

## 多型扩散网络溯源方法综述

崔恒睿, 陈东, 赵翔

(国防科技大学大数据与决策实验室, 湖南长沙 410073)

**摘要:** 随着互联网技术的快速发展, 信息是如何在网络中传播和扩散的, 成为了一个重要的研究课题。网络溯源技术通过分析扩散网络中信息的来源和传播路径, 追溯信息主体, 辅助确定信息的真实性, 对于抑制虚假信息传播、维护网络安全具有重要价值。首先, 对扩散网络发展历史沿革、虚假信息传播对网络安全治理的影响及溯源在网络安全治理体系中的广泛应用进行了概述, 基于信息传播模型、信息观察模式和扩散网络源节点数量3种角度对多种扩散网络溯源方法进行了分类, 并进一步介绍了受限感知条件下的扩散网络溯源模型。随后, 利用现有数据集, 对各分类典型溯源方法进行了案例分析。最后, 对扩散网络溯源方法进行了总结, 同时从网络溯源技术的网络空间安全隐私保护以及受限感知条件下的溯源方法发展两方面展望了网络溯源领域的未来研究方向。

**关键词:** 网络信息传播; 扩散网络; 网络溯源; 受限感知

**中图分类号:** TP399

**文献标志码:** A

**DOI:** 10.11959/j.issn.2096-109x.2025040

## Review of localization methods over multi-type diffusion networks

CUI Hengrui, CHEN Dong, ZHAO Xiang

Laboratory for Big Data and Decision, National University of Defense Technology, Changsha 410073, China

**Abstract:** With the rapid development of internet technology, the dissemination and diffusion of information across networks have become a significant area of research. Source localization technology is used to trace the origin and propagation of information in order to identify source entities, thereby assisting in the verification of information authenticity. It plays a crucial role in curbing the spread of false information and maintaining network security. An overview of the historical evolution of networks, the impact of false information dissemination on network security governance, and the extensive applications of source localization within the network security governance frame-

收稿日期: 2025-01-21; 修回日期: 2025-05-14

通信作者: 赵翔, xiangzhao@nudt.edu.cn

基金项目: 国家重点研发计划 (2022YFB3102600); 国家自然科学基金 (U23A20296, 62272469); 湖南省科技创新计划 (2023RC1007)

**Foundation Items:** The National Key Research and Development Program of China (2022YFB3102600), The National Natural Science Foundation of China (U23A20296, 62272469), The Science and Technology Innovation Program of Hunan Province (2023RC1007)

引用格式: 崔恒睿, 陈东, 赵翔. 多型扩散网络溯源方法综述[J]. 网络与信息安全学报, 2025, 11(4): 15-31.

**Citation Format:** CUI H R, CHEN D, ZHAO X. Review of localization methods over multi-type diffusion networks[J]. Chinese Journal of Network and Information Security, 2025, 11(4): 15-31.

work were presented. Various source localization methods for diffusion networks were classified based on information observation patterns, information propagation models, and the number of sources. Source localization models under constrained sensing conditions were also introduced. Subsequently, using existing datasets, case analyses of typical source localization methods within each category were conducted. Finally, the findings were summarized according to the different classifications, and future research directions in the field of network source localization were outlined, with emphasis on network space security, privacy protection, and the advancement of source localization under constrained sensing conditions.

**Keywords:** information propagation, diffusion networks, network localization, constrained perception

## 0 引言

随着互联网技术的爆炸式发展,人类社会的信息存储、交换、传播方式发生着快速而深刻的变革。人类社会逐步迈向第三代互联网时代<sup>[1]</sup>,在突破狭义物理空间限制的前提下,个体与个体之间、组织与组织之间的互动也更加丰富灵活<sup>[2]</sup>。随着互联网的诞生和发展,扩散网络的研究经历了一段漫长的发展,从早期网络的扩散理论,到社交媒体的全球化兴起与治理,再到多类型传播模型的系统性提出以及在线社交网络数据集的整合扩容,每个阶段都有其独特的成就和挑战,扩散网络研究发展时间线如图1所示。

扩散网络在极大助力新媒体发展及群体社

交的同时,信息的大面积无差别覆盖与便捷快速的发布传播也是一把双刃剑。由有蓄谋的个体或组织编辑发布的恶意谣言<sup>[3]</sup>或计算机病毒以类似疫情传播的形式通过网络空间进行扩散,造成难以想象的破坏与损失。在过去的几年中,全球发生了一系列引起广泛关注的事件,大量虚假信息在新闻网站、社交媒体等传播渠道迅速蔓延,不仅掩盖和扭曲真相,还误导了广大受众。在当前的数字化时代,网络空间中散布虚假信息等违法犯罪行为也已成为一种严重的社会问题,不仅严重冲击了经济、社会生活的正常秩序,甚至对国家政治安全造成了不容忽视的威胁,逐渐演变成为一类全球性公害<sup>[4]</sup>。在这样的背景下,采取有效措施来应对和解决




图1 扩散网络研究发展时间线

Figure 1 Timeline of the development of diffusion network research

这一问题显得尤为重要。

在国内外的多项研究报告中,溯源作为一种有效手段被广泛应用于网络安全治理体系<sup>[2]</sup>。溯源技术指通过分析和追踪信息的来源和传播路径,确定信息真实性的过程。这种技术能够揭示信息产生的根源以及扩散背后的机理,从而有助于抑制虚假信息的传播。通过溯源可以有效阻断虚假信息的进一步传播,并为追究相关责任主体提供证据。

近年来,研究人员针对信息传播模型、信息观察模型、源节点数量等提出了一系列溯源方法。信息传播模型描述了信息在网络中传播的方式,不同的传播模型意味着信息的传播具有不同的动力学机理,而各类溯源方法需要适应相应的传播模型。信息观察模型指的是在网络中能够获取的信息的类型和范围,不同的观察模型决定了溯源算法可以使用的数据量和质量,从而影响溯源方法的有效性。源节点数量指的是信息起始传播的节点数,影响溯源的复杂度和策略。

受限感知条件是近年出现的溯源研究设定,涉及在扩散网络溯源时可能遇到的各种限制条件,针对溯源模型不同输入模块的受阻需要采用不同的响应机制来缓解其对最终结果的影响。在

扩散网络溯源实践中,一些扩散网络的区域拓扑结构无法直接获取,研究者基于从历史数据中观察到的扩散结果实现拓扑重建<sup>[5]</sup>,从而支撑溯源系统功能正常运行。这表明在受限条件下,仍然可以合理利用资源和技术手段来进行扩散网络溯源,为应对虚假信息监测及防控提供了有益的经验。综上所述,如何在溯源端跨越感知端的最后一道数据不完备壁垒,是当前扩散网络溯源研究面临的一项重大挑战。

扩散网络溯源方法的时间轴如图2所示,本文主要从假设依赖的传播模型、信息传播的观察模式、扩散源节点的数量3个维度进行分类综述,同时进一步介绍了现有基于受限感知条件的扩散网络溯源方法,涉及的方法依照时间和类别,以时间轴的方式用不同颜色进行分类。本文的综述框架遵循溯源问题的内在逻辑,依次围绕信息传播模型、信息观察模式、源节点数量和受限感知条件4个方面展开。首先基于信息传播模型建立溯源理论基础,其次基于信息观察模式明确数据观测的现实约束,进而以源节点数量作为溯源问题复杂度的核心变量,最后明确受限感知条件的实践壁垒,从而覆盖了网络溯源技术从理论构建到工程落地的各个环节。




图2 扩散网络溯源方法时间轴

Figure 2 Timeline of methods for diffusion networks localization

## 1 信息传播模型

传播模型是溯源研究的基础。信息扩散的动力学特征直接决定溯源算法的设计范式。信息传播模型是理解和预测信息扩散路径的关键工具,通过模拟信息在网络中的传播机制,为溯源方法提供了理论支持。本节主要介绍了信息级联模型、传染病模型、博弈论模型,并系统梳理传播模型从简单到复杂、从确定到随机的演进过程,揭示传播模型如何塑造溯源方法的核心机制。

### 1.1 基于信息级联的方法

在网络科学和社会网络分析中,已经开发出多种用于准确模拟和理解信息传播过程的模型。其中,基于信息级联的扩散模型,尤其是独立级联(independent cascade, IC)模型<sup>[6]</sup>和线性阈值(linear threshold, LT)模型<sup>[7]</sup>成为了研究信息传播机制的主流工具。这些模型通过定义网络中每个节点的状态(活跃或非活跃),提供了一种框架来描述节点之间信息传递的行为及其感染状态。

