MSE), 优化函数为 Adam。SIR 模型的感染率范围为 0.01~0.1。

除 4.4.4 小节中的实验外, 在其余实验中, 节点的时空特征矩阵均基于传播时间构建。

4.4 实验及分析

4.4.1 参数实验

本实验用于确定 4 个超参数, 包括快照数 L 、空间上下文长度 L_{space} 、时间上下文长度 L_{time} 以及时空上下文长度 L_{st} 。实验在 InVS15 数据集上进行, 3 个指标均取所有感染率下的平均值。

1) 快照数 L

参考文献^[26], 首先固定 $L_{space} = L_{time} = L_{st} = 8$, 分别取 $L \in \{100, 120, 140, 160, 180, 200\}$, 实验结果如表 2 所列。

表中, K , HR 和 P 分别表示肯德尔系数、前 10% 命中率和皮尔森相关性系数, Avg 表示 3 个指标的平均值, 粗体表示最优值, 下划线表示次优值。

表 2 InVS15 上 MCNN 在不同快照数下的性能

Table 2 Performance of MCNN with different number of snapshots on InVS15

L	K	HR	P	Avg
100	0.8256	0.6045	0.9137	0.7813
120	0.7842	0.8182	0.8940	0.8321
140	0.7942	0.8318	0.9111	<u>0.8457</u>
160	0.7881	<u>0.8273</u>	0.9084	0.8412
180	<u>0.8217</u>	0.7864	<u>0.9385</u>	0.8489
200	0.8133	0.6682	0.9443	0.8086

从表 2 中可看到, 3 个指标的最优值在不同的快照数 L 上。考虑在 $L=180$ 时, MCNN 的平均指标最高, 因此在后续实验中, 采用 $L=180$ 作为时序社交网络的快照划分数。

2) 上下文长度

固定 $L=180$, 分别取 $L_{space}, L_{time}, L_{st} \in \{4, 8, 12, 16, 20\}$, 实验结果如图 4 所示。图中, x, y, z 轴分别代表 L_{space}, L_{time} 以及 L_{st} , 点的颜色和大小代表归一化后的 3 个指标的平均值, 颜色对应的归一化值如图 4 右侧颜色条所示。

从图 4 中可以很明显地观察到两个较大的紫色的点, 表示在这两个点所对应的上下文长度上, MCNN 可以得到较好的性能。观察这两个点的坐标, 可以看到它们的 L_{time} 和 L_{st} 都很接近, 但 L_{space} 的差距较大, 分别为 8 和 20。考虑到较小的上下文长度可以降低计算复杂度, 因此选择 $L_{space}=8$, 其对应的的时间和时空上下文长度分别为 $L_{time}=8$ 和 $L_{st}=8$ 。

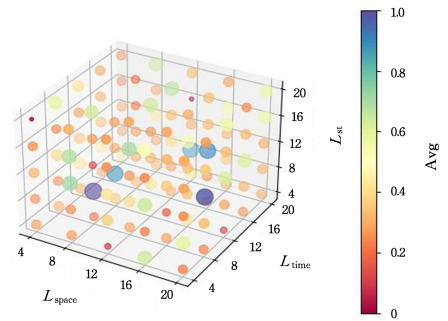


图 4 InVS15 上 MCNN 在不同上下文长度的性能

Fig. 4 Performance of MCNN with different context lengths on InVS15

4.4.2 对比实验

在 6 个不同规模的时序社交网络数据集上比较 MCNN 和基线方法的性能。3 个指标均取所有感染率下的平均值。

不同方法的肯德尔系数如表 3 所列, 其中 Improved 表示 MCNN 相比最优基线方法的提升率。

如表 3 所列, 除了在 HT2009 数据集上 MCNN 的肯德尔系数略低于 DGCN, 在其他数据集上, MCNN 均取得了最优的性能, 尤其是在 HS2013 数据集上, MCNN 的性能比次优方法 DGCN 提升了 31.6%。这表明 MCNN 得到的节点排名更接近 SIR 模型得到的节点真实影响力排名。

表3 各个方法和 SIR 模型得到节点排名的肯德尔系数

Table 3 Kendall's τ coefficients of node ranking obtained by each method and SIR model

Methods	InVS15	HC	HS2013	HT2009	PS	SFHH
TDC	<u>0.7015</u>	0.5782	0.6400	0.5273	0.5742	<u>0.6955</u>
TK	0.5486	0.5930	0.6262	0.5234	0.5533	0.6606
TGC	0.6923	0.5810	0.6086	0.5174	0.5371	0.6923
SPT-C	0.4637	<u>0.7828</u>	0.6171	0.7938	0.7615	0.4796
ASAM	0.4632	0.6279	0.5661	0.5991	0.5917	0.6690
TIG	0.5222	0.5466	0.5104	0.4821	0.4451	0.6371
MLI	0.6971	0.5735	0.6402	0.5198	0.5714	0.6944
DGCN	0.4336	0.7641	<u>0.6442</u>	0.8066	<u>0.7646</u>	0.4688
MCNN	0.8217	0.8370	0.8475	<u>0.8041</u>	0.7659	0.7950
Improved/%	17.1	6.9	31.6	-0.3	0.2	14.3

