

群体认知异常：发现与判定技术综述

高阳, 刘立坤, 张宏莉

(哈尔滨工业大学计算学部, 黑龙江 哈尔滨 150001)

摘要: 认知安全是网络空间安全领域的新兴方向, 群体认知安全是其中的学术前沿。为总结分析其中的核心技术方法, 将群体认知安全分为群体发现和群体异常检测两个子任务, 前者主要借助社区发现技术, 后者主要利用图异常检测技术。将社区发现分为局部社区发现和全局社区结构识别, 将图异常分为节点/边级异常和子图/全图级异常。系统综述其中的核心概念、基础理论和代表性方法, 比较分析现有方法的优点与不足, 并展望了未来的研究方向。

关键词: 群体认知安全; 群体识别; 群体异常检测

中图分类号: TP391

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2026024

Collective cognitive anomalies: a survey of techniques for detection and assessment

Gao Yang, Liu Likun, Zhang Hongli

Faculty of Computing, Harbin Institute of Technology, Harbin 150001, China

Abstract: Cognitive security is recognized as an emerging direction in cyberspace security, with collective cognitive security identified as its academic frontier. To systematically summarize and analyze the main methods, collective cognitive security was divided into two subtasks group detection and group anomaly detection. The former primarily utilizes community detection techniques, while the latter mainly relies on graph anomaly detection methods. Community detection was categorized into local community detection and global community detection, whereas graph anomalies were classified into node/edge-level anomalies and subgraph/graph-level anomalies. Main concepts, fundamental theories, and representative methods were systematically reviewed, with comparative analyses conducted to evaluate the strengths and limitations of existing approaches. Future research directions were also prospected.

Keywords: collective cognitive security, group detection, group anomaly detection

0 引言

在网络空间安全领域, 认知异常指个体或群体的认知过程(包括信息处理、判断与决策)受到系统性、有目的的恶意干扰, 如人工智能生成虚假内容、算法操纵与信息茧房强化、认知战与叙事控制、协同造势与舆论压制等, 导致其安全观念、风

险感知与行为模式持续偏离客观现实或公认的安全准则, 并倾向于支持或认同那些对其自身、组织乃至国家网络安全构成实质危害的错误立场。其中前者一般称为个体认知异常, 后者常称为群体认知异常。

随着人工智能技术在社交网络中的广泛应用,

收稿日期: 2025-11-28; 修回日期: 2026-01-26

通信作者: 高阳, csgaoyang@hit.edu.cn

基金项目: 黑龙江省自然科学基金资助项目(No.LH2023F018); 中央高校基本科研业务费专项资金资助项目

Foundation Items: The Natural Science Foundation of Heilongjiang Province (No.LH2023F018), The Fundamental Research Funds for the Central Universities

以保护网络用户正确认知为目的的认知安全逐渐成为网络空间安全领域的核心研究方向^[1]。社交网络平台极大地加速了社会网络中信息的传播,已成为人们传递情感、观点与诉求的基本渠道^[2]。社交网络具有聚簇效应,针对突发/热点社会事件,网络个体常容易形成统一情感与观点,并相互作用形成网络群体。网络群体作为一种介于网络用户和宏观网络之间的中观结构,已成为连接用户个体情感与网络舆论的桥梁,是决定网络舆情形成与扩散的基本单位。因此,准确把握群体认知是理解和引导网络舆情态势、构建健康网络生态的重要技术手段。

目前,认知安全领域的研究已取得初步进展,已有若干文献对这一新兴研究方向进行了探索性研究^[3],其中包含少量面向群体认知安全的专题研究成果^[4-6]。文献[4]面向人工智能生成内容(artificial intelligence generated content, AIGC)环境下的群体认知安全问题,从多学科视角出发,阐述了认知入侵的相关概念,提出了群体认知入侵模型,利用数值仿真技术对入侵过程进行了量化分析,并给出了相应入侵防范策略。文献[5]面向认知战环境,从认知操纵和认知觉醒等方面阐述了群体认知的演化,并建立了群体认知演化模型。文献[6]采用文献综述和调研等方式,研究了面向群体目标的认知攻防策略。然而,这些研究主要从社会科学的角度的进行建模,多局限于小规模样本分析,缺乏对社交网络中海量数据的处理能力。

值得关注的是,当前图数据挖掘与图深度学习技术的迅猛发展,为群体认知安全研究提供了全新的技术路径。一方面,现有社区发现方法可高效识别大规模社交网络中的目标群体和群体结构,为群体认知安全分析提供基础数据;另一方面,图神经网络(graph neural network, GNN)^[7]等深度学习模型在处理图结构数据时展现出显著优势,可有效捕捉群体拓扑结构、群体内部个体之间和群体之间复杂的交互特征,能够有效检测群体的异常模式。然而,当前缺乏面向群体认知安全这一特定应用场景的相关技术方法的总结分析。为此,本文面向社交网络平台,从群体发现和群体异常检测两方面对群体认知安全相关技术模型进行综述。

1 群体发现

随着互联网技术的飞速发展,社交网络已成为

信息传播与观点交互的主要载体。作为复杂网络理论的典型代表,社交网络具有无标度性^[8]、小世界效应^[9]、聚簇效应^[10-14]等诸多特性。其中聚簇效应指网络用户常自组织地形成各种群体,群体内部用户之间连接紧密,群体之间的连接相对稀疏。针对某一热点社会事件,同一群体内部用户常具有相对统一的观点、意见或诉求。因此,在认知安全领域,最新研究常将群体作为异常检测的基本单元,极大地提高了分析效率。在学术界,网络群体常被称为网络社区,社区发现已成为分析社交网络拓扑结构与社会学性质的基础方法,相关理论技术已相对完备,本文主要总结分析其中可应用于群体认知的代表性工作。

1.1 相关概念

在复杂网络分析中,社区的定义根据数据类型呈现显著差异:对于无属性网络,社区一般指在拓扑结构上连接紧密的节点集合,数学表征为内部边密度显著高于网络平均水平,典型实例包括社交网络中基于现实关系或兴趣自发形成的群组,如QQ群、微信群等;在包含节点属性信息的网络中,社区除需保证结构紧致以外,内部节点还需具有相对一致的属性,如具有相似的社会身份、相同的兴趣爱好等。

传统的社区发现也称为图分割,旨在对网络拓扑进行区域划分,获取网络中的所有社区。鉴于真实网络的规模逐步扩大,而下游任务常仅需网络中的特定社区,近年来出现了局部社区发现的概念。局部社区发现也称为社区搜索,一般指识别包含指定节点/节点集的单一目标社区。为有效区分,本文将传统社区发现任务称为全局社区结构识别。

给定网络 $G(V, E)$, V 表示网络包含的节点集合, E 表示网络包含的边集合,本文用 $m = |E|$ 表示网络中边的数量,用 $n = |V|$ 表示网络中节点的数量。上述两种社区发现任务形式化定义如下。

定义1 全局社区结构识别。给定网络 G ,传统社区发现旨在捕获网络中的所有社区 C_1, \dots, C_k ,使 $C_1 \cup \dots \cup C_k \subset V$ 。其中, k 表示网络中包含的社区数量,社区之间可包含共有节点,称为重叠社区结构。定义中虽未规定所有网络节点均需在社区中,但一般要求全局社区结构对网络拓扑形成高覆盖率。

定义2 局部社区发现。给定网络 G 和目标社

区 C 中的搜寻节点集 Q ($Q \subset C$)，局部社区发现旨在获取社区 C 中的所有节点。其中，节点集 Q 可仅包含单一搜寻节点，也可包含属于同一社区的多个目标节点。在群体认知安全领域，全局社区结构可为异常分析提供基础数据单元，局部社区发现可针对特定异常个体，捕获对应异常群体。面向两类社区发现任务，现有方法多通过优化选定社区指标来提取网络社区，本文也对常见社区指标函数进行总结。