在独立级联模型中,假设网络中的每个节点在任意给定时间点都处于某种状态,即处于活跃的或非活跃的状态。该模型假设,每个活跃的节点在其生命周期中只有一次机会去尝试激活其每一个非活跃的邻居节点。这种激活尝试成功与否是依据预先设定的概率来决定的,这种传播机制反映了信息扩散的普遍性与随机性。

线性阈值模型通过为网络中的每条边赋予权重来模拟信息传递的过程,这些权重表示节点间传递信息的影响力。在此模型中,每个节点都被赋予一个阈值,该阈值代表一个节点变为活跃状态所需的来自其邻居的总体影响力的最小值。当一个节点的所有活跃邻居对其总体影响力达到或超过该阈值时,该节点将变为活跃状态。线性阈值模型基于此给出了一个框架,用于描述节点相互作用强度,以及个体接收新信息的倾向来模拟信息的整体扩散过程。

这两种模型的引入,有效提升了网络扩散过程的可描述性和可理解性,使研究人员能够更准确地将这些扩散过程描述为随机过程。基于这些状态假设,研究人员能够更有效地进行影响力最大化<sup>[6]</sup>、级联发展的预测<sup>[8]</sup>以及网络中信息溯源

等反向扩散任务的分析。上述这些研究不仅揭示了信息传播的内在机制,还为制定营销策略和控制信息扩散提供了理论基础和实用工具。

### 1.2 基于传染病模型的方法

在信息传播和疾病扩散研究领域,早期研究主要集中在一些经典的传播模型上,诸如 SI(susceptible-infected)<sup>[9]</sup>、SIR(susceptible-infected-recovered)<sup>[10]</sup>、SIS(susceptible-infected-susceptible)<sup>[11]</sup>等模型,其中,S表示易感(susceptible),I表示感染(infected),R表示康复(recovered)。利用 Facebook 数据集分别对 SI、SIS、SIR 模型进行信息扩散模拟。其中绿色代表易感节点、红色代表感染节点,橙色代表康复节点。3类模型以简洁的形式对扩散网络的信息传播进行了清晰准确的建模,为进一步开展扩散网络上的溯源研究提供了理论基础。传染病模型如图 3 所示。




图3 传染病模型示意

Figure 3 Diagram of infectious disease model

这些模型因其明确的数学建模和简洁的实现得到了广泛应用。Prakash等<sup>[9]</sup>提出了一种高效方法,用于处理 SI 传播模型。这个方法旨在找到一组最佳的种子节点,这些节点能够最好地解释给定的图快照数据。为了识别最佳的种子节点和传播路径,有学者提出了使用最小描述长度(minimum description length, MDL)原则<sup>[12]</sup>,这是一种通过最简洁的描述感染图来识别最佳种子节点和传播波纹的方法。该工作提供的算法可以识别给定快照的可能种子节点集,并展示了如何通过最大化似然度来优化传播路径的识别,从而以一种有原则的方式确定这些节点。通过结合上述 3 个方面,其能够自动识别正确的种子节点数

量以及具体节点。Jiang 等<sup>[13]</sup>进一步提出了一种方法来解决 SI 模型下的多源识别以及传播源的数量、传播的起始位置和传播的爆发时间等问题。该方法基于两个关键元素: 传播概率和节点之间的跳数, 对原始网络进行了改进。同时, 该方法还引入了一种高效的算法来估计信息传播的时间和传播源的数量。Shah 等<sup>[10]</sup>使用了 SI 模型来模拟网络中的谣言传播, 构建了一个谣言源头的估计器。这个估计器基于新的拓扑量——谣言中心性 (rumor centrality, RC)。并在一类特定的图上证明, 该估计器是一个最大似然 (maximum likelihood, ML) 估计器。研究中发现一类新的阈值现象: 在生长速度比直线更快的树状网络中, 估计器总是具有非平凡的检测概率; 而在生长速度与直线相似的树状网络中, 随着网络规模扩大, 检测概率会降至 0。论文还将谣言中心性与距离中心性 (distance centrality, DC) 进行了比较。结果证明了在树图上, 谣言中心和距离中心是等价的, 但在一般网络上可能不同。最终的模拟结果表明, 在非树状的网络中, 谣言中心性在寻找谣言源头方面优于距离中心性。针对 SIR 模型, Luo 等<sup>[14]</sup>提出了基于感染序列计数近似的估计器。对于几何树网络, 当感染源的数量最多为两个时, 随着感染节点数量的增加, 估计器正确识别感染源的概率将趋于 1。基于 SIR 模型, 当感染源数量超过两个时, 进一步提出了具有二次复杂度的启发式算法。实验结果表明所提出的估计器能够在高概率下正确识别感染源, 并且距离真实源的跳数仅在几跳之内。Zhu 等<sup>[15]</sup>的工作同样基于 SIR 模型。为了解决在已知图拓扑结构和所有感染节点的情况下, 无法区分易感节点和康复节点的问题, 提出了一种基于样本路径的方法来估计信息源, 该方法考虑了网络中信息传播的可能路径。同时, 提出了采用一种逆向感染算法, 在一般图中找到这样的估计器。该算法从观察到的感染节点出发, 逆向追踪可能的传播路径, 以估计信息源的位置。

除了上述模型外, 传染病模型如 SIRS (susceptible-infected-recovered-susceptible)<sup>[16]</sup> 和 SEIR (susceptible-exposed-infected-recovered)<sup>[17]</sup>

等, 虽然广泛应用于大量传播动力学机理研究领域, 但在扩散网络溯源的研究中尚未被广泛应用。引入这些模型可能会给未来的研究带来新的视角和方法, 特别是在处理更加复杂的信息传播和疾病扩散问题时, 提供更为精确和灵活的分析工具。因此, 未来的工作可以考虑将更多传染病模型纳入研究范畴, 以期在源识别和信息传播研究领域取得新的突破。

### 1.3 基于博弈论的方法

信息的动态扩散过程, 尤其在复杂网络中, 不仅受到网络结构的影响, 还涉及网络中个体之间的互动和决策。为更深入地探讨这一复杂现象, 一些学者提出将演化博弈论应用于信息扩散研究的先进框架。

具体地, Jiang 等<sup>[18]</sup>针对社交网络中的信息扩散机制, 考虑到社交用户在决策过程中的行动选择以及社会经济因素的互动影响, 提出了一个演化博弈的框架, 旨在模拟扩散网络中信息的动态扩散过程。这一方法允许研究人员从微观层面上, 考察个体用户在社交网络中如何基于各自的利益和策略做出信息传播的决策, 以及这些决策如何影响整个网络的信息扩散模式。Wang 等<sup>[19]</sup>深化了这一领域的研究, 其考虑社交网络中的各个用户节点, 这些节点根据概率选择预设策略库中的某个策略来进行信息传播。采用协调博弈模型描述社交网络中谣言传播的扩散机制, 这可以帮助理解在社交网络环境下, 如何通过调整策略和激励机制来协调用户行为, 以达到抑制或控制谣言传播的目的。与此同时, Li 等<sup>[20]</sup>从识别文本及阻断谣言传播的角度来理解信息扩散过程, 认为谣言内部的影响力大小及社交网络中对源节点的信任度是影响谣言产生和传播的关键因素。基于上述考虑, Liu 等<sup>[21]</sup>建立了 ET (explosion-trust) 博弈模型, 以寻求博弈均衡点, 从而为谣言控制提供策略建议。

基于博弈论的信息扩散模型进一步用于探讨谣言影响的极值研究<sup>[22]</sup>。在这种方法中, 研究者利用博弈论来探索谣言扩散的极限情况, 即在最优和最差情况下谣言可以达到的影响范围。包括了解哪些网络结构、初始条件和传播规则会最大化或最小化谣言的扩散。同时混淆信息源问

题<sup>[23]</sup>也受到众学者的关注与探索。该问题聚焦于谣言或错误信息已经在网络中传播,如何确定或混淆这些信息的原始来源。研究者通过模拟不同的策略和计算每个策略的成功概率来分析这个问题,力求找到最有效的方法来识别或保护信息源,以便在必要时能够快速准确地应对谣言或虚假信息的传播。