不同方法的前 10% 命中率实验结果如表 4 所列。与肯德尔系数实验的情况相似,MCNN 在 HT2009 数据集上的前 10% 命中率表现略低于 DGCN,但在其余数据集上均取得了

最优值,且在 InVS15 数据集上的表现最优,比次优方法 SPT-C 提升了 34.1%。这表明 MCNN 在识别关键节点方面具有优异的表现。

表4 各个方法和 SIR 模型得到的前 10% 命中率

Table 4 Top10% HR obtained by each method and SIR model

Methods	InVS15	HC	HS2013	HT2009	PS	SFHH
TDC	0.5818	0.5125	0.5394	0.4545	0.6583	<u>0.7925</u>
TK	0.3364	0.5125	0.5667	0.5273	0.6333	0.7425
TGC	0.5818	0.5125	0.4788	0.4455	0.6083	0.7550
SPT-C	<u>0.5864</u>	0.8500	<u>0.6727</u>	0.7182	0.6167	0.3550
ASAM	0.4000	0.7750	0.4727	0.6818	0.6000	0.6625
TIG	0.2000	0.5250	0.3758	0.4636	0.4583	0.6175
MLI	0.5818	0.5125	0.5091	0.4545	0.6458	<u>0.7925</u>
DGCN	0.4591	<u>0.9625</u>	0.6303	0.7255	<u>0.6833</u>	0.3775
MCNN	0.7864	0.9750	0.7333	<u>0.7191</u>	0.6875	0.8825
Improved/%	34.1	1.3	9.0	-0.9	0.6	11.4

不同方法的皮尔森相关性系数实验结果如表 5 所列。在 HT2009 数据集上,MCNN 的皮尔森相关性系数几乎与 DGCN 一致,在其他数据集上保持了最优值,在 HS2013 数据集上相比次优方法的提升率最大,提升了 9.3%。这表明,在线性相关性上,MCNN 预测的节点重要性和真实节点重要性的匹配程度更高。

综合分析以上 3 个对比实验发现,MCNN 在 InVS15, HS2013 和 SFHH 数据集上的表现最好,在 HC,HT2009 和 PS 数据集上的表现次之。根据表 1 给出的统计属性进行分析,原采样快照数越多,说明被压缩后的时序网络的每个快照

的边数越多,且快照和快照间的变化越大,有助于空间结构特征和时间耦合特征的提取。节点联系次数和聚合静态图边数越多,表明节点间的互动频率越多,有助于时空传播特征的提取。节点数越多,也表明网络复杂度高,有利于所有特征的提取。而 InVS15 拥有最多的原采样快照数、节点联系次数和聚合静态图边数,HS2013 拥有次多的节点数和节点联系次数,SFHH 拥有最多的节点数和次多的聚合静态图边数。因此,在这 3 个数据集上 MCNN 可以取得更优的性能。而 HT2009 数据集上的节点数和聚合静态图边数较少,且节点联系次数最少,因此 MCNN 在该数据集上的性能略低。

表5 各个方法和 SIR 模型得到节点分数的皮尔森相关性系数

Table 5 Pearson correlation coefficients of node scores obtained by each method and SIR model

Methods	InVS15	HC	HS2013	HT2009	PS	SFHH
TDC	<u>0.8802</u>	0.7459	0.7958	0.6479	0.7954	0.9029
TK	0.7416	0.7571	0.8008	0.6518	0.7742	0.8646
TGC	0.8723	0.7380	0.7528	0.6368	0.7449	0.8921
SPT-C	0.6074	0.9728	0.8397	0.9202	0.8508	0.6286
ASAM	0.5622	0.8113	0.7042	0.8245	0.7694	0.8421
TIG	0.6920	0.6242	0.6694	0.5971	0.6393	0.7891
MLI	0.8767	0.7444	0.7959	0.6462	0.7928	<u>0.9032</u>
DGCN	0.5692	<u>0.9789</u>	<u>0.8459</u>	0.9261	<u>0.8589</u>	0.5952
MCNN	0.9385	0.9815	0.9249	<u>0.9258</u>	0.8626	0.9316
Improved/%	6.6	0.3	9.3	-0.0	0.4	3.1