定义 3 社区密度^[15-16]。给定网络社区 C ，社区密度 $\delta(C)$ 即对应网络子图密度，指子图内部节点之间边的数量 $|E_c|$ 与节点之间可容纳边最大数量的比值，即

$$\delta(C) = \frac{2|E_c|}{|C|(|C| - 1)} \quad (1)$$

定义 4 平均内部度^[15-16]。给定网络社区 C ，社区平均内部度 $\bar{d}_{in}(C)$ 指社区中节点内部度的平均值，可表示为

$$\bar{d}_{in}(C) = \frac{2|E_c|}{|C|} \quad (2)$$

定义 5 社区切割率^[16]。本文将连接社区 C 与外部节点的边称为社区的切割边，社区 C 的切割边集合记为 $L(C)$ ，社区的切割率 $\ell(C)$ 指切割边数量与社区与外部节点所有可能连边数量的比例，即

$$\ell(C) = \frac{|L(C)|}{|C|(n - |C|)} \quad (3)$$

定义 6 社区导率^[10, 17]。给定网络社区 C ，社区的导率 $\phi(C)$ 指社区切割边数量与社区内部节点总度和外部节点总度中较小值的比值，即

$$\phi(C) = \frac{|L(C)|}{\min(\text{vol}(C), \text{vol}(\bar{C}))} \quad (4)$$

其中， $\text{vol}(C)$ 表示社区 C 内部节点度值之和，也称为社区的体积， $\text{vol}(\bar{C})$ 表示社区外部节点的度值之和。在上述 4 个指标中，社区密度和平均内部度通过计算社区内部节点之间关联的紧密程度度量社区质量，较大值对应更优的目标社区；社区切割率和导率通过计算社区与外部结构之间的关联程度刻画社区的质量，较小值对应更优的目标社区。

1.2 局部社区发现

局部社区发现面向特定目标群体，相关方法常不依赖网络的整体结构，具有极低的计算需求，适

应社交网络的节点海量性。现有方法多单纯利用网络的拓扑结构信息，主要包括面向确定结构的方法和图扩散^[10, 18]方法；同时也有少量工作融合网络拓扑和节点属性信息，利用图神经网络框架识别特定目标社区。本文总结其中的代表性工作，并分析其在群体认知安全领域的应用。

1) 面向确定结构的方法

面向确定结构的方法一般将社区定义为具有特定结构的网络子图，如 k -core^[19-22]、 k -truss^[23-26] 和 k -clique^[27-28] 等。近期工作面向不同任务场景，常对上述基础子图结构进行调整，并构建对应识别方法，例如文献[19]将不确定网络中有影响力的社区定义为 (k, η) -core 结构，通过一种削皮剪枝策略逐步简化网络，从而识别有影响力的社区。文献[20]基于 (θ, k) -core 结构识别动态网络的局部社区，重点关注动态社区的连续性。文献[21]基于 (k, P) -core 结构识别异构信息网络 (heterogeneous information network, HIN) 中的影响力社区。文献[22]利用 (α, β) -core 结构识别二分网络中的显著社区。文献[23]基于 k -truss 结构识别属性网络中的局部社区，主要利用边的属性信息。文献[24]利用三角形连通 k -truss 结构识别动态网络中的局部社区。文献[25]将 k -truss 扩展到多层网络中，提出 FirmTruss 结构识别多层网络局部社区。文献[26]利用 k -truss 结构识别有规模限制的局部社区。文献[27]提出了加权网络中 k -clique 的识别方法，文献[28]提出了网络中 k -clique 包含率最高的子图识别方法，均可应用于局部社区发现任务中。

面向确定结构的方法旨在捕获网络中特定结构的子图，这些子图本身未必构成真实的功能性群体，但它们通常呈现出紧致的局部结构。这种特性使其往往成为更大规模群体的核心子结构，因此可作为分析认知不一致大规模群体的有效切入点。

2) 图扩散方法

图扩散方法识别包含指定节点/节点集的自然社区，旨在与真实社区相符，发现群体适合认知安全分析任务。相关方法一般利用图扩散技术将种子周围节点进行相关性排序，依据某种社区结构函数切割序列，从而确定目标社区。

给定无属性网络 $G(V, E)$ ，本文用 $A \in \mathbb{R}^{n \times n}$ 表示其邻接矩阵，用 d_u 表示节点 u 的度，用 $D \in \mathbb{R}^{n \times n}$ 表示邻接矩阵的对角矩阵，即

$$D_{uv} = \begin{cases} d_u, & u = v \\ 0, & u \neq v \end{cases} \quad (5)$$

用 $P \in \mathbb{R}^{n \times n}$ 表示图扩散的状态转移矩阵, 学术上常将 P 定义为 $P = D^{-1}A$, 也有工作采用惰性转移矩阵 $P = \frac{1}{2}(D^{-1}A + I)$ ^[10, 29]。

定义7 图扩散^[18]。给定网络 G 的状态转移矩阵 P , 随机向量 $s \in \mathbb{R}^n$ ($\sum_{k=1}^n s_k = 1, s_k \geq 0$), 以及系数向量 a ($\sum_{k=0}^{\infty} a_k = 1, a_k \geq 0$), 起始于向量 s 的图扩散向量 h 定义为

$$h = \sum_{k=0}^{\infty} a_k s P^k \quad (6)$$

常用图扩散方法主要包括个性化网页排名 (personalized pagerank, PPR)^[30-31] 和热核扩散^[18, 32], 主要不同在于系数向量 a 的设定。

定义8 个性化网页排名。给定状态转移矩阵 P , 随机向量 $s \in \mathbb{R}^n$, 以及转移概率 $\alpha \in (0, 1]$, 则式(7)称为 PPR 方程, 对应解 $h \in \mathbb{R}^n$ 称为相对于起始向量 s 的 PPR 向量。

$$h = \alpha s + (1 - \alpha) h P \quad (7)$$

式(7)的解 h 可精确表示为图扩散向量的形式, 即

$$h = \alpha \sum_{k=0}^{\infty} (1 - \alpha)^k s P^k \quad (8)$$

显然, PPR 向量为系数 $a_k = \alpha(1 - \alpha)^k$ 的图扩散向量。

定义9 热核扩散。给定状态转移矩阵 P , 随机向量 $s \in \mathbb{R}^n$, 以及参数 t , 热核向量 h 定义如下。

$$h = e^{-t} \sum_{k=0}^{\infty} \frac{t^k}{k!} s P^k \quad (9)$$

热核扩散将系数定义为 $a_k = \frac{e^{-t} t^k}{k!}$, 显然, 该系数具有更高的衰减速度, 为短步长的图扩散设定了相对更高的权重。

在社区发现任务上, 相关工作的主要创新在于对上述两种基础图扩散方式进行调整并设计对应向量的计算方法。计算 PPR 向量的原始方法是幂迭代算法^[30], 时间需求与网络中边的数量呈线性关系, 显然无法适应社交网络的超大规模。文献^[29]提出了一种 PPR 向量的局部计算方法 (APPR), 通过定

义残留向量构建了近似的 PPR 方程, 并设计了 push 算法逐步缩小残留向量。APPR 的时间复杂度与网络整体规模无关, 反比于结果向量的准确性, 使 PPR 向量可以处理大规模网络的局部社区发现任务。然而, 文献^[33]指出, 标准 PPR 向量获取的目标社区一般以给定搜寻节点为中心, 若给定种子出现在目标社区边界, 结果社区常有较低的准确性; 另一方面, 标准 PPR 缺乏对随机游走的限制, 图扩散过程可自由离开目标社区, 进入无关区域。为此, 文献^[33]提出一种多头随机游走框架 (MWC), 从给定种子发起多个随机游走, 每个随机游走轮流向前移动, 并记录每个随机游走的高频访问节点。MWC 将每个随机游走形式化为一个 PPR 方程, 方程的起始向量随其他随机游走的高频访问节点不断变化, 从而通过其他随机游走限定当前随机游走的移动, 使其难以逃离目标社区。

针对同样的问题, 文献^[34]定义了二阶随机游走, 并提出了二阶个性化网页排名方法 (PP²)。在标准 PPR 中, 随机游走的下一步移动完全由当前所在节点决定, 即从当前节点的邻节点中随机选择一个作为移动方向。PP² 则利用当前所在节点和上一步所在节点共同决定随机游走的下一步方向, 使随机游走倾向于在目标社区内部移动。传统 PPR 方程的状态转移矩阵定义了节点到节点的移动概率, PP² 则采用边到边的移动概率, 因此具有更高的时间需求。

为提高图扩散方法社区发现的准确性, 相关工作引入了网络模体^[35-36]的概念。模体指真实网络中大量存在的结构紧致的微小子图, 如三阶完全子图 (3-cliques)、四阶完全子图 (4-cliques) 等。网络模体没有严格的数学描述, 可粗略定义为以下形式。