## 2 信息观察模式

信息传播模型的构建为信息观察策略设计提供了理论基础。在传播机理明确的基础上,观察模式构成溯源算法设计的第二层约束。本节探讨了基于信息观察模式分类的扩散网络溯源模型,主要介绍了基于完全观察的方法、基于传感器观察的方法、基于快照观察的方法。系统梳理了观察-模型的耦合关系,以及如何推动溯源方法从理想假设向工程化实践演进。

### 2.1 基于完全观察的方法

在扩散理论网络中,完全观察假设(full observation assumption, FOA)指一种理想化条件,观察者能够在给定时间点获得网络中所有节点的详尽信息。这包括每个节点的感染状况及其相互之间的连接模式。此假设为研究人员提供了一种全面的数据视角,允许其在特定时间点精确掌握网络内每个节点的状态,并据此推测信息或其他类型影响的网络扩散过程。大量的网络扩散研究均基于完全观察假设,原因在于它能够对网络行为及其动态演变的全面洞察。借助完全观察,研究者可以准确跟踪并模拟在网络中的传播轨迹及模式,进而为防控预备和干预策略的制定提供了理论基础和实践指导。

然而,尽管完全观察能够提供极为丰富的数据资源,但在现实应用中仍然面临众多技术挑战和隐私保护的问题。实现对网络中所有节点信息的完整收集可能受限于数据采集技术的能力及资源的可用性。在隐私保护方面,涉及个人隐私权和数据安全的多个关键问题<sup>[24]</sup>,这使得在实际场景中实施完全观察变得非常困难。

### 2.2 基于传感器观察的方法

尽管完全观察提供了理论基准,但监控全体节点的实时状态会产生大量的存储成本。这也催

生了传感器观察模式,其过程涉及将部分传感器节点嵌入网络中,以便实时捕捉与记录节点的状态、状态变化时间及感染传播方向等动态数据。这些传感器充当了网络中用户或计算机的代理,具有特殊的监控能力。与普通节点相比,传感器通常处于网络管理员的直接监控之下,这使得传感器能够详尽地记录在其上发生的谣言传播。在理论上,这些传感器节点具有无限生命周期,能够在整个传播动态期间持续监测网络状态。

此外,传感器监测方法因其在成本效益和执行可行性上的优势,尤其适用于大规模网络环境。Zhu 等<sup>[25]</sup>在扩散网络溯源研究中,将部分节点划定为观察者节点,并针对低感染率场景源定位问题,开发了一种 PBSI (path-based source identification) 算法。这种算法能够利用有限的观测数据,较为准确地实现源头追踪。同期,Shen 等<sup>[26]</sup>利用反向传播算法实现了有限传感器溯源模型。

进一步地,Wang 等<sup>[27]</sup>提出了一种结合有限传感器部署的定位算法 GFNL (greedy full-order neighbor localization),该算法包括基于贪心算法的传感器部署策略和基于传播方向路径的源头估计策略两大部分。Wang 等<sup>[28]</sup>还进一步提出了 GRSL (greedy randomized source localization) 方法,此方法旨在大规模网络的早期传播阶段实现快速源头追溯。其通过不在集合  $O$  中的所有节点到集合  $O$  中的传感器的路径和最短来确定传感器组:

$$GS(G, O) \approx \min_{v_i \in (V/O)} d(v_i, O) \quad (1)$$

其中,  $(V/O)$  指源候选集,  $d(v_i, O)$  为节点到传感器的距离函数。进一步,采用 3 种方法执行源推断<sup>[29]</sup>,从图  $G$  中的候选集  $(V/O)$  利用  $O_Y$  记录的有限信息来推断源:

$$\hat{s} = \underset{v \in V_\theta}{\operatorname{argmin}} \left( \sum_{o \in O_Y} d_{o,v} \right)^p \cdot \left( \sum_{o \in O_Y} \otimes (t_o, d_{o,v}) \right)^q \cdot rp(v) \quad (2)$$

通过这种方法,研究人员能够在网络的早期阶段有效地定位传播源头,从而为信息控制或其他相关网络管理活动提供重要的决策支持。Hou

等<sup>[30]</sup>设计了用户中心化传感器定位框架，在真实传播场景下单源定位时延降低至8.2 min。

### 2.3 基于快照观察的方法

传感器观察模式解决了空间维度的监测成本问题，而快照观察模式从时域角度解决了连续监测困难。其通过在特定时间点对网络进行状态的快照式观察，以捕捉网络状态随时间变化的动态过程。Wang等<sup>[31]</sup>通过收集网络在多个时间点的独立且随机采集的快照数据，可以实现近似连续完整观察网络的效果<sup>[31]</sup>。

快照观察方法在展示网络状态随时间变化方面显示出显著的效能。Cai等<sup>[32]</sup>将Twitter用户转发关系建模为无向图，令用户为节点，转发关系为边。其采用传染病模型，提取用户转发状态的时序依赖快照，并基于快照集推断初始推文的发布者、发布时间以及不同信息分支的传播速度。

然而，在快照观察中，部分节点状态可能未知或未被观察到，这要求研究者在分析时引入不同粒度的时间戳来标记快照顺序。为应对这一挑战，研究者尝试利用快照观察模式来降低扩散网络分析的数据量和复杂性。例如，Jiang等<sup>[33]</sup>采用快照观察模式，针对时变网络中的溯源问题，将动态网络解构为一系列静态快照，并运用反向传播模型来缩小潜在源节点的范围。最终，通过扩散模型在疑似源节点集合中进行最大似然估计的推断。此外，Hou等<sup>[34]</sup>基于离散的快照集合，提出了一种TGASI（temporal sequence based graph attention source identification）方法。该方法旨在解决动态感染场景中，由用户互动稀疏导致的源定位准确性降低的问题。在该框架中，编码器负责通过估计两个用户间的影响概率来生成多维特征，而解码器则采用时间自注意机制，以区分不同时间戳中预测源的重要性，从而提高源头识别的精确度。在此基础上，设计了一类复合的损失函数来进一步适应源定位任务：

$$\mathcal{L} = \mathcal{L}_{\text{Entropy}}(R_{\text{hot}}, R_{\text{hot}}^*) + \mathcal{L}_{\text{MSE}}(R_{\text{hot}}, H_{\text{hot}}^{s_i}) + \mathcal{L}_G(R_{\text{hot}}, R_{\text{hot}}^*) \quad (3)$$

其中，使用二元交叉熵作为训练TGASI完整过程的主要损失。使用均方误差作为编码器损失来约束单个时间戳的信源概率预测的学习过程。其中 $\mathcal{L}_G$ 是一种设计的辅助损失，用于增强TGASI

在定位任务上的学习能力。算法伪代码如下。

#### 算法1 TGASI算法伪代码

**输入** 社交网络中的一系列带有时间戳的感染快照  $G_{s_j}$

**输出** 预测的谣言源集合  $R^*$

- 1) **begin**
- 2) 估计影响概率矩阵  $W$
- 3) **for** 每个时间戳  $s$  **do**
- 4)     生成粗粒度源概率特征  $H_{s1}$
- 5)     生成动态感染特征  $H_{s2}$  和  $H_{s3}$
- 6)     生成静态拓扑特征  $HG$
- 7)     将特征  $H_s$  进行拼接
- 8) **end for**
- 9) **for** 每个时间戳  $s$  **do**
- 10)     将编码器的嵌入  $H_{s1}, H_{s2}, H_{s3}, HG$  输入到 Bi-GRU 解码器
- 11)     使用前向 GRU 根据时间戳  $s_1$  到  $s_c$  的快照
- 12)     使用后向 GRU 推断源
- 13)     **for** 每个节点  $v$  **do**
- 14)         合并前向和后向 GRU 的输出  $\hat{R}_f(v)$
- 15)     **end for**
- 16) **end for**
- 17) **for** 每个时间戳  $s_i$  **do**
- 18)     计算不同时间戳的源预测概率的权重
- 19)     使用 K 头注意力机制计算节点  $v$  在时间戳  $s_i$  的最终预测  $\hat{R}'_i(v)$
- 20)     **end for**
- 21)     根据预测概率选择前  $Z$  个节点作为预测
- 22) **end**