4.4.3 消融实验

为验证 MCNN 中设计的几个主要模块的作用,进行了消融实验。MCNN 的几个变体如下:1) w/o S, 移除空间特征矩阵;2) w/o T, 移除时间特征矩阵;3) w/o ST, 移

除时空特征矩阵;4) w/o S_T, 移除空间和时间特征矩阵;5) w/o S_ST, 移除空间和时空特征矩阵;6) w/o T_ST, 移除时间和时空特征矩阵;7) w/o CNN, 移除 CNN 模块;8) w/o SA, 移除自注意力机制模块;9) w/o LSTM, 移除 LSTM

模块。实验结果如表 6—表 8 所列。

如表 6—表 8 所列,从三类节点特征来看,保留一类特征和两类特征在 3 个评价指标上的表现均不如 MCNN,因此节点的空间结构、时间耦合和时空传播特征在 MCNN 识别关键时序网络关键节点中都是必要的信息。从表 6 可以看出,MCNN 的平均肯德尔系数相比于 w/o S, w/o T 和 w/o ST 分别提升 68.9%, 53.6% 和 48.8%, 因此从三类特征对于 MCNN 的重要性来看,空间结构特征是最重要的,其次是时间耦合特征和时空传播特征。这也从侧面证实了自注意力机制模块为特征分配权重的必要性。

表 6 InVS15 上 MCNN 及其变体的肯德尔系数

Table 6 Kendall's τ coefficients for MCNN and its variants on InVS15

β	MCNN	w/o S	w/o T	w/o ST	w/o S_T	w/o S_ST	w/o T_ST	w/o CNN	w/o SA	w/o LSTM
0.01	0.8192	0.5803	0.6286	0.6466	0.5583	0.5693	0.5557	0.5626	0.5699	0.6896
0.02	0.8360	0.5529	0.5970	0.6152	0.5302	0.5411	0.5280	0.5351	0.5417	0.7113
0.03	0.8434	0.5241	0.5704	0.5860	0.5003	0.5124	0.4998	0.5070	0.5130	0.7282
0.04	0.8367	0.4938	0.5384	0.5553	0.4701	0.4817	0.4706	0.4773	0.4823	0.7364
0.05	0.8311	0.4747	0.5207	0.5366	0.4511	0.4628	0.4509	0.4575	0.4636	0.7444
0.06	0.8248	0.4591	0.5069	0.5227	0.4356	0.4474	0.4350	0.4424	0.4480	0.7455
0.07	0.8186	0.4451	0.4945	0.5124	0.4219	0.4339	0.4216	0.4283	0.4347	0.7463
0.08	0.8104	0.4418	0.4920	0.5101	0.4182	0.4299	0.4180	0.4254	0.4305	0.7424
0.09	0.8054	0.4429	0.4966	0.5132	0.4201	0.4313	0.4200	0.4278	0.4319	0.7371
0.10	0.7914	0.4494	0.5044	0.5228	0.4255	0.4376	0.4254	0.4346	0.4386	0.7231

表 7 InVS15 上 MCNN 及其变体的前 10% 命中率

Table 7 Top10% HR for MCNN and its variants on InVS15

β	MCNN	w/o S	w/o T	w/o ST	w/o S_T	w/o S_ST	w/o T_ST	w/o CNN	w/o SA	w/o LSTM
0.01	0.8182	0.6818	0.8182	0.7273	0.5909	0.6818	0.6364	0.7273	0.6818	0.4091
0.02	0.8182	0.5455	0.6818	0.5455	0.5000	0.5455	0.5000	0.5455	0.5455	0.5455
0.03	0.8636	0.6818	0.7727	0.6818	0.5909	0.6364	0.5909	0.6818	0.6364	0.4545
0.04	0.8636	0.6364	0.7727	0.6818	0.5455	0.5909	0.5455	0.6364	0.5909	0.5000
0.05	0.7727	0.5909	0.7273	0.5909	0.5000	0.5909	0.5455	0.6364	0.5909	0.5000
0.06	0.7273	0.5000	0.5909	0.5455	0.4091	0.5000	0.4545	0.5455	0.5000	0.5000
0.07	0.8182	0.5909	0.6818	0.6364	0.5000	0.5909	0.5455	0.6364	0.5909	0.5000
0.08	0.6818	0.4545	0.5909	0.5000	0.4091	0.4545	0.4091	0.5000	0.4545	0.5455
0.09	0.7273	0.5000	0.6364	0.5455	0.4545	0.5000	0.4545	0.5455	0.5000	0.5000
0.10	0.7727	0.5455	0.6818	0.5909	0.5000	0.5455	0.5000	0.5909	0.5455	0.5455