定义10 网络模体^[37]。网络模体是网络中致密的子图结构, 且在真实网络中的数量远高于相同规模的随机网络。

文献^[35]利用网络模体对原始网络进行重组, 保持原网络节点集不变, 若两个节点同属于一个网络模体, 则定义它们之间存在一条高阶边, 并将两个节点同属模体的数量定义为高阶边的权重。重组后的网络一般称为网络的高阶超图。显然, 对于部分网络模体, 高阶边预示节点间更加紧密的连接关系, 如三角形模体。在此基础上, 文献^[35]将 PPR

方法延拓到高阶超图,提出了基于高阶 PPR 的社区发现方法 (MAPPR), MAPPR 利用 APPR 获取基于模体的 PPR 向量,并定义了基于模体的社区导率,用于抽取目标社区。高阶超图中的随机游走基于原始网络中的强连接关系,同样可有效阻碍图扩散逃离目标社区。然而社交网络常具有低密度特性,网络的原始边多不在紧密的模体中,上述高阶边的数量将非常稀少,导致高阶超图的结构信息缺失问题^[38-39]。为此,文献[38]通过添加边的方式构建网络的超图结构,首先采用上述方法构建初始重组网络,然后利用已知社区发现方法将重组网络中较大的连通分支划分为若干社区,并向每个社区添加边,使社区内任何两个节点之间均存在边的连接,最后把所有新增加的边加入原始网络拓扑中,形成最终的超图结构。文献[40]将高阶随机游走引入网络的高阶超图中,提出局部社区发现算法,旨在保护网络中的模体不被社区破坏,即使社区内部包含较多网络模体,使较少网络模体跨越社区边界。该算法定义了高阶导率来识别目标社区。

标准的局部社区发现以识别包含指定节点/节点集的单一社区为目标,而现实场景中常给定多个可能分布在不同真实社区内的搜寻节点,需获取这些节点所在的所有社区。针对该问题,文献[41]提出了一种记忆随机游走 (memory-based random walk, MRW) 方法,从每个搜寻节点发出一个随机游走,并保存每个随机游走的每一步访问历史,每个随机游走的下一步移动由当前所在节点和历史节点共同决定。MRW 方法利用不同随机游走路径的相似性判定对应搜寻节点是否属于相同社区,并对属于同一社区的随机游走相互限制,提高社区发现的准确性。与之类似,文献[42]提出了受限局部社区发现问题,定义如下。

定义 11 受限局部社区发现。给定被标记为 k 种不同颜色的若干节点,每种颜色对应一个真实社区,受限局部社区发现旨在识别这 k 个社区。

为解决上述问题,文献[42]提出了着色随机游走 (colored random walk, CRW) 方法。CRW 方法从每种颜色节点发起一个随机游走,每个随机游走为被访问节点分配一个自身颜色的权值,并倾向于向相同颜色节点移动,以此阻止随机游走逃离目标社区。CRW 方法将每个随机游走形式化为一个具有动态转移矩阵的 PPR 方程,利用幂迭代方法求解

PPR 向量。

真实网络中常存在局部信息缺失或包含噪声,使部分局部社区发现任务难以完成。而真实系统常可抽象为多层网络,通过整合多层网络信息可有效解决单层网络中的信息缺失与噪声问题。为此,文献[43]提出了面向多层网络局部社区发现的随机游走多层网络 (random walk in multiple network, RWM) 图扩散方法,多层网络及其中的局部社区发现任务定义如下。

定义 12 多层网络。多层网络是多个普通网络的集合,且存在跨层边连接不同网络中的节点。

定义 13 多层网络局部社区发现。给定多层网络和网络某一层中的一个搜寻节点,多层网络局部社区发现的目标是获取每层网络中的相关社区。

RWM 图扩散方法在每层网络上分别执行一个随机游走,并将每个随机游走形式化为一个 PPR 方程。为利用每层网络之间的关联关系,RWM 图扩散方法定义了捕获不同随机游走相似性的关联矩阵,并基于关联矩阵定义每个随机游走的转移矩阵。RWM 图扩散方法利用幂迭代方法求解 PPR 方程,并给出了加速方案。

真实网络多包含重叠的社区结构,一个节点可同时属于多个社区,如果指定搜寻节点出现在社区之间的重叠区域,则局部社区发现需获取所有包含该节点的社区。为此,文献[44]提出了一种面向多目标的局部社区发现方法,首先基于给定搜寻节点识别多个相关种子,然后利用 PPR 识别每个种子的目标社区,从而识别局部区域的多个重叠社区。

鉴于真实网络的拓扑结构常频繁变化,文献[45]提出了面向时序网络的局部社区发现方法。该方法定义了时序转移张量刻画图扩散中的状态转移概率,构建了多重线性 PageRank 方程,利用 push 算法获取对应向量,最后设计了基于增量的清扫 (sweep) 方法提取目标社区。

在局部社区发现任务中,利用热核扩散技术的相关工作较少。与 PPR 相比,热核扩散为短步长的随机游走设定了更高的权重,相关工作的研究热点在于热核向量的近似计算。文献[18]提出了一种松弛法计算热核向量,该方法主要利用高斯-赛德尔迭代法的思想,最后利用导率识别目标社区。实验结果表明,该方法在较小网络上相比于 PPR 时间需求更低,在较大网络上则运行更慢;另一方面,在

真实网络中识别的社区结果多具有更小的规模, 准确性较高。文献[32]结合蒙特卡罗方法和图遍历设计了热核向量的计算方法, 与文献[18]相比, 计算速度提升4倍以上。

基于图扩散的局部社区发现方法种类繁多, 适合不同类型网络和面向不同识别任务并采用不同的图扩散技术, 本文总结分析了其中的代表性工作, 如表1所示。

上面两类局部社区发现方法主要依赖网络的拓扑结构, 以社区内部连接紧密、社区间关联稀疏为核心依据定义目标函数进行社区抽取。然而真实网络中的社区结构呈现多样化, 难以用单一目标函数准确刻画, 也存在大量在结构上关联稀疏, 但在内容上相对一致的社会群体, 单纯利用网络拓扑信息将难以有效识别。为此, 出现了面向属性网络的半监督学习方法。

定义14 属性网络中的局部社区发现^[46]。已知属性网络 $G(V, E, F)$, 其中 $F \in \mathbb{R}^{|V| \times d}$ 为节点的属性矩阵, d 为节点属性维度, 与搜寻节点 q , 该任务的目标是获取包含节点 q , 结构相对紧密且内容相对一致的节点集合 C 。

基于半监督学习的局部社区发现方法除利用网络的拓扑与属性信息外, 也常需要一些已知社区(或有社区标签的节点)作为训练集, 一般利用图神经网络融合网络的结构与属性信息, 旨在捕获包含搜寻节点且与已知社区在结构与内容上相似的社区。因此, 在存在已知认知异常群体的场景下, 此

类方法可捕获网络中的同类群体, 直接完成社交网络中的异常群体识别任务。

存在已知社区或有社区标签的节点作为训练集的局部社区发现一般称为基于示例的局部社区发现^[46]。文献[47]提出了一种局部社区发现方法, 根据用户的反馈迭代地在搜寻节点与有标签节点周围抽取候选子图, 基于用户创建的节点标签训练分类器, 从而判定候选节点是否属于目标社区, 为节点层次的深度学习方法。

真实网络中常包含海量社区, 社区之间在结构和内容上常各不相同, 同时用户进行社区搜索也常出于多样化的目的或不同的下游任务。因此, 在已知部分社区作为示例的前提下, 挖掘与之相似的同类社区可大幅度提高局部社区发现的有效性与准确性。为利用已知社区特征, 文献[46]提出了社区层次的深度学习方法, 基于社区结构特征构建增量式图神经网络来学习节点表征, 利用自回归流模型捕获目标社区。面向同样场景, 文献[48]提出了基于结构相似性的半监督局部社区发现方法, 定义了基于最短路径长度的社区结构相似度, 首先选取与搜寻节点附近结构类似的已知社区, 然后利用这些已知社区指导目标社区的扩展。传统局部社区发现把单一社区作为识别目标, 而现实场景中常需获取具有相似特征的一类社区, 如一个社交网络平台中的所有诈骗团伙、认知异常群体等。为此文献[49]提出了基于社区定位与社区优化的半监督学习方法, 旨在发现具有相似特征的一类社区。该方法利用图