随着动态图（Dynamic Graph, DG）问题不断涌现，研究者将动态关联建模方法引入快照观察模式中以解决复杂多变的时空信息溯源问题。Hou等<sup>[35]</sup>提出了一类 DAVA（DAG-aware variational autoencoder）架构，利用社交传播的多平台快照数据生成潜在扩散图以建模跨平台传播的隐式关联。Wang等<sup>[36]</sup>提出了一类无时间戳扩散网络推断算法，基于不完整快照数据重构多源传

播路径并恢复传播网络的拓扑结构。随着多平台用户特征建模工作不断展开<sup>[37]</sup>, Wang 等<sup>[38]</sup>提出 DSLF (dual-channel source localization framework), 通过融合多平台传播快照数据, 利用隐式传播特征关联相似传播事件, 解决异构数据下的多源定位问题。上述研究推动了社交网络溯源从单源静态分析向多源动态协同推理的跨越, 为应对信息生态中的复杂传播挑战提供了方法论基础。

## 2.4 各类观察模式下溯源方法对比

不同信息观察模式下的扩散网络溯源方法在技术路径、适用场景与理论边界上存在显著差异, 其核心特征可通过多维度对比分析进行系统总结。

完全观察方法以全节点实时监控为特征, 在传播路径重构精度与动力学建模完备性方面<sup>[47]</sup>具有理论优势。其采用 SIR/SIS 经典传播模型与最大似然估计法, 可精确解析网络微观传播机制。然而, 该方法受限于高昂的数据采集成本及隐私泄露风险, 仅适用于小规模实验网络验证场景。

传感器观察方法通过稀疏节点部署 (通常覆盖 5%~20% 节点) 实现成本可控的连续监测。典型算法如 PBSI 算法<sup>[25]</sup>与 GRSL 方法<sup>[28]</sup>, 利用传感器节点的传播方向记录数据, 在早期传播阶

段实现源头定位。其优势在于可嵌入差分隐私机制, 但存在传感器部署策略敏感性问题: 当传感器密度低于 10% 时, 路径盲区导致的定位误差呈指数级增长<sup>[27]</sup>。该方法尤其适用于社交网络谣言追踪与物联网设备传播监测等大规模场景。

快照观察方法采用离散时间点采样策略, 通过 TGASI 时间注意力模型<sup>[34]</sup>与反向传播算法<sup>[33]</sup>实现动态网络分析。其数据采集量较连续观察降低 60%~80%。快照观察方法支持历史信息扩散回溯分析, 如社交媒体虚假信息传播重构。但时间分辨率受采样间隔制约, 当大于传播特征时间尺度时, 插值误差累积效应将导致溯源准确率下降高于 37%<sup>[34]</sup>。该方法在时变网络研究与低频率传播事件分析中展现独特价值。

3 类观察模式下溯源方法对比总结见表 1。结果表明, 基于完全观察的溯源方法奠定了扩散网络溯源方法的理论基础, 基于传感器观察的溯源方法在即时工程实践中有较好的应用价值, 基于快照观察的溯源方法从信息历史扩散的角度进行分析推演。3 类观察模式共同推动溯源技术向“低侵入-高精度-强泛化”方向演进。

## 3 扩散网络源节点数量

在明确传播模型与观察模式的基础上, 源节点数量直接影响扩散网络溯源任务的复杂度和策略。本节主要介绍了单源扩散网络以及多源扩散

表 1 3 类观察模式下溯源方法对比总结

Table 1 Comparative analysis of source localization methodologies across three observation paradigms

| 对比维度   | 完全观察方法                                                     | 传感器观察方法                                                                                                                                                    | 快照观察方法                                                                                                                                                              |
|--------|------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 典型算法   | Gaussian 方法 <sup>[39]</sup><br>Bayesian 方法 <sup>[40]</sup> | PBSI 方法 <sup>[25]</sup><br>GFNL 方法 <sup>[27]</sup><br>GRSL 方法 <sup>[28]</sup><br>TRBS 方法 <sup>[26]</sup><br>KC 方法 <sup>[13]</sup><br>HC 方法 <sup>[41]</sup> | LPSI 方法 <sup>[42]</sup><br>GCNSI 方法 <sup>[43]</sup><br>GCSSI 方法 <sup>[44]</sup><br>IVGD 方法 <sup>[45]</sup><br>SL-VAE 方法 <sup>[46]</sup><br>TGASI 方法 <sup>[34]</sup> |
| 数据采集特性 | 全节点状态覆盖<br>静态网络场景下的完整数据采集                                  | 局部节点动态监控<br>依赖传感器部署密度与覆盖范围                                                                                                                                 | 离散时间戳下的网络状态捕捉<br>动态网络多阶段数据聚合                                                                                                                                        |
| 技术优势   | 利于实现溯源方法与动力学建模耦合<br>理论模型完备性高                               | 具备即时监控溯源能力<br>适用于大规模网络的低成本部署                                                                                                                               | 数据采集复杂度低<br>支持动态网络时序分析                                                                                                                                              |
| 技术缺陷   | 用户隐私泄露风险较高<br>全节点监控资源消耗大                                   | 传感器部署算法耗时较长<br>早期传播阶段定位精度受限                                                                                                                                | 快照缺失影响模型连续性<br>多次采样计算资源消耗大                                                                                                                                          |
| 动态网络适度 | 仅适用于静态网络分析                                                 | 支持实时动态调整<br>依赖传感器响应时延                                                                                                                                      | 通过时间序列快照重构动态过程需结合传播模型实现快照补全                                                                                                                                         |
| 应用场景   | 小规模封闭网络溯源<br>理论研究中的基准验证                                    | 社交网络谣言追踪<br>物联网设备异常传播检测                                                                                                                                    | 社交网络谣言追踪<br>历史流行病学传播路径重建                                                                                                                                            |

网络, 梳理了解决从单源问题到复杂多源问题的各类方法, 以及如何解决传播路径交叉感染等挑战。

### 3.1 针对单源扩散网络的方法

在网络信息传播的研究领域, 特别是在追踪和识别信息源节点方面, 相关技术根据传播源的数量主要分为两类: 单源溯源和多源溯源。单源溯源作为较早被探索的分支, 专注于从复杂网络中识别单一的信息源节点。

在该领域内, Shah等<sup>[10]</sup>首次系统地探讨了单一信源识别问题, 提出了基于树状静态网络模型, 利用极限概率传播路径数来追踪并识别中心源节点的方法, 为后续的研究奠定了基础。他们在此基础上, 提出信息的传播遵循宽度优先搜索原则, 这一假设拓宽了中心源节点概念在一般网络环境中的应用范围。Dong等<sup>[48]</sup>研究了单源扩散网络溯源, 通过预设一组部分候选源节点, 并在已知的先验信息条件下, 开发了一种预测局部中心源节点的新方法, 这为识别和追踪信息源提供了更高的灵活性和准确性。Zhu等<sup>[15]</sup>在这一系列研究的基础上, 提出了基于网络传播路径采样的方法, 并成功证明了在树状静态网络图中, 通过此方法可以有效识别Jordan中心节点。Jordan中心节点是一种特殊的中心节点, 能够最小化到网络中其他所有节点的最大距离期望, 从而在理论上优化了信息源的定位。

在这些理论成果的基础上, 研究者进一步考虑了信息观测模式的差异以及异构网络不同传播率中的信息扩散等问题<sup>[31]</sup>。这些扩展研究, 例如Kesavareddigari等<sup>[49]</sup>提出的TC (types centre) 概念, 旨在更准确地估计树状静态网络中的源节点<sup>[49]</sup>。此外, 研究者不断尝试将树状网络中的溯源技术扩展应用到更广泛的网络结构中, 包括高斯方法<sup>[50]</sup>、贝叶斯推理<sup>[40]</sup>等经典方法, 以增强单一源节点识别的准确性和应用的广泛性。