表 8 InVS15 上 MCNN 及其变体的皮尔森相关性系数

Table 8 Pearson correlation coefficients for MCNN and its variants on InVS15

β	MCNN	w/o S	w/o T	w/o ST	w/o S_T	w/o S_ST	w/o T_ST	w/o CNN	w/o SA	w/o LSTM
0.01	0.9150	0.7560	0.8189	0.8255	0.7443	0.7471	0.7378	0.7505	0.7490	0.8619
0.02	0.9397	0.7088	0.7714	0.7804	0.6995	0.7001	0.6942	0.7054	0.7024	0.8859
0.03	0.9468	0.6735	0.7401	0.7487	0.6621	0.6648	0.6582	0.6698	0.6670	0.8971
0.04	0.9502	0.6295	0.6968	0.7087	0.6179	0.6203	0.6140	0.6257	0.6225	0.9029
0.05	0.9466	0.6031	0.6763	0.6874	0.5905	0.5930	0.5865	0.6000	0.5953	0.9061
0.06	0.9465	0.5835	0.6600	0.6706	0.5712	0.5733	0.5664	0.5803	0.5756	0.9077
0.07	0.9428	0.5641	0.6448	0.6565	0.5506	0.5529	0.5462	0.5613	0.5554	0.9089
0.08	0.9378	0.5605	0.6454	0.6559	0.5470	0.5493	0.5433	0.5589	0.5519	0.9060
0.09	0.9341	0.5591	0.6485	0.6579	0.5453	0.5475	0.5416	0.5582	0.5501	0.9044
0.10	0.9258	0.5621	0.6561	0.6644	0.5475	0.5502	0.5440	0.5613	0.5528	0.8988

4.4.4 扩展实验

在时空特征矩阵构建中,除了采用传播时间外,还可以采用传播距离和传播路径数量描述传播关系,本实验考察不同时空特征构建方式对 MCNN 的影响。将采用传播距离的 MCNN 记为 MCNN_d,采用传播路径数量的 MCNN 记为 MCNN_n,与基线方法和 MCNN 进行肯德尔系数对比。实验中 SIR 模型的感染率为 0.01。实验结果如表 9 所列。其中,

从模型功能上看,与 MCNN 相比,在 3 个指标上, w/o CNN, w/o SA, w/o LSTM 均显著下降。这说明 CNN、自注意力机制和 LSTM 对于 MCNN 分别提取节点三类特征、处理特征异质性有效融合特征和进一步提取节点时序特征具有重要作用。

综上所述,MCNN 由于同时在空间、时间和时空 3 个维度构建节点特征矩阵,并且通过 CNN、自注意力和 LSTM 构建的动态注意力卷积网络依次提取节点快照特征和快照序列特征,全面的空间结构关联、时间耦合依赖与时空传播演化信息,大幅提升了时序网络关键节点识别能力。

MCNN 及其扩展变体的最优值用粗体表示,基线方法中的最优值用下划线表示,Improved 为 MCNN 及其变体的最优值相对于最优基线方法的提高比例。

如表 9 所列,在 6 个数据集上,MCNN,MCNN_d 和 MCNN_n 都分别在两个数据集上取得了最佳表现,尤其在 InVS15 和 HS2013 数据集上,MCNN_d 大幅度超过了最优基线方法。这说明基于传播距离以及传播路径数量分析时空特

征对于 MCNN 也是有效的,证明了 MCNN 具有较好的扩展性。

为了进一步验证时空特征矩阵构建中,综合考虑传播时间、传播距离和传播路径数量对模型性能的影响,采用加权的

方式构建时空特征矩阵,在 HC 数据集上进行肯德尔系数实验。实验结果取所有感染率下的平均值,如表 10 所列。其中, $\omega_0, \omega_1, \omega_2 \in \{0.0, 0.2, 0.4, 0.6, 0.8, 1.0\}$ 是权重系数。由于组合数量过多,本实验仅展示最优的前五组数据。

表 9 MCNN 及其扩展变体与基线方法的肯德尔系数

Table 9 Kendall's τ coefficients for MCNN and its extended variants and baselines

Methods	InVS15	HC	HS2013	HT2009	PS	SFHH
TDC	<u>0.6683</u>	0.5749	0.6131	0.5318	0.5315	0.6755
TK	0.4935	0.5870	0.5966	0.5274	0.5052	0.6270
TGC	0.6541	0.5741	0.5813	0.5212	0.4889	0.6670
SPT-C	0.5573	<u>0.7604</u>	0.6162	0.7563	<u>0.7772</u>	0.4874
ASAM	0.5441	0.5177	0.4617	0.5407	0.5131	<u>0.7395</u>
TIG	0.4787	0.5380	0.4894	0.4901	0.3967	0.6092
MLI	0.6643	0.5748	0.6137	0.5262	0.5293	0.6729
DGCN	0.5567	0.7456	<u>0.6425</u>	<u>0.7687</u>	0.7694	0.4664
MCNN	0.8192	0.8054	0.8023	0.7645	0.7079	0.7614
MCNN _d	0.8644	0.7960	0.8088	0.7661	0.7638	0.7548
MCNN _n	0.6369	0.7592	0.7357	0.7842	0.8042	0.6002
Improved/%	29.3	5.9	25.9	2.0	3.5	3.0