表1 基于图扩散的局部社区发现方法

模型	面向网络	识别目标	图扩散方法	主要贡献
文献[29]	单层网络	单一社区	标准 PPR	PPR 向量的高效计算
文献[33]	单层网络	单一社区	动态起始向量的 PPR	阻碍随机游走逃离目标社区
文献[34]	单层网络	单一社区	二阶 PPR	阻碍随机游走逃离目标社区
文献[35]	单层网络	单一社区	基于模体的 PPR	引入网络高阶信息, 定义模体导率
文献[40]	单层网络	单一社区	基于模体的高阶 PPR	引入网络高阶信息, 定义高阶导率
文献[41]	单层网络	多个社区	动态起始向量的 PPR	提出面向多种子的多目标社区问题
文献[42]	单层网络	多个社区	动态转移矩阵的 PPR	提出受限局部社区发现问题
文献[43]	多层网络	多个社区	动态转移矩阵的 PPR	多层网络的图扩散方案
文献[44]	单层网络	多个社区	标准 PPR	提出面向单一种子的多目标社区问题
文献[45]	时序网络	多个社区	基于模体的高阶动态 PPR	动态 PPR 向量的增量式计算方法
文献[18]	单层网络	单一社区	热核扩散	热核向量的近似计算方法
文献[32]	单层网络	单一社区	热核扩散	高效的热核向量计算

神经网络定位与已知社区相似的网络子图作为潜在目标社区,利用深度强化学习方法对潜在社区进一步优化得到最终社区集合,该方法同样需要对适量已知社区进行模型训练。

基于半监督学习的局部社区发现方法能够捕获网络的属性信息,可识别与已知社区相似的单一社区或一类社区。在有异常群体示例的情况下,能够直接获取网络中的目标异常群体或所有同类异常群体。

基于半监督学习的局部社区发现方法通过融合网络拓扑与节点属性,能够有效识别与已知社区模式相似的特定社区。当存在预标注的异常群体样本时,该技术可实现对目标异常群体的精准定位,并捕获网络中具有相似特征的同类型异常群体集合。然而该方向现处于起步阶段,相关工作较少,本文对其中的代表性方法进行总结,如表 2 所示。

1.3 全局社区结构识别

全局社区结构识别旨在获取目标网络中的所有社区,即传统的社区发现,可为群体认知安全分析提供基础网络单元。该任务经过长期研究,现已形成众多理论方法,如标签传播方法^[51-53]、非负矩阵分解方法^[54-55]、结构优化方法^[56-58]、基于图扩散的方法^[10, 39, 59-60]和深度学习方法^[61-66]等。在无属性网络中,图扩散方法得到的社区结构与真实社区间的一致程度较高,且具有良好的可扩展性,在社交网络中被广泛应用;面向属性网络,相关工作主要利用深度学习技术。本节重点总结分析这两类代表性方法:图扩散方法和基于图神经网络的社区发现方法。

图扩散方法一般包含两个核心步骤,首先选取目标网络中若干代表性节点作为每个社区的种子,然后基于图扩散技术扩展每个种子形成一个社区。其中前者一般称为种子搜索过程,种子的数量一般即为最终发现的社区数量,相关方法的关键目标是使种子在网络中具有广泛的分布,从而对真实社区

形成高覆盖率;后者称为社区扩展过程,一般独立完成每个社区的扩展,可自然形成重叠的社区结构^[11]。

文献[67]提出了基于 PPR 的社区发现方法,构建了 GC (graculus center) 和 SH (spread hub) 两种方法搜索网络中的种子。GC 利用现有社区发现方法对网络进行区域划分,在每个社区中选取中心位置的节点作为种子。SH 选取网络中度值最大的若干节点作为种子,且不允许两个种子相邻。文献[67]简单利用 APPR 算法进行每个社区的扩展。文献[68]在上述两步图扩散框架中加入了社区优化过程,提出了全局社区结构识别方法。该方法同样利用 APPR 算法识别网络中的每个社区,但对每个已发现社区做了进一步调整:通过移入社区周围节点和移出社区内部节点降低社区导率;定义融合社区相似度与导率变化的合并函数,对相似社区进行合并,并进一步优化社区导率;以社区导率为目标函数将网络中的孤立节点移入已知社区,从而提高发现社区结构对网络的覆盖率。

在图扩散方法中,不同社区虽独立扩展,但一般存在先后顺序,已捕获的社区能够引导后续社区的识别。基于该思路,文献[60]提出了基于受限随机游走的社区发现方法,定义了随机游走的偏移矩阵并融入图扩散的状态转移矩阵中,阻碍图扩散进入已知社区内部或在已知社区内移动,鼓励图扩散逃离已知社区。该方法允许社区之间发生重叠,同时避免形成相似社区,有效提高了发现社区与真实社区间的一致程度。

网络模体在传统社区发现任务中同样表现出色。文献[69]提出了基于三角形模体的全局社区结构识别方法。与传统利用单一结构网络模体的社区发现方法不同。该方法围绕社区构建了 3 类三角形结构:社区内部三角形,用于度量社区内部结构的紧致程度;两种社区边界三角形,分别度量社区与周围结构间的强弱关联程度,并基于 3 种网络模体

表 2 基于半监督学习的局部社区发现方法

模型	面向网络	识别目标	先验信息	核心技术
文献[47]	属性网络	单一社区	有标签节点	图神经网络,交互式社区搜索
文献[46]	属性网络	单一社区	已知社区	增量图神经网络,自回归流模型
文献[48]	无属性网络	单一社区	已知社区	最短路径核 ^[50]
文献[49]	属性网络	一类社区	已知社区	图神经网络,深度强化学习

定义了社区的三角形导率,可以更加有效地刻画社区质量。文献[39]基于三角形模体定义了节点间的高阶连接,并与网络的原始边融合构建重组网络,通过将PPR技术引入重组网络中,提出了全局社区结构识别方法,显然,该方法避免了基于模体的重组网络中的结构信息退化问题。

图扩散技术在时序网络的全局社区结构识别任务中同样有良好的表现。

定义15 时序网络中的全局社区发现。给定包含 T 个快照的时序网络 $\mathbf{G}^T = (G_1, G_2, \dots, G_T)$,每个快照 G_i 都是一个包含各自节点集和边集的静态网络,该任务旨在获取每个网络快照的社区结构。

文献[59]提出了基于增量的动态社区发现方法,利用PPR技术获取初始网络的社区结构,然后采用时序更新的方式依次识别后续快照的社区结构。文献[59]将网络在每个时刻的拓扑变化细化为4类基本事件:节点增加、节点删除、边增加和边删除,并针对每类基本事件分别设计局部方法更新社区结构,时间需求与网络宏观规模无关。

除了上述两步图扩散方法外,也出现了利用随机游走计算节点间相似度的聚类方法。鉴于随机游走多在起始社区中移动,起始于同一个社区的两个随机游走倾向于访问较多相同节点。文献[70]利用上述特点,将路径节点相似随机游走的起始节点进行聚类,形成网络的社区结构。该方法将图扩散过程描述为多个阶段:在初始阶段,图扩散访问大量所在社区中的新节点;然后重复访问所在社区中的节点;最后离开起始社区。因此,该方法在新增被访问节点较少时终止随机游走。

基于图扩散的全局社区结构识别方法采用的随机游走技术与局部社区发现类似,但也存在面向该任务的特定方法,如利用已知社区结构定义动态转

移矩阵^[60],本文对其中的代表性方法进行总结,如表3所示。

与局部社区发现不同,基于深度学习的全局社区结构识别可采用无监督的方式训练,不需要先验信息。此外,传统社区发现依托网络的全局信息,社交网络规模庞大,常存在已知社区和有社区标签的节点。因此,深度学习方法适合社交网络的群体发现任务。文献[61]基于自编码器框架构建图神经网络来识别网络的社区结构,结合马尔可夫随机场与卷积神经网络构建编码器,定义以社区为核心的解码器,并设计一种局部增强策略,使同一社区内节点具有相似属性和更多共同邻节点。文献[62]基于图神经网络对网络中的边进行编码,利用多目标进化算法识别属性网络的社区结构。文献[63]设计自适应图卷积网络作为编码器,利用双重解码器同时对网络拓扑和属性进行重构,最终通过最大化模块度识别网络的社区结构。文献[64]提出了面向社区结构的图卷积网络框架,利用伯努利-泊松模型融合表示学习与社区结构,通过定义社区视角的相似度和构建跨社区的模块度调节社区层次的信息。面向动态异构网络,文献[65]设计了异构时序图卷积网络,首先构建异构图卷积网络模块表征网络的每个异构快照,然后通过残差压缩聚合模块学习两个连续异构快照的时序表征,通过时序表征捕获社区结构的演化过程。文献[66]提出了基于图对比学习框架的社区发现方法,基于节点表征识别节点的社区隶属关系,并利用节点的社区隶属反向优化节点表征,使相同社区内节点表征相似,不同社区内节点表征相异,同时基于增量学习将方法泛化至时序网络。