### 3.2 针对多源扩散网络的方法

单源溯源方法为网络传播研究奠定了重要基础, 但其单一传播起点的核心是假设在现实复杂场景中存在显著局限性。基于SI模型的多源溯源问题研究首先由Prakash等<sup>[9]</sup>提出并开展研究。他们采用最小描述长度 (minimum description

length, MDL) 策略来确定多源节点的数量, 并进一步通过考察各候选源节点周边未受感染邻居对已感染节点的免疫权重, 以筛选出最合适的源节点。随后, Chen等<sup>[51]</sup>通过引入MJC (multi Jordan centre) 方法, 推进了多源节点识别的研究。Jiang等<sup>[13]</sup>提出的KC (K-centre) 聚类算法概念, 旨在无向带权网络中识别多个源节点, 展示了一种确定性聚类策略, 其核心在于识别网络的度量中心, 从而使网络中其他节点到最近中心的距离最小化。此方法通过定义GED (graph effective distance) 来改造原始网络结构。有效距离作为衡量网络中节点间交互强度的量度, 常用于模拟和理解复杂网络中的动态过程。有效距离通常通过传输概率的逆对数来计算:

$$d(u, v) = a^{-w(u, v)} \quad (4)$$

其中,  $a$  为图距离常数, 有效距离与权重呈负相关。基于这一原理, 研究者进而利用容量约束网络Voronoi图<sup>[52]</sup>进行多源节点区域划分。考虑到现实世界中多源节点可能不会同时启动传播, Ji等<sup>[41]</sup>引入了HC (heavy centre) 概念, 开发了一个多源节点框架。此外, Tang等<sup>[53]</sup>和Ji等<sup>[54]</sup>在后续研究中引入了Gromov方法, 该方法通过Gromov矩阵描述空间中各点之间的距离关系, 用于多源节点推断分析。

随着研究的深入, 研究者发现上述提到的大部分模型泛化能力较弱, 在处理现实世界复杂社交网络中的信息传播现象时存在局限。因此, 后续研究开始探索不依赖于特定信息传播模型的数据驱动方法, 以更好地捕捉和分析复杂网络中的信息传播行为。标签传播算法<sup>[42]</sup>和图神经网络算法<sup>[43]</sup>是其中的两个标志性工作。具体地, Wang等<sup>[42]</sup>提出的基于标签传播的多源溯源 (label propagation based source identification, LPSI) 算法, 开创了使用标签传播技术进行信息源溯源研究的先河。

针对更加动态复杂的多源溯源问题, 图神经网络被广泛应用于处理信息的传播和扩散特性。在近年的研究中, Dong等<sup>[43]</sup>开发了基于图卷积网络的源识别 (graph convolutional network source identification, GCNSI) 深度学习模型, 旨在不预先了解底层传播模型的情况下, 定位社交

网络中的多个谣言源。该研究通过利用谣言传播过程中的节点多阶邻居信息建立节点表示,采用谱域卷积来解决节点标签的整数限制,从而提升了源节点预测的精度。GCNSI 的算法伪代码如下所示。

#### 算法2 GCNSI 算法伪代码

**输入** 社交网络图  $G=(V, E)$ , 其中  $V$  是节点集合,  $E$  是边集合,  $Y_{sj}$  是节点状态集合

**输出** 预测的谣言源集合  $R^*$

```

1  begin
2  对每个节点  $v \in V$ , 初始化其特征表示  $h_v$ 
3  for 每个时间截  $s$  do
4    for 每个节点  $v$  在图  $G$  中 do
5      计算节点  $v$  的高阶邻居信息
6      更新节点  $v$  的特征表示  $h_v$ 
7    end for
8  end for
9  for 每个节点  $v$  在图  $G$  中 do
10   if 节点  $v$  特征表示满足谣言源条件
11     then
12       将节点  $v$  添加到  $R^*$ 
13   end if
14 end for
15 return  $R^*$ 
16 end

```

在此基础上, Dong 等<sup>[44]</sup>加入了语义信息传递, 设计了基于图约束的序列化源识别 (graph constraint based sequential source identification, GCSSI) 方法。然而, 该方法受到一定预设规则的限制, 限制了其在处理更复杂场景时的灵活性和准确度。对此, Wang 等<sup>[45]</sup>通过设计一个端到端的框架 IVGD (invertible validity-aware graph diffusion) 方法, 成功摆脱了对预设规则的依赖, 进一步优化了基于图卷积神经网络的溯源算法性能。这一进步标志着模型在不依赖于先验知识的前提下, 能够更加准确地识别和定位信息传播的源头, 为复杂网络环境下的溯源问题提供了更加有效的解决策略。此外, Ling 等<sup>[46]</sup>提出的源定位变分自动编码器 (source localization variational auto-encoder, SL-VAE) 模型, 通过结合正向扩散估计模型和深度生成模型, 为在任意扩散

模式下定位扩散源提供了一种创新的解决方案, 尤其在量化溯源过程中的不确定性方面表现出色。Transformer<sup>[55]</sup>近年来也常被用于图学习中, 如 Graphformer 被用于图嵌入的学习。Graphformer 模型如图 4 所示。




图4 Graphformer 示意  
Figure 4 Diagram of Graphformer

Graphformer 将图结构信息引入 Transformer, 并增设了多个针对图特征的 Encoding 部分, 广泛应用于诸如图像描述生成、图像推理、分子设计等领域, 从而为这些领域的任务带来更好的性能和效果。Graphformer 的出现丰富了 Transformer 模型的应用场景, 同时进一步推动了扩散网络溯源领域的发展。

## 4 受限感知溯源模型

随着溯源理论渐趋完善, 在理想场景下的溯源方法已取得显著突破。然而, 在扩散过程较长、节点分布空间较广及监测人员不足等现实场景下, 囿于工程实现的可行性与成本阈值, 全面连续地监测现实世界的扩散过程并不总能完全实现。在工业、交通和社会管理等领域, 基于受限感知条件的溯源模型有助于追踪复杂、庞大系统的运作状况和性能表现, 为系统管理和优化提供数据支持和决策依据。因此, 在最大限度控制人力、资金等限制条件下, 如何利用受限条件进行扩散网络溯源在未来的工程应用中至关重要。受

限感知条件涉及在信息获取和处理过程中面临的限制，包括扩散网络拓扑结构缺失、离散快照缺失、节点标签缺失、不确定性观测状态等方向。

在现实世界中，网络系统常常展现出庞大而复杂的拓扑结构，包含大量的未知节点和隐藏的连接关系，这种网络拓扑不完全的情景对信息溯源研究提出了新的挑战。为了在这种约束条件下实现有效的信息溯源，研究者需要深入探索和开发新的策略和方法。一种可行的途径是采用基于部分观察节点的策略，利用已知的网络节点和连接信息来推断整个网络中的未知部分，如Luo等<sup>[56]</sup>定义了一个受限感知条件下的SI模型感染源估计问题，其利用Jordan中心模型预测出与产生有限观测值的最可能感染路径相关的源节点。另一些方法依赖于对现有数据的深入分析和理解，通过有限的已知信息来揭示和预测网络中未观察到的拓扑结构。Kumar等<sup>[57]</sup>率先提出TARSD（temporally agnostic rumor-source detection）在获得部分粗粒度感染时间戳的条件下，通过预处理步骤修剪图以保留与信息集兼容的有向树，并采用结合Aldous算法和拒绝采样的MCMC（Markov chain monte Carlo）方法推导一类极限概率估计器进行溯源。Han等<sup>[58]</sup>在TENDS（statistical estimation of diffusion network topologies）模型中，同样结合MCMC方法进行拓扑网络的重建，提出了一个新的评分标准，该标准能够基于感染状态结果估计目标扩散网络潜在拓扑结构的可能性，并具有较低的统计误差。由于所提出的评分标准是可分解的，问题转化成在网络中为每个节点找到一组最可能的父节点，以最大化局部评分。Huang等<sup>[59]</sup>提出了基于极限节点分布概率的不完全观察源检测学习（learning from incomplete diffusion observations, LIDO）模型，在TENDS等模型的基础上完成了不全知拓扑结构信息溯源任务。其主要提出3个步骤来实现拓扑结构的补全。利用已知节点初步推断未见节点值，并推断目标扩散网络的拓扑结构。首先定义补全拓扑问题的基本对象为有向图 $G=(V,E)$ ，有向边的从属结构为 $(v_j, v_i) \in E$ ，其中 $v_j$ 为父节点， $v_i$ 为子节点。预设扩散结果仅可观察节点的最终感染状态，定义感染状态参数：

$$S = \{ s_i^l | i \in \{1, \dots, n\}, l \in \{1, \dots, \beta\} \} \quad (5)$$

进一步地，定义了节点进入感染状态与节点保持未感染状态的概率可视为其父节点状态的直接后果：

$$p_{s_i^l=1} = 1 - \prod_{v_j \in F_i} (1 - p_{ji} s_i^l) \quad (6)$$

$$p_{s_i^l=0} = \prod_{v_j \in F_i} (1 - p_{ji} s_i^l) \quad (7)$$

随后，定义了满足上述条件的模型优化问题：

$$\begin{aligned} \max \mathcal{G} = & \sum_{\ell=1}^{\beta} \sum_{s_i^{\ell}=1} \ln \left( 1 - \prod_{v_j \in F_i^{(\ell+1)}} (1 - p_{ji} s_j^{\ell}) \right) + \\ & \sum_{\ell=1}^{\beta} \sum_{s_i^{\ell}=0} \ln \left( \prod_{v_j \in F_i^{(\ell+1)}} (1 - p_{ji} s_j^{\ell}) \right) \end{aligned} \quad (8)$$