如表 10 所列,最优结果出现在 ω_0 和 ω_1 较高时。

表 10 HC 上不同权重时空特征的肯德尔系数

Table 10 Kendall's τ coefficients for different weight spatio-temporal features on HC

ω_0	ω_1	ω_2	K
0.0	0.6	0.4	0.7942
0.0	0.8	0.2	0.8014
0.0	1.0	0.0	0.8272
0.6	0.4	0.0	0.8324
1.0	0.0	0.0	0.8370

这表明在 HC 数据集上,传播时间和传播距离对于时空特征的表达更为重要,而传播路径数量不占主导地位。同时,

对比表 3 可知,在加权组合三类时空特征后,其表现依然超过了基线方法。因此,针对不同数据集,可以通过动态调整三类时空特征的权重进行更有效的关键节点识别。

4.4.5 模型组件实验

在 MCNN 中,采用 CNN、自注意力机制和 LSTM 进行特征的提取和融合。为了验证各个组件的有效性,与以下模型变体进行对比实验:1) w/ Densenet,将 CNN 模块替换为 Densenet 模块;2) w/ ECA,将自注意力模块替换为 ECA 模块;3) w/ Transformer,将 LSTM 模块替换为 Transformer 模块。评价指标取肯德尔系数,实验结果取所有感染率下的平均值,如表 11 所列。

表 11 MCNN 及其组件变体的肯德尔系数

Table 11 Kendall's τ coefficients for MCNN and its component variants

Methods	InVS15	HC	HS2013	HT2009	PS	SFHH
w/ Densenet	0.4763	0.7469	<u>0.6542</u>	0.8120	0.7259	0.5141
w/ ECA	0.4805	<u>0.7879</u>	0.6483	<u>0.8082</u>	<u>0.7632</u>	0.5082
w/ Transformer	<u>0.7049</u>	0.5449	0.5239	0.4639	0.4825	<u>0.5262</u>
MCNN	0.8217	0.8370	0.8475	0.8041	0.7659	0.7950

如表 11 所列,除了在 HT2009 数据集上,w/ Densenet 和 w/ ECA 的肯德尔系数略高于 MCNN 外,在其他数据集上,MCNN 都取得了最优值。从 3 个模块上看,MCNN 在所有数据集上平均分别比 w/ Densenet, w/ ECA 和 w/ Transformer 提升 24.0%, 21.9%, 50.1%。可见,MCNN 中采用的 CNN、自注意力机制和 LSTM 是有效的。

4.4.6 大规模数据集实验

为了验证 MCNN 模型在更大规模的时序社交网络数据

集上识别关键节点的准确性,本实验在一个大规模数据集 Dublin 上对 MCNN 进行肯德尔系数实验。Dublin 是一个物理世界的人类接触网络,其统计属性如表 12 所列。实验结果如表 13 所列,avg 表示平均值。

表 12 Dublin 的统计属性

Table 12 Statistical properties of Dublin

网络	n	T	C	E
Dublin	10972	76944	415912	44517

表 13 Dublin 上 MCNN 及基线的肯德尔系数

Table 13 Kendall's τ coefficients for MCNN and baselines on Dublin

β	TDC	TK	TGC	SPT-C	TIG	MLI	DGCN	MCNN
0.01	0.3578	0.3510	0.3154	0.5059	0.3229	0.3374	<u>0.7301</u>	0.7422
0.02	0.3600	0.3510	0.3116	0.5010	0.3197	0.3373	<u>0.7775</u>	0.7883
0.03	0.3611	0.3512	0.3108	0.4764	0.3201	0.3385	<u>0.7935</u>	0.8036
0.04	0.3643	0.3527	0.3111	0.4579	0.3200	0.3402	<u>0.8002</u>	0.8110
0.05	0.3670	0.3545	0.3125	0.4459	0.3218	0.3426	<u>0.8062</u>	0.8175

(续表)

β	TDC	TK	TGC	SPT-C	TIG	MLI	DGCN	MCNN
0.06	0.3677	0.3546	0.3123	0.4442	0.3216	0.3427	<u>0.8087</u>	0.8198
0.07	0.3713	0.3574	0.3144	0.4235	0.3239	0.3456	<u>0.8092</u>	0.8213
0.08	0.3725	0.3577	0.3147	0.4251	0.3243	0.3465	<u>0.8110</u>	0.8228
0.09	0.3725	0.3575	0.3149	0.4311	0.3242	0.3467	<u>0.8121</u>	0.8241
0.10	0.3742	0.3585	0.3155	0.4444	0.3246	0.3477	<u>0.8139</u>	0.8261
avg	0.3668	0.3546	0.3133	0.4555	0.3223	0.3425	<u>0.7962</u>	0.8077