2 群体异常检测

社区发现作为社交网络分析的核心技术,能够

表3 基于图扩散的全局社区结构识别方法

模型	面向网络	图扩散方法	主要贡献
文献[67]	静态网络	PPR	构建两种种子选取方法
文献[68]	静态网络	PPR	构建3种社区优化方法
文献[60]	静态网络	受限PPR	定义基于社区结构的转移矩阵
文献[69]	静态网络	PPR	围绕社区定义网络模体
文献[39]	静态网络	基于模体的PPR	高阶网络与原始网络结构融合
文献[59]	时序网络	PPR	基于网络局部信息的社区更新
文献[70]	静态网络	随机游走	利用随机游走路径信息计算节点间相似度

通过拓扑结构与属性信息识别网络中的功能群体：既可定位包含指定个体的特定目标群体，也能揭示网络中的全尺度群体分布。这种多粒度的群体辨识能力，为群体认知安全分析提供了基础结构单元。在此基础上，准确判定群体认知状态是否偏离正常模式，成为保障群体认知安全的关键环节。群体认知异常的宏观表现主要包括结构、属性与行为等的异常，例如受控的僵尸网络群体突出表现为由恶意指令统一调度的海量设备协同攻击，呈现高度机械化的行为异常。当前，群体异常检测主要依托图异常检测（graph anomaly detection, GAD）^[71-73]技术，通过分析群体结构、属性特征、交互模式及其动态演化特征来识别认知异常。本节主要总结分析图异常检测中的核心概念和适用于群体异常检测的代表性方法。

2.1 相关概念

图异常检测旨在识别网络中在结构或属性上与与众不同的实体，如节点、边、子图或整个网络。相应地，图异常检测可分为节点层次、边层次、子图和整图层次的异常检测。其中节点、边和子图层次的任务一般在单一网络中完成，将网络中的节点、边或子图作为检测对象，即模型输入；整图层次的异常检测模型则将多个网络组成的集合作为模型输入。为表述方便，本文将图异常检测模型的输入实体统一表示为 q ， q 可以表示一个节点、一条边、一个子图或一个网络，则图异常检测可形式化为以下定义^[71]。

定义 16 图异常检测。图异常检测旨在构建异常度量函数 $f: \{q_1, q_2, \dots\} \rightarrow \mathbb{R}$ ，使对任意 $q \in Q$ 和 $q' \in Q'$ ，有 $f(q') > f(q)$ ，其中 Q 和 Q' 分别表示正常和异常实体集合，一般有 $|Q| \gg |Q'|$ 。

文献^[73]进一步将节点和连边层次的图异常分为结构异常和属性异常两个类别，例如，在已知社区结构的网络中，社区的边界节点和社区之间的关联边常被定义为异常节点/异常边；将子图异常分为上级异常和下级异常两个类别。

定义 17 上级异常子图。在结构或属性上与网络中其他子图存在显著差异的子图。

定义 18 下级异常子图。内部节点属性存在较大差异或节点之间关联稀疏的网络子图。

例如，虚假信息传播群体在结构上一般由连接异常紧密、协调性强的稠密核心（操纵者集合）和

连接稀疏的边缘节点（被动员的“放大器”账号）组成，多表现为星形结构，与网络中关联均匀的普通群体显著不同，为上级异常子图；而群体内节点属性差异较大，如不同的年龄、不同的城市、不同的职业等，则表现为下级异常子图。围绕群体认知安全，本文重点总结分析子图异常检测的相关方法，为增强论文的可读性，本节首先介绍节点级图异常检测方法。

2.2 节点异常检测

给定目标网络，异常节点指与网络中其他节点显著不同的节点，例如社交网络中的一个诈骗用户、一条虚假新闻等。在图异常检测领域，节点异常检测的相关工作最为丰富，本节从面向无属性网络和属性网络两个方面进行介绍。

1) 无属性网络中的节点异常检测

面向图结构数据，众多图表示学习方法在节点异常检测任务上取得了良好的效果。文献^[74]基于网络的社区结构，将与较多社区关联的节点定义为异常节点。该方法利用现有社区发现算法将网络划分为 d 个社区，然后构建能够捕获每个节点 i 与 d 个社区之间关联信息的节点表征 $\mathbf{x}_i = (x_i^1, \dots, x_i^d)$ ，其中 $x_i^k (1 \leq k \leq d)$ 利用节点 i 与社区 k 之间的隶属关系进行初始化，具体为

$$\mathbf{x}_i^k = \begin{cases} \frac{1}{\sqrt{2}}, i \in k \\ 0, i \notin k \end{cases} \quad (10)$$

并优化节点表征，使相邻节点具有相似表征，不相邻节点具有相异表征。为融合邻节点的结构信息，该方法在上述节点表征的基础上定义了邻节点集的向量嵌入，用 $N(i)$ 表示节点 i 的邻节点集合，其向量嵌入 $\overline{N(i)}$ 定义为每个邻节点表征的加权和，即

$$\overline{N(i)} = (y_i^1, \dots, y_i^d) = \sum_{j \in N(i)} (1 - \|\mathbf{x}_i - \mathbf{x}_j\|) \mathbf{x}_j \quad (11)$$

该方法最终利用 $\overline{N(i)}$ 量化节点 i 与 d 个社区之间的关联关系，并基于 $\overline{N(i)}$ 定义了节点的异常函数，通过设定阈值判定节点的异常情况。

目前，Deepwalk^[75]、LINE^[76]和 Node2Vec^[77]等无属性图的表示学习方法广泛应用于节点表征，并已应用于异常检测的性能验证^[72, 78]。

文献^[79]结合图表示学习与强化学习，提出了节点异常检测方法，假设网络只有部分区域已知，

且包含有标签节点,利用强化学习方法在已知子网络上学习异常识别策略,从而识别网络未知区域的异常节点。

2) 属性网络中的节点异常检测

面向属性网络,近期的节点异常检测方法主要利用图神经网络框架。文献[80]提出了基于图卷积网络(graph convolutional network, GCN)^[7]的节点异常检测方法,该方法采用图卷积网络作为编码器,将目标网络进行低维嵌入表示,然后利用解码器同时重构网络拓扑结构和节点属性,最终利用编码-解码全过程产生的节点重构误差定位属性网络中的异常节点。

真实网络常包含多视图信息,如社交网络平台除包含用户的基本信息外,也包含用户发布的文本等内容,多视图能提供差异化的互补信息,提升节点异常检测的准确性。为此,文献[81]提出了多视图异常检测方法,该方法主要包含多视图编码器、聚合器以及面向结构与属性的解码器3个模块,利用多个GCN对多视图信息进行编码,采用加权聚合的方式形成节点表征,继而分别从网络结构与节点属性两个维度进行特征重构,最终基于编码-解码中产生的重构误差实现异常节点识别。

与GCN相比,图注意力网络(graph attention network, GAT)^[82]能够更有效地融合邻节点的关键信息,也被引入节点异常检测任务中。文献[83]提出一种基于双自编码器的联合表征学习框架,利用GAT对网络结构信息进行编码,采用独立的属性自编码器进行属性编码。通过无监督的编码-解码过程,每个节点根据其对应的重构损失进行排序,最终序列中的前 k 个节点被识别为异常节点。

2.3 子图异常检测

在社交网络中,异常个体常自组织地形成各类群体,通过协同行为达到特定目标。例如,在线评论网络中的欺诈用户群体可能通过统一发布误导性评论来诋毁或推广特定商品^[72],具有相似错误认知、立场的社交网络用户常有密切的关联关系,形成异常群体。相对于节点异常检测,子图异常检测面临更多挑战,例如,一些社交网络群体虽内部每个节点均表现正常,整体上却表现出异常特性。

传统的子图异常检测方法多基于密度估计方法^[84],代表性工作包括DeepFD^[85]和FraudNE^[86],两者均面向二分网络设计。DeepFD面向在线购物