引入拉格朗日乘子，将受多重约束的优化问题转化为无约束问题，从而简化求解过程：

$$c_i^{\ell} = 1 - s_i^{\ell} - \prod_{v_j \in F_i^{(\ell+1)}} (1 - p_{ji} s_j^{\ell}) \quad (9)$$

$$\mathcal{L} = \mathcal{G} + \sum_{\ell=1}^{\beta} \sum_{s_i^{\ell} \in S^{mis}} \lambda_i^{\ell} c_i^{\ell} \quad (10)$$

最后通过求解针对 $\mathcal{L}$ 的一系列偏导数方程来优化当前概率分布估计，重复上述步骤直到推断的拓扑结构收敛。随后利用多种模块依托补全后的拓扑结构对扩散网络进行溯源。

在依托快照观察模式下，同样会面临离散快照缺失的限制，快照缺失示意如图5所示。由于快照数据仅能捕捉到特定时刻的信息，无法涵盖连续的时间序列，因此在分析过程中可能会遗漏关键的中间状态，进而影响扩散网络溯源的准确性。

在各类数据收集、上传与接收的过程中同样面临着各类问题。如在现实环境中存在某些节点无法正常上传数据，或在数据上传过程中引入了随机噪声，以及在接收端发生了数据遗失，均有可能导致快照集中部分节点信息缺失，节点感染状态缺失示意如图6所示。

在网络中信息传播的源头识别过程中，缺失的节点数据可能导致溯源算法无法准确识别真正的信息源或者传播路径。同样，缺失节点意味着网络的某些连接信息无法被捕获，导致对网络结构特性（如度分布、聚类系数等）的分析存在偏




图5 快照缺失示意

Figure 5 Diagram of missing snapshots




图6 感染状态缺失示意

Figure 6 Diagram of missing infection status

差, 进而影响基于这些结构特性的理论推断和实际应用。Huang 等<sup>[60]</sup>为解决节点仅包含概率感染状态情景, 将扩散网络推理问题表述为概率数据的约束非线性回归, 并设计了一种交替最大化方法 PIND (inferring networks from probabilistic data) 用于迭代更新潜在影响关系存在概率估计及影响关系加强过程。理论上保证了迭代中估计质量的提高。迭代收敛后, 可以根据估计结果识

别目标扩散网络中最可能的影响关系。表 2 针对上述受限感知条件下的溯源方法的受限设定进行分类。

## 5 扩散网络溯源案例分析

本节主要总结与罗列通用扩散网络溯源数据集, 并利用其中部分数据集对本文分类下的典型溯源方法进行了案例实验与分析。

表 2 受限条件溯源方法分类

Table 2 Classification of network localization methods under constrained conditions

| 模型名称  | 拓扑结构  | 缺失条件   | 观察模式  | 传播模型       | 源节点数量 | 节点类型  |
|-------|-------|--------|-------|------------|-------|-------|
| JCE   | 树状/普通 | 拓扑缺失   | 快照观察  | 易感-感染      | 单源    | 同构/异构 |
| TENDS | 普通    | 拓扑缺失   | 快照观察* | 独立级联       | 多源    | 同构    |
| LIDO  | 普通    | 拓扑缺失   | 快照观察* | 独立级联       | 多源    | 同构    |
| TARSD | 树状/普通 | 时间戳缺失  | 快照观察  | 易感-感染/独立级联 | 单源    | 同构    |
| PIND  | 普通    | 感染状态缺失 | 快照观察  | 独立级联       | 多源    | 同构    |

注: 快照观察\*表明仅使用最终感染状态作为观察对象

## 5.1 数据集

在网络科学和社会网络分析领域，本文总结与罗列包含斯坦福大学在2020年建立的网络分析项目<sup>[61]</sup>的通用扩散网络溯源数据集。Karate数据集代表某大学空手道俱乐部的社交网络，记录了34名俱乐部成员之间的社交关系；Jazz数据集包含了198位爵士乐手之间的合作关系。这些数据基于1912年至1940年间录制的爵士乐专辑；Email数据集从一个大型欧洲研究机构收集，包括1 133名员工之间的电子邮件交换情况；P2P数据集包含了蛋白质间的相互作用信息，其中，蛋白质节点表示生物体蛋白质，边代表它们之间的相互作用；Facebook数据集包括4 039名用户及其之间的88 234条友谊链接；PG数据集代表了美国西部的电力网结构，包括发电站、变电站和电缆的连接情况。上述网络统计特性见表3。

表3 部分静态网络统计特性

Table 3 Partial static network statistical characteristics

| 网络       | 节点    | 边      | 平均度    | 直径 | 平均路径长度 | 平均聚类系数 |
|----------|-------|--------|--------|----|--------|--------|
| Karate   | 34    | 78     | 4.592  | 5  | 2.414  | 0.571  |
| Jazz     | 198   | 2 742  | 27.724 | 8  | 3.362  | 0.627  |
| Email    | 1 133 | 5 451  | 9.622  | 7  | 2.768  | 0.497  |
| P2P      | 2 375 | 11 693 | 9.834  | 11 | 4.820  | 0.457  |
| Facebook | 4 039 | 88 234 | 43.691 | 8  | 3.693  | 0.606  |
| PG       | 4 941 | 6594   | 2.669  | 46 | 18.989 | 0.080  |

## 5.2 案例分析

在上述数据集中，选择Karate、Jazz和Facebook数据集，这些数据具有高度的平均聚类系数和短平均路径长度，这是典型的“小世界”网络特性，即网络中的任意两个节点可以通过相对较少的步骤连接起来。此外，上述网络显示明显的社区结构，意味着这3种网络具有较高的节点聚类系数，节点在这些聚类内部的连接比跨聚类的连接更加频繁。因此，这些数据集适合作为本文进行扩散网络溯源案例实验的实验对象。

一般选用F1-score及AED（average error distance）作为评价指标：

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (11)$$

$$\Delta_{AED} = \min_{r^* \in \text{permutation}(R^*)} \sum_{i=1}^Q \frac{d(r_i^*, r_i)}{Q} \quad (12)$$

其中 $r^* \in \text{permutation}(R^*)$ 指真实源序列的所有排列方式， $Q$ 表示序列中的元素数量， $r$ 表示预测源序列。 $d(\cdot)$ 表示跳数。

在3个数据集上对各分类下的典型方法进行多源扩散网络溯源实验，实验结果如图7所示。




图7 扩散网络溯源案例实验结果

Figure 7 Results of network source localization case experiments

**Jordan模型：**基于网络传播路径采样模型识别Jordan中心。

**GCNSI模型：**基于GCN结构信息传递模型的代表学习。

**GCSSI模型：**基于GCN结构与语义信息传递模型的代表学习。

**ResGCN模型：**基于残差连接GCN模型的代表学习。

**SL-VAE模型：**结合正向扩散估计模型和深度生成模型的代表学习。

**TGASI模型：**基于时空图注意力机制模型的代表学习。

如图 7 所示, 基于完全观察假设的传统模型如 Jordan 模型在小数据集上表现较好, 但在中大型网络上表现欠佳。而基于快照观察方法的结合图表示学习的深度学习模型, 如 TGASI 模型在各类数据集上表现较为稳定。这在一定程度上体现了面对复杂扩散网络溯源问题时, 采用深度学习的图溯源框架值得进一步的探索。

GCNSI 和 GCSSI 模型均采用 GCN 框架, 但 GCSSI 通过语义信息融合扩展了 SIR 模型参数空间, 实验显示, 在社区结构显著的 Jazz 数据集上, GCSSI 的 *F1-score* 相比纯结构模型提升 14.6%, 验证了传播模型与表征学习耦合的技术优势。