可以看到,在Dublin数据集上,MCNN的表现更好,在所有感染率下均取得了最优值,平均比次优方法DGCN提升了1.4%。可见,MCNN具有节点特征维度的多样性,以及特征提取方法的多样性,使其在大规模时序社交网络数据集上能更好地挖掘节点特征,更准确地识别关键节点。

4.5 讨论

综合以上实验,MCNN融合空间、时间和时空特征,具有很强的时序社交网络关键节点识别能力。从MCNN拥有的三类特征来分析其他方法,可以发现,TDC和TK是传统中心性方法的时序版本,以所有快照上的静态中心性的平均值或和作为节点影响力,仅考虑了空间结构关系。TGC是重力模型的时序版本,引入了时间路径,仅考虑了空间结构关系和时空传播关系。SPT-C是基于顺序路径树的中心性度量方法,考虑了3个特征,但这3个特征均只考虑了时空传播关系。ASAM是基于超邻接矩阵的方法,仅考虑了空间结构关系和时间耦合关系。TIG,MLI,DGCN采用了网络嵌入的方法,但TIG在提取节点特征时未考虑时间耦合关系,MLI仅考虑了空间结构关系,DGCN将MLI处理时间序列的加权方法改进为LSTM模型,但仍然只考虑了空间结构关系。可见,MCNN弥补了这些方法仅从空间、时间、时空某个或者某两个维度分析节点特征的缺点,从3个维度基于快照建模时序网络分析节点特征,因此得到了更好的时序社交网络关键节点识别性能。

结束语 时序社交网络关键节点识别对于控制社交网络信息的传播具有重要的现实意义。为了提高时序社交网络关键节点识别的准确性,本文提出了一个基于深度学习和多特征融合的方法MCNN。该方法综合考虑了3个维度的节点关系,将时序网络建模为基于快照的多维关系网络,并从节点的空间结构关系、时间耦合关系以及时空传播关系,提取空间、时间和时空上下文并构建对应节点特征矩阵。采用CNN深度挖掘节点特征并采用自注意力机制融合得到节点快照特征,采用LSTM深度挖掘快照序列特征,最后使用全连接层预测节点影响力。在6个真实时序社交网络上的评估实验表明,MCNN的关键节点识别能力高于基线方法。

本文提出了一种新的节点特征表示方法,但在应用于大规模网络时仍然面临效率挑战。当前方法对于每一节点在每一快照下构造时空特征矩阵时,需要计算该节点和所有节点间的最快到达路径,因此整体复杂度较高。未来,可以进一步优化时空特征矩阵构造的时间复杂度,包括考虑:1)采用更高效的图算法优化路径计算;2)重用多个相邻快照的路径信息以减少重复计算;3)实现节点级或快照级的并行处理,使该方法在应用于大规模网络时效率更高。此外,现实社交网络普遍具备多层级的拓扑交互特性,将本研究拓展至多层社交

网络场景^[51],可作为后续研究的重要方向之一。

参考文献

- [1] WEI P C, ZHOU J H, YAN B, et al. ENIMNR: Enhanced node influence maximization through node representation in social networks [J]. *Chaos, Solitons & Fractals*, 2024, 186: 115192.
- [2] MENG L, XU G Q, DONG C, et al. Modeling information propagation for target user groups in online social networks based on guidance and incentive strategies [J]. *Information Sciences*, 2025, 691: 121628.
- [3] FOROOZANI A, EBRAHIMI M. Nonlinear anomalous information diffusion model in social networks [J]. *Communications in Nonlinear Science and Numerical Simulation*, 2021, 103: 106019.
- [4] ZHOU Y M, WANG G Z, HAO J K, et al. A fast tri-individual memetic search approach for the distance-based critical node problem [J]. *European Journal of Operational Research*, 2023, 308(2): 540-554.
- [5] AN Z Y, HU X H, JIANG R X, et al. A novel method for identifying key nodes in multi-layer networks based on dynamic influence range and community importance [J]. *Knowledge-Based Systems*, 2024, 305: 112639.
- [6] HU Q, JIANG J T, XU H F, et al. IMNE: Maximizing influence through deep learning-based node embedding in social network [J]. *Swarm and Evolutionary Computation*, 2024, 88: 101609.
- [7] WU J, QIU T, CHEN G. A general deep-learning approach to node importance identification [J]. *Chaos, Solitons & Fractals*, 2024, 188: 115501.
- [8] ZHAO M, YE J H, LI J Y, et al. NRD: A node importance evaluation algorithm based on neighborhood reliance degree for power networks [J]. *Physica A: Statistical Mechanics and Its Applications*, 2023, 624: 128941.
- [9] ZHAO S Y, SUN S W. Identification of node centrality based on Laplacian energy of networks [J]. *Physica A: Statistical Mechanics and its Applications*, 2023, 609: 128353.
- [10] YANG P L, MENG F Y, ZHAO L J, et al. AOGC: An improved gravity centrality based on an adaptive truncation radius and omni-channel paths for identifying key nodes in complex networks [J]. *Chaos, Solitons & Fractals*, 2023, 166: 112974.
- [11] XU G Q, DONG C. CAGM: A communicability-based adaptive gravity model for influential nodes identification in complex networks [J]. *Expert Systems with Applications*, 2024, 235: 121154.
- [12] SAUMYA S, KUMAR A, SINGH J P. Filtering offensive language from multilingual social media contents: A deep learning approach [J]. *Engineering Applications of Artificial Intelligence*, 2024, 133: 108159.