网络中的欺诈团伙,将在线购物网络抽象为一个无属性二分图,包含用户和商品两类节点,两类节点之间存在关联边。DeepFD通过深度结构学习获取用户节点的向量表征,使同一群组中的可疑用户表征尽可能接近,而正常用户的表征则相对远离。鉴于同一欺诈群体中的用户常评价相同商品,DeepFD基于共同评价商品数定义了用户之间的相似度。DeepFD利用自编码器生成用户表征,并采用标准的编码-解码流程,最终通过基于密度的检测方法识别欺诈群体。

FraudNE面向在线评论网络,同样将网络抽象为二分网络,旨在捕获网络中的恶意用户和受操控商品。与DeepFD不同,FraudNE将二分图中的两类节点均编码到一个共享空间中,使同一稠密区块中的可疑用户和商品在此空间中彼此高度近邻,其他节点则均匀分布。FraudNE利用两个传统自编码器分别学习用户表征和商品表征,通过联合优化各自的重构损失与共享损失,实现双自编码器的协同训练。

上述两个模型的有效性依赖于一个关键假设:异常子图中节点的表征向量应彼此接近,而正常节点则在剩余空间中均匀分布。当网络中正常节点共享相似拓扑结构或属性时,此假设可能失效。为此,文献[87]提出子图异常检测方法,该方法主要包含位置感知图自编码器和超模图异常量化两个模块:前者通过编码器将目标网络映射为低维嵌入,并通过解码器从低维嵌入中重构图结构与节点特征,利用原始图与重构图之间的差异生成残差图,以此作为识别候选异常子图的核心依据;后者在已构建的残差图中识别最显著的异常子图并学习其异常分值函数。文献[87]最终构建了无监督与弱监督两种学习策略优化模型中的参数。

文献[88]面向学术异常引用群体,提出了基于局部扩展社区发现的异常子图检测方法,该方法首先利用异常节点检测方法获取网络中的异常节点,形成异常节点子图,利用Louvain算法^[89]对该子图进行初步社区划分,在每个社区中选取预设指标最高的节点作为种子进行社区扩展,形成异常群体。文献[88]利用获取的异常群体更新异常节点集合,并重复上述过程,以提高准确性。

在图异常检测研究领域,节点级别的异常检测方法已形成相对成熟的技术体系,而面向子图级别

的异常检测研究则尚显薄弱, 本文对其中的代表性工作进行总结, 如表 4 所示。

2.4 群体发现与群体异常检测的协同机制

在群体认知安全研究中, 社区发现与子图异常检测已成为两大核心分析任务。尽管已有研究尝试将社区发现技术作为子图异常检测的结构先验, 但两类方法的系统性融合仍有待深化。本节重点探讨二者在技术与应用层面的协同机制。

近年来, 随着深度学习技术的发展, 社区发现方法不仅能识别网络的整体社区结构, 还能在已知部分社区样本(如已标注的虚假信息传播群体、社交机器人集群)的前提下, 实现同类社区的全局提取。这为子图异常检测提供了重要的结构先验: 检测过程可从全网“漫灌”式扫描, 转向针对已识别高风险社区的定向分析, 从而大幅提升异常识别的效率与准确性。

此外, 社区发现中对“特定类别社区”的识别, 又高度依赖高质量的已知社区样本。而子图异常检测技术恰好能通过捕捉局部结构、行为或内容的异常模式, 为社区发现提供这些关键样本。例如, 检测出的异常密集子图或协同行为簇, 可直接作为“种子社区”输入社区发现模型, 驱动其识别全网中的同类群体。

因此, 在群体认知安全实践中, 社区发现与子图异常检测可构建一个“发现-检测-再发现”的迭代分析闭环: 社区发现提供结构先验以聚焦检测范围, 子图异常检测产出可疑样本以优化社区模型, 两者动态交互、相互增强。这一协同机制有助于从复杂网络中精准、高效地识别出虚假信息传播群体、社交机器人网络等认知安全威胁, 为平台风险感知与干预提供可操作的技术路径。

3 研究展望

群体认知安全作为网络空间安全领域的新兴研究方向, 虽已在基础理论构建与关键技术探索方面取得初步进展, 但整体仍处于发展的初级阶段, 存在众多关键问题亟待突破, 本文对该方向的研究进行展望。

1) 当前, 群体认知安全方向虽已积累部分研究成果, 但现有工作主要基于社会科学范式构建理论模型, 其分析方法多依赖于小规模样本统计, 难以适配现代社交网络海量、高维、动态的数据特性。与此同时, 图数据挖掘与图深度学习技术近年来取得显著突破, 在社区发现、影响力传播建模、异常群体检测等任务中展现出卓越性能, 这些技术成果为解决群体认知安全问题提供了潜在路径。然而, 目前尚缺乏将这些前沿网络分析技术系统化应用于群体认知安全领域的专项研究。因此, 构建融合图结构与认知语义的专用计算框架, 发展面向大规模社交网络的群体认知安全分析范式, 应成为未来重点探索方向。

2) 尽管大语言模型 (large language model, LLM) 在自然语言处理领域展现出卓越能力, 但其在图结构数据分析方面的潜力尚未得到充分探索。特别是在群体认知安全的核心任务场景中, 如社区结构识别^[90]、图异常检测^[91-92]等关键环节, 现有技术仍存在显著局限, 如何使 LLM 有效理解网络拓扑(如社区结构、结构异常等)并将其与文本内容语义进行关联推理是其中的关键问题。未来研究的一个重要方向在于推动大语言模型与图分析技术的深度融合, 以解锁其在群体认知安全领域的创新应用潜力。

表 4 图异常检测方法

模型	类别	面向网络	核心方法
文献[74]	节点级异常检测	无属性网络	网络表征
文献[79]	节点级异常检测	无属性网络	图表示学习、强化学习
文献[80]	节点级异常检测	属性网络	GCN
文献[81]	节点级异常检测	属性网络	多个 GCN
文献[83]	节点级异常检测	属性网络	GAT
文献[85]	子图级异常检测	二分网络	网络表征、对一类节点编码
文献[86]	子图级异常检测	二分网络	网络表征、对两类节点编码
文献[87]	子图级异常检测	属性网络	位置感知网络表征
文献[88]	子图级异常检测	无属性网络	社区发现

3) 现有的子图异常检测方法主要聚焦于从原始网络中直接挖掘潜在的异常群体。随着社区发现技术的日益成熟,其已能精准揭示网络的固有社区结构。基于此,在群体认知安全领域,一个重要的未来研究方向是:如何基于已知的、准确的社区结构,来有效判定特定功能群体的异常状态与安全风险,特别是面向时序网络,如何根据已知动态社区,预测其异常风险趋势,这标志着研究重心从“寻找群体”向“评估群体”的深化与转变。

4 结束语

本文面向群体认知安全这一网络空间安全领域的新兴方向,系统综述了其中的核心概念、基础理论和代表性方法。从局部社区发现和传统社区发现两个方面总结了与群体认知安全相关的社区发现方法,从节点异常检测和子图异常检测两方面综述了群体异常检测的相关方法,并对未来的研究方向进行了展望,旨在为群体认知安全方向的科研人员提供技术参考。

参考文献:

- [1] 陈金波. 射频人体感知关键技术及其在认知安全中的应用研究[D]. 安徽: 中国科学技术大学, 2024.
Chen J B. Research on key technologies of radio frequency human sensing and its application in cognitive security[D]. Anhui: University of Science and Technology of China, 2024.
- [2] 刘嘉宇. 基于高阶交互网络的在线群体观点演化与引导研究[D]. 长春: 吉林大学, 2024.
Liu J Y. Research on the evolution and guidance of online group opinion based on higher-order interactive networks[D]. Changchun: Jilin University, 2024.
- [3] Casino F. Unveiling the multifaceted concept of cognitive security: Trends, perspectives, and future challenges[J]. *Technology in Society*, 2025, 83: 102956.
- [4] 刘佳豪, 夏一雪, 沈宇航, 等. AIGC环境下群体认知入侵机理与防范策略[J]. *情报杂志*, 2025, 44(9): 154-163, 111.
Liu J H, Xia Y X, Shen Y H, et al. Mechanism and defense strategies of group cognitive intrusion in the context of AIGC[J]. *Journal of Intelligence*, 2025, 44(9): 154-163, 111.
- [5] 黄凤翔, 夏一雪, 兰月新. 认知战环境下群体认知演化动力学机理研究[J]. *情报杂志*, 2025, 44(8): 67-77, 42.
Huang F X, Xia Y X, Lan Y X. Research on the dynamics mechanism of group cognitive evolution in a cognitive warfare environment[J]. *Journal of Intelligence*, 2025, 44(8): 67-77, 42.
- [6] 赵高端, 孟凡松. 基于群体目标的认知攻防行动探析[C]//第十三届中国指挥控制大会. 北京: 兵器工业出版社, 2025: 625-630.
Zhao G D, Meng F S. Exploration of cognitive offensive and defensive actions based on group goals[C]//The 13th China Command and Control Conference. Beijing: Ordnance Industry Press, 2025: 625-630.
- [7] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[J]. *arXiv Preprint, arXiv: 1609.02907*, 2016.
- [8] Barabasi A, Albert R. Emergence of scaling in random networks[J]. *Science*, 1999, 286(5439): 509-512.
- [9] Watts D J, Strogatz S H. Collective dynamics of 'small-world' networks[J]. *Nature*, 1998, 393(6684): 440-442.
- [10] Gao Y, Zhang H L. Community detection based on graph diffusion: a survey of definitions, challenges, and models[J]. *Expert Systems with Applications*, 2025, 290: 128396.
- [11] 高阳, 张宏莉. 基于随机游走的社区发现方法综述[J]. *通信学报*, 2023, 44(6): 198-210.
Gao Y, Zhang H L. Survey on community detection method based on random walk[J]. *Journal on Communications*, 2023, 44(6): 198-210.
- [12] Jin D, Yu Z Z, Jiao P F, et al. A survey of community detection approaches: from statistical modeling to deep learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(2): 1149-1170.
- [13] Liu A, Moitra A. Minimax rates for robust community detection[C]//Proceedings of the 2022 IEEE 63rd Annual Symposium on Foundations of Computer Science (FOCS). Piscataway: IEEE Press, 2022: 823-831.
- [14] Magnani M, Hanteer O, Interdonato R, et al. Community detection in multiplex networks[J]. *ACM Computing Surveys*, 2022, 54(3): 1-35.
- [15] Radicchi F, Castellano C, Cecconi F, et al. Defining and identifying communities in networks[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2004, 101(9): 2658-2663.
- [16] Chakraborty T, Dalmia A, Mukherjee A, et al. Metrics for community analysis: a survey[J]. *ACM Computing Surveys*, 2017, 50(4): 1-37.
- [17] Gao Y, Zhang H L. Multi-order clustering on dynamic networks: on error accumulation and its elimination[C]//Proceedings of the IEEE INFOCOM 2024 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2024: 1950-1959.
- [18] Kloster K, Gleich D F. Heat kernel based community detection[C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2014: 1386-1395.
- [19] Luo W S, Zhou X, Li K L, et al. Efficient influential community search in large uncertain graphs[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(4): 3779-3793.
- [20] Tang Y F, Li J X, Al Hasan Haldar N, et al. Reliability-driven local community search in dynamic networks[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(2): 809-822.
- [21] Li X Y, Zhou L H, Kong B, et al. Influential community search over large heterogeneous information networks[C]//International Conference on Spatial Data and Intelligence. Berlin: Springer, 2023: 165-176.
- [22] Wang K, Zhang W J, Zhang Y, et al. Discovering significant communities on bipartite graphs: an index-based approach[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(3): 2471-2485.

- [23] Li L, Zhao Y H, Luo S Q, et al. Efficient community search in edge-attributed graphs[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(10): 10790-10806.
- [24] Xu T Y, Lu Z, Zhu Y Y. Efficient triangle-connected truss community search in dynamic graphs[J]. *Proceedings of the VLDB Endowment*, 2022, 16(3): 519-531.
- [25] Behrouz A, Hashemi F, Lakshmanan L V S. FirmTruss community search in multilayer networks[J]. *Proceedings of the VLDB Endowment*, 2022, 16(3): 505-518.
- [26] Zhang F, Guo H C, Ouyang D, et al. Size-constrained community search on large networks: an effective and efficient solution[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(1): 356-371.
- [27] Yu D X, Zhang L F, Luo Q, et al. Maximal clique search in weighted graphs[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(9): 9421-9432.
- [28] He Y Z, Wang K, Zhang W J, et al. Scaling up k-clique densest subgraph detection[J]. *Proceedings of the ACM on Management of Data*, 2023, 1(1): 1-26.
- [29] Andersen R, Chung F, Lang K. Local graph partitioning using PageRank vectors[C]//*Proceedings of the 2006 47th Annual IEEE Symposium on Foundations of Computer Science (FOCS'06)*. Piscataway: IEEE Press, 2006: 475-486.
- [30] Page L, Brin S, Motwani R, et al. The PageRank citation ranking: bringing order to the Web[R]. 1999.
- [31] Lofgren P A, Garcia-molina H, Goel A, et al. Efficient algorithms for personalized PageRank[D]. California: Stanford University, 2015.
- [32] Yang R C, Xiao X K, Wei Z W, et al. Efficient estimation of heat kernel PageRank for local clustering[C]//*Proceedings of the 2019 International Conference on Management of Data*. New York: ACM Press, 2019: 1339-1356.
- [33] Bian Y C, Ni J C, Cheng W, et al. Many heads are better than one: local community detection by the multi-walker chain[C]//*Proceedings of the 2017 IEEE International Conference on Data Mining (ICDM)*. Piscataway: IEEE Press, 2017: 21-30.
- [34] Wu Y B, Zhang X, Bian Y C, et al. Second-order random walk-based proximity measures in graph analysis: formulations and algorithms[J]. *The VLDB Journal*, 2018, 27(1): 127-152.
- [35] Yin H, Benson A R, Leskovec J, et al. Local higher-order graph clustering[C]//*Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2017: 555-564.
- [36] Benson A R, Gleich D F, Leskovec J. Higher-order organization of complex networks[J]. *Science*, 2016, 353(6295): 163-166.
- [37] Huang L, Chao H Y, Xie Q. MuMod: a micro-unit connection approach for hybrid-order community detection[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(1): 107-114.
- [38] Li P Z, Huang L, Wang C D, et al. EdMot: an edge enhancement approach for motif-aware community detection[C]//*Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2019: 479-487.
- [39] Gao Y, Zhang H L, Yu X Z. Higher-order community detection: on information degeneration and its elimination[J]. *IEEE/ACM Transactions on Networking*, 2023, 31(2): 891-903.
- [40] Zhou D W, Zhang S, Yildirim M Y, et al. A local algorithm for structure-preserving graph cut[C]//*Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2017: 655-664.
- [41] Bian Y C, Yan Y W, Cheng W, et al. On multi-query local community detection[C]//*Proceedings of the 2018 IEEE International Conference on Data Mining (ICDM)*. Piscataway: IEEE Press, 2018: 9-18.
- [42] Yan Y W, Bian Y C, Luo D S, et al. Constrained local graph clustering by colored random walk[C]//*Proceedings of the World Wide Web Conference*. New York: ACM Press, 2019: 2137-2146.
- [43] Luo D S, Bian Y C, Yan Y W, et al. Local community detection in multiple networks[C]//*Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2020: 266-274.
- [44] Liu J X, Shao Y X, Su S. Multiple local community detection via high-quality seed identification over both static and dynamic networks[J]. *Data Science and Engineering*, 2021, 6(3): 249-264.
- [45] Fu D Q, Zhou D W, He J R. Local motif clustering on time-evolving graphs[C]//*Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM Press, 2020: 390-400.
- [46] Chen J Z, Xia Y K, Gao J. CommunityAF: an example-based community search method via autoregressive flow[J]. *Proceedings of the VLDB Endowment*, 2023, 16(10): 2565-2577.
- [47] Chen J Z, Gao J, Cui B. ICS-GNNS⁺: lightweight interactive community search via graph neural network[J]. *The VLDB Journal*, 2023, 32(2): 447-467.
- [48] Ni L, Ge J N, Zhang Y W, et al. Semi-supervised local community detection[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(2): 823-839.
- [49] Wu X X, Xiong Y, Zhang Y, et al. CLARE: a semi-supervised community detection algorithm[C]//*Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2022: 2059-2069.
- [50] Borgwardt K M, Kriegel H P. Shortest-path kernels on graphs[C]//*Proceedings of the Fifth IEEE International Conference on Data Mining (ICDM'05)*. Piscataway: IEEE Press, 2006: 8.
- [51] Zarezadeh M, Nourani E, Bouyer A. DPnLP: distance based peripheral nodes label propagation algorithm for community detection in social networks[J]. *World Wide Web*, 2022, 25(1): 73-98.
- [52] Zhang W T, Shang R H, Jiao L C. Large-scale community detection based on core node and layer-by-layer label propagation[J]. *Information Sciences*, 2023, 632: 1-18.
- [53] Roghani H, Bouyer A. A fast local balanced label diffusion algorithm for community detection in social networks[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(6): 5472-5484.