ResGCN 模型采用残差连接增强多源信号分离能力, 在节点密度最高的 Facebook 数据集上实现了 AED=2.3 跳, 较单源优化的 Jordan 模型降低了约 61%。这进一步说明多源问题并非单源问题的简单重复, 需要进一步设计多源方法来解耦节点关联性。

## 6 结束语

扩散网络溯源方法经历了传播模型未知到丰富的传播模型建立的底层理论发展, 从完全观察到多种观察模式的应用场景拓展, 从单源节点到多源节点的任务复杂度提升, 以及从完全感知到受限感知的数据处理能力增强。随着深度学习等学科领域的发展, 扩散网络溯源方法框架也利用相关技术得以不断优化完善, 并在多种领域任务中展现出更强的泛化能力。本节基于本文内容进行总结并展望下一步工作。

### 6.1 总结

本文主要围绕几类信息观察模式、信息传播模型以及依照扩散网络中源节点数量的不同, 对扩散网络溯源方法进行了分类与总结。首先, 本文根据信息在网络中的传播动力学模型, 即信息传播模型, 归纳了各类模型对溯源方法设计的具体要求和挑战。然后, 本文梳理了信息观察模式对溯源策略选择的影响, 这些模式涉及全网数据可观性与局部信息可获取性的不同情况。随后, 针对扩散网络源节点数量差异, 讨论了溯源技术的复杂性及其解决策略的变化。进一步, 本文探讨了在各类受限感知条件下,

现有的扩散网络溯源方法的应用与优化。最后, 本文利用现有网络数据集, 对各分类典型方法进行了案例实验。

### 6.2 展望

未来的扩散网络溯源研究将面临数据治理与算法效能协同优化的挑战, 同时也将迎来新的发展机遇。随着网络活动日益复杂, 用户愈发注重个人网络利益关切。网络空间隐私安全保护要求溯源模型对用户数据的处理必须在法律和伦理框架内。同时, 在“毒数据”“数据孤岛”“数据烟囱”等感知端困境下, 持续推进受限感知条件的扩散网络溯源研究, 以应对数据不完备问题。

面对网络空间隐私安全保护问题, 未来可以通过构建在法律保护下的更贴切、更有效的图表特征来解决。从节点级特征出发, 考虑如何在数据集构建端形成新的用户特征抽象及收集<sup>[62]</sup>, 并在用户画像构建中嵌入隐私预算约束<sup>[37]</sup>。从图级特征出发, 考虑如何构建新的描述扩散网络特征的参数。同时, 考虑进一步筛选与优化模型输入端需求数据集, 推进感知端数据采集范式革新<sup>[63]</sup>, 通过设计面向溯源任务的最优观测策略, 在减少数据冗余的同时提升关键传播路径的捕获概率。综合上述方案, 共同支撑溯源端算法的进一步发展。

进一步, 受限感知条件下的扩散网络溯源模型将是应对现实网络风险挑战的另一个重要方向。本文对当前针对受限感知条件的扩散网络溯源研究进行了初步的总结。未来工作可以从明确噪声来源及其特征分布出发, 将图数据集上不同类型的噪声因素纳入考虑, 形成多层次的模型框架。针对受限感知条件, 需重点突破噪声建模技术, 建立包含噪声分类、影响量化、补偿机制的 3 阶段处理流程<sup>[47]</sup>, 相关工作仍有待进一步研究。

### 参考文献:

- [1] 刘爱琴, 陈宋敏, 赵慧敏. 基于 Web3.0 的知识交流与传播服务平台构建[J]. 图书馆工作与研究, 2017(10): 48-53.  
LIU A Q, CHEN S M, ZHAO H M. Construction of the knowledge exchange and communication service platform based on Web3.0[J]. Library Work and Study, 2017(10): 48-53.

- [2] ZHU H M, ZHANG S T, JIN Z. The effects of online social networks on tacit knowledge transmission[J]. *Physica A: Statistical Mechanics and Its Applications*, 2016, 441: 192-198.
- [3] 刘伟. 热点事件网络谣言的内生逻辑与规制[J]. *政法论丛*, 2023(4): 148-160.  
LIU W. Internal logic and rules of Internet rumors of hot events[J]. *Journal of Political Science and Law*, 2023(4): 148-160.
- [4] BERGER D. Constructing crime, framing disaster: routines of criminalization and crisis in hurricane Katrina[J]. *Punishment & Society*, 2009, 11(4): 491-510.
- [5] GAN T, HAN K, HUANG H, et al. Diffusion network inference from partial observations[C]//*Proceedings of the 30th AAAI Conference on Artificial Intelligence*. 2021: 7493-7500.
- [6] WANG Q Y, JIN Y H, LIN Z, et al. Influence maximization in social networks under an independent cascade-based model[J]. *Physica A: Statistical Mechanics and Its Applications*, 2016, 444: 20-34.
- [7] GURSOY F, GUNNEC D. Influence maximization in social networks under deterministic linear threshold model[J]. *Knowledge-Based Systems*, 2018, 161: 111-123.
- [8] CHENG J, ADAMIC L, DOW P. Can cascade be predicted[C]//*Proceedings of the 23rd International Conference on World Wide Web*. 2014: 925-936.
- [9] PRAKASH B A, VREEKEN J, FALOUTSOS C. Spotting culprits in epidemics: how many and which ones[C]//*Proceedings of the 2012 IEEE 12th International Conference on Data Mining*. Piscataway: IEEE Press, 2012: 11-20.
- [10] SHAH D, ZAMAN T. Rumors in a network: who's the culprit[J]. *IEEE Transactions on Information Theory*, 2011, 57(8): 5163-5181.
- [11] WANG X, NI W, ZHENG K F, et al. Virus propagation modeling and convergence analysis in large-scale networks[J]. *IEEE Transactions on Information Forensics and Security*, 2016, 11(10): 2241-2254.
- [12] PRAKASH B A, VREEKEN J, FALOUTSOS C. Efficiently spotting the starting points of an epidemic in a large graph[J]. *Knowledge and Information Systems*, 2014, 38(1): 35-59.
- [13] JIANG J J, WEN S, YU S, et al. K-center: an approach on the multi-source identification of information diffusion[J]. *IEEE Transactions on Information Forensics and Security*, 2015, 10(12): 2616-2626.
- [14] LUO W Q, TAY W P. Identifying infection sources in large tree networks[C]//*Proceedings of the 2012 9th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks (SECON)*. Piscataway: IEEE Press, 2012: 281-289.
- [15] ZHU K, YING L. Information source detection in the SIR model: a sample-path-based approach[J]. *IEEE/ACM Transactions on Networking*, 2016, 24(1): 408-421.
- [16] SONG L P, JIN Z, SUN G Q. Modeling and analyzing of botnet interactions[J]. *Physica A: Statistical Mechanics and Its Applications*, 2011, 390(2): 347-358.
- [17] YAO Y, LUO X R, GAO F X, et al. Research of a potential worm propagation model based on pure P2P principle[C]//*Proceedings of the 2006 International Conference on Communication Technology*. Piscataway: IEEE Press, 2006: 1-4.
- [18] JIANG C X, CHEN Y, RAY LIU K J. Evolutionary dynamics of information diffusion over social networks[J]. *IEEE Transactions on Signal Processing*, 2014, 62(17): 4573-4586.
- [19] WANG Y F, VASILAKOS A V, MA J H, et al. On studying the impact of uncertainty on behavior diffusion in social networks[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2015, 45(2): 185-197.
- [20] LI M C, LIU F M. Game theory-based network rumor spreading model[C]//*Proceedings of the 2016 International Conference on Network and Information Systems for Computers (ICNISC)*. Piscataway: IEEE Press, 2016: 89-94.
- [21] LIU F M, LI M C. A game theory-based network rumor spreading model: based on game experiments[J]. *International Journal of Machine Learning and Cybernetics*, 2019, 10(6): 1449-1457.
- [22] AGHA MOHAMMAD ALI KERMANI M, FATEMI ARDESTANI S F, ALIAHMADI A, et al. A novel game theoretic approach for modeling competitive information diffusion in social networks with heterogeneous nodes[J]. *Physica A: Statistical Mechanics and Its Applications*, 2017, 466: 570-582.
- [23] LUO W Q, TAY W P, LENG M. Infection spreading and source identification: a hide and seek game[J]. *IEEE Transactions on Signal Processing*, 2016, 64(16): 4228-4243.
- [24] MITRA R, MCGOUGH S F, CHAKRABORTI T, et al. Learning from data with structured missingness[J]. *Nature Machine Intelligence*, 2023, 5(1): 13-23.
- [25] ZHU K, CHEN Z, YING L. Catch' Em all: Locating multiple diffusion sources in networks with partial observations[C]//*Proceedings of the 29th Innovative Applications of Artificial Intelligence Conference and 7th Symposium on Educational Advances in Artificial Intelligence*. 2017:1.
- [26] SHEN Z S, CAO S N, WANG W X, et al. Locating the source of diffusion in complex networks by time-reversal backward spreading[J]. *Physical Review E*, 2016, 93(3): 032301.
- [27] WANG Z, HOU D P, GAO C, et al. A rapid source localization method in the early stage of large-scale network propagation[C]//*Proceedings of the ACM Web Conference 2022*. New York: ACM, 2022: 1372-1380.
- [28] WANG Z, HOU D P, GAO C, et al. Lightweight source localization for large-scale social networks[C]//*Proceedings of the ACM Web Conference 2023*. New York: ACM, 2023: 286-294.
- [29] HOU D P, GAO C, WANG Z, et al. Random full-order-coverage based rapid source localization with limited observations for large-scale networks[J]. *IEEE Transactions on Network Science and Engineering*, 2024, 11(5): 4213-4226.
- [30] HOU D P, WANG Y C, GAO C, et al. New localization frameworks: user-centric approaches to source localization in real-world propagation scenarios[C]//*Proceedings of the 33rd ACM International Conference on Information and Knowledge Management*. New York: ACM, 2024: 839-848.
- [31] WANG Z X, DONG W X, ZHANG W Y, et al. Rooting our rumor