- [13] ZHANG M,WANG X J,JIN L,et al. A new approach for evaluating node importance in complex networks via deep learning methods [J]. *Neurocomputing*,2022,497:13-27.
- [14] KOU J H,JIA P,LIU J Y,et al. Identify influential nodes in social networks with graph multi-head attention regression model [J]. *Neurocomputing*,2023,530:23-36.
- [15] KUMAR S,MALLIK A,PANDA B S. Influence maximization in social networks using transfer learning via graph-based LSTM [J]. *Expert Systems with Applications*, 2023, 212: 118770.
- [16] ACOSTA A,CARDENAS N C,IMBACUAN C,et al. Modelling control strategies against classical swine fever; Influence of traders and markets using static and temporal networks in Ecuador [J]. *Preventive Veterinary Medicine*,2022,205:105683.
- [17] KIM H,ANDERSON R. Temporal node centrality in complex networks [J]. *Physical Review E*,2012,85:026107.
- [18] YE Z H,ZHAN X X,ZHOU Y Z,et al. Identifying vital nodes on temporal networks: An edge-based k-shell decomposition [C]//*Proceedings of the 36th Chinese Control Conference(CCC 2017)*. New York:IEEE,2017:1402-1407.
- [19] BI J L,JIN J,QU C Q,et al. Temporal gravity model for important node identification in temporal networks [J]. *Chaos, Solitons & Fractals*,2021,147:110934.
- [20] TAO L,KONG S Z,HE L Z,et al. A sequential-path tree-based centrality for identifying influential spreaders in temporal networks [J]. *Chaos,Solitons & Fractals*,2022,165:112766.
- [21] TAYLOR D,MYERS S A,CLAUSET A,et al. Eigenvector-based centrality measures for temporal networks [J]. *Multiscale Modeling & Simulation*,2017,15(1):537-574.
- [22] YIN R R,GUO Q,YANG J N,et al. Inter-layer similarity-based eigenvector centrality measures for temporal networks [J]. *Physica A: Statistical Mechanics and Its Applications*, 2018, 512:165-173.
- [23] JIANG J L,FANG H,LI S Q,et al. Identifying important nodes for temporal networks based on the ASAM model [J]. *Physica A: Statistical Mechanics and Its Applications*, 2022, 586: 126455.
- [24] QU C Q,ZHAN X X,WANG G H,et al. Temporal information gathering process for node ranking in time-varying networks [J]. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 2019,29(3):033116.
- [25] SONG Q,ZONG B,WU Y H,et al. Tgnet: Learning to rank nodes in temporal graphs [C]//*Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. New York:ACM,2018:97-106.
- [26] YU E Y,FU Y,CHEN X,et al. Identifying critical nodes in temporal networks by network embedding [J]. *Scientific Reports*,2020,10:12494.
- [27] YU E Y,FU Y,ZHOU J L,et al. Predicting critical nodes in temporal networks by dynamic graph convolutional networks [J]. *Applied Sciences*,2023,13(12):7272.
- [28] YAN M X,HAN Y X,WANG B. NFI-SGAT: Node feature initialization-based streaming graph learning model with graph attention network for critical node identification in temporal networks [J]. *Neurocomputing*,2025,630:129679.
- [29] AHMAD W,WANG B. A neural diffusion model for identifying influential nodes in complex networks [J]. *Chaos, Solitons & Fractals*,2024,189:115682.
- [30] DONG X F,YE L T,LIAN Y. Who has dominated information spreading on social media during the early stage of COVID-19 pandemic in China? A temporal network analysis [J]. *International Journal of Disaster Risk Reduction*,2024,107:104493.
- [31] LI H Y,ZHANG T,ZHANG Y K,et al. A maximum flow algorithm based on storage time aggregated graph for delay-tolerant networks [J]. *Ad Hoc Networks*,2017,59:63-70.
- [32] GUNTURI V M V,SHEKHAR S,JOSEPH K,et al. Scalable computational techniques for centrality metrics on temporally detailed social network [J]. *Machine Learning*,2017,106:1133-1169.
- [33] HAFIENE N,KAROUI W,ROMDHANE L B. Influential nodes detection in dynamic social networks: A survey [J]. *Expert Systems with Applications*,2020,159:113642.
- [34] WU H H,CHENG J,HUANG S L,et al. Path problems in temporal graphs [J]. *Proceedings of the VLDB Endowment*,2014, 7(9):721-732.
- [35] MA Z H,LI L Y,HEMPHILL L,et al. Investigating disaster response for resilient communities through social media data and the Susceptible-Infected-Recovered(SIR) model: A case study of 2020 Western U. S. wildfire season [J]. *Sustainable Cities and Society*,2024,106:105362.
- [36] ZHANG H G,ZHANG D P,WAN Y,et al. Multiplex network influence maximization based on representation learning method [J]. *Applied Soft Computing*,2025,174:112956.
- [37] YU E Y,WANG Y P,FU Y,et al. Identifying critical nodes in complex networks via graph convolutional networks [J]. *Knowledge-Based Systems*,2020,198:105893.
- [38] ZHAO G H,JIA P,ZHOU A M,et al. InfGCN: Identifying influential nodes in complex networks with graph convolutional networks [J]. *Neurocomputing*,2020,414:18-26.
- [39] MA T H,WANG H M,ZHANG L J,et al. Graph classification based on structural features of significant nodes and spatial convolutional neural networks [J]. *Neurocomputing*, 2021, 423: 639-650.
- [40] CHEN J F,XIE H D,CAI S H,et al. GCN-MHSA: A novel malicious traffic detection method based on graph convolutional neural network and multi-head self-attention mechanism [J]. *Computers & Security*,2024,147:104083.
- [41] AHMED I,AHMAD M,CHEHRI A,et al. A heterogeneous network embedded medicine recommendation system based on LSTM [J]. *Future Generation Computer Systems*,2023,149:1-11.
- [42] OU Y,GUO Q,XING J L,et al. Identification of spreading influence nodes via multi-level structural attributes based on the graph convolutional network [J]. *Expert Systems with Applications*,2022,203:117515.
- [43] TOCINO A,SERRANO D H,HERNANDEZ-SERRANO J,