- [54] Su S X, Guan J W, Chen B L, et al. Nonnegative matrix factorization based on node centrality for community detection[J]. *ACM Transactions on Knowledge Discovery from Data*, 2023, 17(6): 1-21.
- [55] Guan J W, Chen B L, Huang X. Community detection via multihop nonnegative matrix factorization[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(7): 10033-10044.
- [56] Shang R H, Zhao K J, Zhang W T, et al. Evolutionary multiobjective overlapping community detection based on similarity matrix and node correction[J]. *Applied Soft Computing*, 2022, 127: 109397.
- [57] Zhou J J, Chen Z, Du M, et al. RobustECD: enhancement of network structure for robust community detection[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(1): 842-856.
- [58] Zhang Q Q, Chu L Y, Zhao Z J, et al. Finding antagonistic communities in signed uncertain graphs[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2025, 37(2): 655-669.
- [59] Gao Y, Yu X Z, Zhang H L. Uncovering overlapping community structure in static and dynamic networks[J]. *Knowledge-Based Systems*, 2020, 201: 106060.
- [60] Gao Y, Yu X Z, Zhang H L. Overlapping community detection by constrained personalized PageRank[J]. *Expert Systems with Applications*, 2021, 173: 114682.
- [61] He D X, Song Y, Jin D, et al. Community-centric graph convolutional network for unsupervised community detection[C]//*Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence*. New York: ACM Press, 2020: 3515-3521.
- [62] Sun J Y, Zheng W, Zhang Q F, et al. Graph neural network encoding for community detection in attribute networks[J]. *IEEE Transactions on Cybernetics*, 2022, 52(8): 7791-7804.
- [63] He C B, Cheng J W, Chen G H, et al. Multiple topics community detection in attributed networks[C]//*Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval*. New York: ACM Press, 2023: 2199-2203.
- [64] Liu H T, Wei J H, Xu T Y. Community detection based on community perspective and graph convolutional network[J]. *Expert Systems with Applications*, 2023, 231: 120748.
- [65] Zheng Y P, Zhang X F, Chen S Y, et al. When convolutional network meets temporal heterogeneous graphs: an effective community detection method[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(2): 2173-2178.
- [66] Park N, Rossi R, Koh E, et al. CGC: contrastive graph clustering for Community detection and tracking[C]//*Proceedings of the ACM Web Conference 2022*. New York: ACM Press, 2022: 1115-1126.
- [67] Whang J J, Gleich D F, Dhillon I S. Overlapping community detection using neighborhood-inflated seed expansion[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2016, 28(5): 1272-1284.
- [68] Gao Y, Zhang H L, Zhang Y. Overlapping community detection based on conductance optimization in large-scale networks[J]. *Physica A: Statistical Mechanics and Its Applications*, 2019, 522: 69-79.
- [69] Gao Y, Yu X Z, Zhang H L. Graph clustering using triangle-aware measures in large networks[J]. *Information Sciences*, 2022, 584: 618-632.
- [70] Okuda M, Satoh S, Sato Y, et al. Community detection using restrained random-walk similarity[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(1): 89-103.
- [71] Qiao H Z, Tong H H, An B, et al. Deep graph anomaly detection: a survey and new perspectives[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2025, 37(9): 5106-5126.
- [72] Ma X X, Wu J, Xue S, et al. A comprehensive survey on graph anomaly detection with deep learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(12): 12012-12038.
- [73] 徐登彬, 袁立宁, 吴沛宸, 等. 图神经网络驱动的图异常检测研究综述[J]. *计算机科学与探索*, 2025, 1-40.
- Xu D B, Yuan L N, Wu P C, et al. A survey of graph anomaly detection driven by graph neural networks[J]. *Journal of Frontiers of Computer Science and Technology*, 2025, 1-40.
- [74] Hu R J, Aggarwal C C, Ma S, et al. An embedding approach to anomaly detection[C]//*Proceedings of the 2016 IEEE 32nd International Conference on Data Engineering (ICDE)*. Piscataway: IEEE Press, 2016: 385-396.
- [75] Perozzi B, Al-Rfou R, Skiena S. DeepWalk: online learning of social representations[C]//*Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2014: 701-710.
- [76] Tang J, Qu M, Wang M Z, et al. LINE: large-scale information network embedding[C]//*Proceedings of the 24th International Conference on World Wide Web*. New York: ACM Press, 2015: 1067-1077.
- [77] Grover A, Leskovec J. Node2Vec: scalable feature learning for networks[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2016: 855-864.
- [78] Bandyopadhyay S, N L, Vivek S V, et al. Outlier resistant unsupervised deep architectures for attributed network embedding[C]//*Proceedings of the 13th International Conference on Web Search and Data Mining*. New York: ACM Press, 2020: 25-33.
- [79] Morales P, Caceres R S, Eliassi-Rad T. Selective network discovery via deep reinforcement learning on embedded spaces[J]. *Applied Network Science*, 2021, 6(1): 24.
- [80] Ding K Z, Li J D, Bhanushali R, et al. Deep anomaly detection on attributed networks[C]//*Proceedings of the 2019 SIAM International Conference on Data Mining*. Philadelphia: SIAM, 2019: 594-602.
- [81] Peng Z, Luo M N, Li J D, et al. A deep multi-view framework for anomaly detection on attributed networks[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(6): 2539-2552.
- [82] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks[J]. *arXiv Preprint, arXiv: 1710.10903*, 2017.
- [83] Fan H Y, Zhang F B, Li Z Y. Anomalydae: dual autoencoder for anomaly detection on attributed networks[C]//*Proceedings of the ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Piscataway: IEEE Press, 2020: 5685-5689.
- [84] Ester M, Kriegel H P, Sander J, et al. A density-based algorithm for dis-

- covering clusters in large spatial databases with noise[C]//Proceedings of the Second International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 1996: 226-231.
- [85] Wang H B, Zhou C, Wu J, et al. Deep structure learning for fraud detection[C]//Proceedings of the 2018 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Press, 2018: 567-576.
- [86] Zheng M Y, Zhou C, Wu J, et al. FraudNE: a joint embedding approach for fraud detection[C]//Proceedings of the 2018 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE Press, 2018: 1-8.
- [87] Zhang Z, Zhao L. Unsupervised deep subgraph anomaly detection[C]//Proceedings of the 2022 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Press, 2023: 753-762.
- [88] 林欣蕊, 王晓菲, 朱焱. 基于局部扩展社区发现的学术异常引用群体检测[J]. 计算机应用, 2024, 44(6): 1855-1861.
Lin X R, Wang X F, Zhu Y. Academic anomaly citation group detection based on local extended community detection[J]. Journal of Computer Applications, 2024, 44(6): 1855-1861.
- [89] Blondel V D, Guillaume J L, Lambiotte R, et al. Fast unfolding of communities in large networks[J]. Journal of Statistical Mechanics: Theory and Experiment, 2008(10): P10008.
- [90] Hua J H, Yuan L, Feng Q S, et al. CS-agent: LLM-based community search via dual-agent collaboration[C]//Proceedings of the 34th ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2025: 928-938.
- [91] Xu Y M, Chen J R, Peng Z, et al. Court of LLMs: evidence-augmented generation via multi-LLM collaboration for text-attributed graph anomaly detection[C]//Proceedings of the 33rd ACM International Conference on Multimedia. New York: ACM Press, 2025: 2437-2446.
- [92] Pang Y H, Chen B, Zhang F J, et al. GuARD: effective anomaly detection through a text-rich and graph-informed language model[C]//Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining V.2. New York: ACM Press, 2025: 2222-2233.

[作者简介]



高阳 (1986-), 男, 黑龙江哈尔滨人, 博士, 哈尔滨工业大学副研究员、硕士生导师, 主要研究方向为图数据挖掘、社交网络分析等。



刘立坤 (1985-), 男, 吉林磐石人, 博士, 哈尔滨工业大学副研究员、硕士生导师, 主要研究方向为网络与信息安全、移动安全、网络流量检测等。



张宏莉 (1973-), 女, 吉林榆树人, 博士, 哈尔滨工业大学教授、博士生导师, 主要研究方向为社交网络分析、网络与信息安全等。