- sources in online social networks: the value of diversity from multiple observations[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2015, 9(4): 663-677.
- [32] CAI K C, XIE H, LUI J C S. Information spreading forensics via sequential dependent snapshots[J]. *IEEE/ACM Transactions on Networking*, 2018, 26(1): 478-491.
- [33] JIANG J J, WEN S, YU S, et al. Rumor source identification in social networks with time-varying topology[J]. *IEEE Transactions on Dependable and Secure Computing*, 2018, 15(1): 166-179.
- [34] HOU D P, WANG Z, GAO C, et al. Sequential attention source identification based on feature representation[C]//*Proceedings of the Thirty-Second International Joint Conference on Artificial Intelligence*. 2023: 4794-4802.
- [35] HOU D P, GAO C, LI X L, et al. DAG-aware variational autoencoder for social propagation graph generation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2024, 38(8): 8508-8516.
- [36] WANG Y C, HOU D P, GAO C, et al. Inferring information diffusion networks without timestamps[C]//*Proceedings of the 33rd ACM International Conference on Information and Knowledge Management*. New York: ACM, 2024: 2453-2461.
- [37] HOU D P, YIN S, GAO C, et al. Propagation dynamics of rumor vs non-rumor across multiple social media platforms driven by user characteristics[EB]. 2024.
- [38] WANG Z, HOU D P, YIN S, et al. Joint source localization in different platforms via implicit propagation characteristics of similar topics[C]//*Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence*. 2024: 2424-2432.
- [39] PINTO P C, THIRAN P, VETTERLI M. Locating the source of diffusion in large-scale networks[J]. *Physical Review Letters*, 2012, 109(6): 068702.
- [40] ALTARELLI F, BRAUNSTEIN A, DALL'ASTA L, et al. Bayesian inference of epidemics on networks via belief propagation[J]. *Physical Review Letters*, 2014, 112(11): 118701.
- [41] JI F, TAY W P, VARSHNEY L R. An algorithmic framework for estimating rumor sources with different start times[J]. *IEEE Transactions on Signal Processing*, 2017, 65(10): 2517-2530.
- [42] WANG Z, WANG C K, PEI J S, et al. Multiple source detection without knowing the underlying propagation model[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2017, 31(1): 217-223.
- [43] DONG M, ZHENG B L, QUOC VIET HUNG N, et al. Multiple rumor source detection with graph convolutional networks[C]//*Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. New York: ACM, 2019: 569-578.
- [44] DONG M, ZHENG B L, LI G H, et al. Wavefront-based multiple rumor sources identification by multi-task learning[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2022, 6(5): 1068-1078.
- [45] WANG J X, JIANG J J, ZHAO L. An invertible graph diffusion neural network for source localization[C]//*Proceedings of the ACM Web Conference 2022*. New York: ACM, 2022. 1058-1069.
- [46] LING C, JIANG J J, WANG J X, et al. Source localization of graph diffusion via variational autoencoders for graph inverse problems[C]//*Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2022. 1010-1020.
- [47] XING B, RUPERT T J, PAN X Q, et al. Neural network kinetics for exploring diffusion multiplicity and chemical ordering in compositionally complex materials[J]. *Nature Communications*, 2024, 15: 3879.
- [48] DONG W X, ZHANG W Y, TAN C W. Rooting out the rumor culprit from suspects[C]//*Proceedings of the 2013 IEEE International Symposium on Information Theory*. Piscataway: IEEE Press, 2013. 2671-2675.
- [49] KESAVAREDDIGARI H, SPENCER S, ERYILMAZ A, et al. Identification and asymptotic localization of rumor sources using the method of types[J]. *IEEE Transactions on Network Science and Engineering*, 2020, 7(3): 1145-1157.
- [50] YANG F, YANG S H, PENG Y, et al. Locating the propagation source in complex networks with a direction-induced search based Gaussian estimator[J]. *Knowledge-Based Systems*, 2020, 195: 105674.
- [51] CHEN Z, ZHU K, YING L. Detecting multiple information sources in networks under the SIR model[C]//*Proceedings of the 2014 48th Annual Conference on Information Sciences and Systems (CISS)*. Piscataway: IEEE Press, 2014: 1-4.
- [52] YANG K, SHEKHAR A H, OLIVER D, et al. Capacity-constrained network-voronoi diagram: a summary of results[C]//*Advances in Spatial and Temporal Databases*. Berlin: Springer, 2013: 56-73.
- [53] TANG W C, JI F, TAY W P. Estimating infection sources in networks using partial timestamps[J]. *IEEE Transactions on Information Forensics and Security*, 2018, 13(12): 3035-3049.
- [54] JI F, TANG W C, TAY W P. On the properties of Gromov matrices and their applications in network inference[J]. *IEEE Transactions on Signal Processing*, 2019, 67(10): 2624-2638.
- [55] YANG J H, LIU Z, XIAO S T, et al. GraphFormers: GNN-nested transformers for representation learning on textual graph[EB]. 2021.
- [56] LUO W Q, TAY W P, LENG M. How to identify an infection source with limited observations[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2014, 8(4): 586-597.
- [57] KUMAR A, BORKAR V S, KARAMCHANDANI N. Temporally agnostic rumor-source detection[J]. *IEEE Transactions on Signal and Information Processing Over Networks*, 2017, 3(2): 316-329.
- [58] HAN K Q, TIAN Y, ZHANG Y J, et al. Statistical estimation of diffusion network topologies[C]//*Proceedings of the 2020 IEEE 36th International Conference on Data Engineering (ICDE)*. Piscataway: IEEE Press, 2020: 625-636.
- [59] HUANG H, HAN K Q, XU B C, et al. Reconstructing diffusion networks from incomplete data[C]//*Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence*. 2022. 3085-3091.
- [60] HUANG H, YAN Q, HAN K Q, et al. Learning diffusions under uncertainty[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2024, 38(18): 20430-20437.

- [61] LESKOVEC J. Stanford large network dataset collection[EB]. 2014.
- [62] SUN X G, ZHANG J W, WU X X, et al. Graph prompt learning: a comprehensive survey and beyond[EB]. 2023.
- [63] YAN Q, YANG Y L, YIN K, et al. Diffusion pattern mining[J]. Knowledge and Information Systems, 2025, 67(2): 1101-1129.

#### [作者简介]



崔恒睿（2002-），男，四川成都人，国防科技大学硕士生，主要研究方向为虚假信息溯源。



陈东（1997-），男，湖南岳阳人，国防科技大学博士生，主要研究方向为图异常检测、虚假信息检测。



赵翔（1986-），男，浙江金华人，国防科技大学教授、博士生导师，主要研究方向为知识图谱、高级数据管理、大语言模型。