- et al. A stochastic simplicial SIS model for complex networks [J]. *Communications in Nonlinear Science and Numerical Simulation*, 2023, 120: 107161.
- [44] GALLO L, LACASA L, LATORA V, et al. Higher-order correlations reveal complex memory in temporal hypergraphs [J]. *Nature Communications*, 2024, 15: 4754.
- [45] NEUHAUSER L, SCHOLKEMPER M, TUDISCO F, et al. Learning the effective order of a hypergraph dynamical system [J]. *Science Advances*, 2024, 10(19): adh4053.
- [46] WU J Y, HE L Z, JIA T, et al. Temporal link prediction based on node dynamics [J]. *Chaos, Solitons & Fractals*, 2023, 170: 113402.
- [47] CENCETTI G, LUCCHINI L, SANTIN G, et al. Temporal clustering of social interactions trades-off disease spreading and knowledge diffusion [J]. *Journal of The Royal Society Interface*, 2024, 21(210): 20230471.
- [48] OUACHENE N, KIESSÉ T S, CORSON M S. Using conditional Kendall's tau estimation to assess interactions among variables in dairy-cattle systems [J]. *Agricultural Systems*, 2024, 220: 104089.
- [49] YANG Y, WU J, SONG X M, et al. Data-driven quasi-convex method for hit rate optimization of process product quality in digital twin [J]. *Journal of Industrial Information Integration*, 2024, 41: 100610.
- [50] TSERKIS S, ASSAD S M, LAM P K, et al. Quantifying total correlations in quantum systems through the Pearson correlation coefficient [J]. *Physics Letters A*, 2025, 543: 130432.
- [51] CAO C P, LIAO Z N, YANG Y L. Maximizing Influence in Multilayer Networks Based on Node Ideology Combined with Invisible Community Detection [J]. *Journal of Chinese Computer Systems*, 2025, 46(9): 2283-2290.



ZHANG Xueqin, born in 1972, professor. Her main research interests include information security, complex network and artificial intelligence.



WANG Zhineng, born in 2000, master. His main research interests include information security and complex network.

(责任编辑:何杨)