基于跨层频率与结构精炼的多重网络社区检测

陈 梅†，付豪杰，王 欢，陈永旭，周启辉

(兰州交通大学 电子与信息工程学院，兰州 730070)

摘 要: 多重网络能够同时刻画实体间的多类关系, 社区检测通过识别跨关系层中联系紧密的节点群组, 为揭示复杂系统的整体组织模式与功能关联提供基础. 现有部分网络聚合方法主要依据节点对的跨层连接频率进行融合, 忽略局部拓扑一致性和层内边权信息, 易使得噪声边获得过高权重并干扰社区划分. 鉴于此, 提出一种基于跨层连接频率与局部结构精炼的多重网络社区检测算法 (CNPML). CNPML 自适应融合跨层连接频率, 归一化共同邻居指标和层内边权信息, 构建初始加权融合图; 随后依据局部结构相似性, 对高相似度但未连接的节点对补边, 对低相似度但已连接的节点对删边, 并在精炼后的融合图上采用 Louvain 算法完成社区划分. 多个真实无权和加权多重网络上的实验结果表明, CNPML 在多数数据集和评价指标上取得较优或具有竞争力的结果; 消融实验, 参数分析和运行时间实验验证了各模块的有效性及算法对大规模网络的适应性.

关键词: 多重网络；跨层连接频率；共同邻居；结构精炼；Louvain 算法；社区检测

中图分类号: TP301 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0601

引用格式: 陈梅, 付豪杰, 王欢, 等. 基于跨层频率与结构精炼的多重网络社区检测 [J]. 控制与决策.

Community detection in multiplex networks with cross-layer frequency and structure refinement

CHEN Mei†，FU Hao-jie，WANG Huan，CHEN Yong-xu，ZHOU Qi-hui

(School of Electronic and Information Engineering，Lanzhou Jiaotong University，Lanzhou 730070，China)

Abstract: Multiplex networks capture multiple types of relations among entities, while community detection identifies densely connected node groups across layers to reveal system-wide organization and functional associations. Existing aggregation methods often rely on cross-layer connection frequency while neglecting local topological consistency and intra-layer edge weights, causing noisy edges to receive excessive weights. To address this problem, we propose a multiplex network community detection method via cross-layer frequency and neighborhood perturbation fusion, called CNPML. CNPML constructs an initial weighted fused graph by adaptively integrating cross-layer connection frequency, the normalized common-neighbor index, and intra-layer edge weights. It then adds edges between highly similar unconnected node pairs, removes edges between dissimilar connected pairs, and applies the Louvain algorithm to the refined graph. Experiments on real-world unweighted and weighted multiplex networks show that CNPML achieves superior or competitive performance on most datasets and metrics. Ablation, parameter, and runtime analyses further demonstrate the effectiveness of its components and its scalability under the tested settings.

Keywords: multiplex network； cross-layer frequency； common neighbor； structural refinement； Louvain algorithm；community detection

0 引 言

社区结构是复杂网络中普遍存在的重要拓扑特征, 表现为社区内部节点连接相对紧密, 社区之间连接相对稀疏. 准确识别社区结构能够从介观尺度揭示网络内部的组织模式, 为理解节点的凝聚性, 功能关联及系统的整体结构提供重要依据[1]. 然而, 社区的边界及节点归属通常隐含在复杂的连接关系中, 难以通过直接观察获得, 因而有必要借助社区检测方法识别潜在的节点群组. 因此, 社区检测是揭示复杂网络组织规律, 认识网络结构与功能关系的一项

收稿日期: 2026-06-19；**录用日期:** 2026-09-02.

基金项目: 国家自然科学基金项目 (62266029)；甘肃省重点研发计划项目 (24YFGA036)；甘肃省高等学校产业支撑计划项目 (2022CYZC-36).

†通信作者. E-mail: mei.chen.lzjtu@hotmail.com.

基础任务. 传统单层网络通常只能描述实体之间的一类关系, 难以完整刻画现实系统中多种关系并存的交互特征[2]. 多重网络通过多个网络层描述同一组节点之间的不同类型连接, 为综合分析复杂系统的社区结构提供了更加丰富的信息. 然而, 不同网络层在边规模, 连接密度, 拓扑模式, 噪声水平和信息冗余等方面通常存在明显差异, 同一节点对在不同层中的连接关系也可能表现出一致, 互补或冲突等特征[3-5]. 因此, 如何在保留各层有效结构信息的基础上合理融合跨层关系, 进而识别能够反映多关系系统整体组织特征的统一社区结构, 是多重网络社区检测需要解决的重要问题.

现有多重网络社区检测方法主要包括单层扩展型方法, 网络聚合型方法以及矩阵或张量分解型方法[6-7]. 单层扩展型方法通过引入层间耦合或联合建模, 将传统单层社区检测算法推广至多重网络[6]. 网络聚合型方法首先将多重网络融合为单一加权网络, 进而应用单层社区检测算法, 因其思想与实现简单且能显著降低建模复杂性而受到广泛关注[8-10]. 张量分解型方法则构建高阶张量模型以捕捉层间非线性关系, 通过张量分解提取统一的社区结构[11-15]. 尽管上述方法在各自适用场景下取得了一定效果, 但在信息融合与噪声抑制方面仍面临两个问题: 其一, 现有融合策略多关注节点对是否连接, 对节点对在局部拓扑结构上的相似性利用不足, 容易造成信息损失[16-17]; 其二, 真实网络中存在的噪声边与偶然共现边可能在聚合网络中获得较高权重, 从而模糊真实社区结构并削弱划分稳定性[18].

针对信息融合维度单一的问题, 研究者已尝试从不同角度加以改进. 在网络聚合框架下, 早期方法通常采用线性加权方式对各层邻接矩阵进行合并, 并将跨层频率作为聚合网络的边权[8-9]. 跨层连接频率能够反映节点对在多个关系层中的重复连接程度, 为判断连接的跨层稳定性提供直接依据. 然而, 该指标主要描述连接关系是否重复出现, 无法进一步判断节点对是否具有相似的局部拓扑环境. 当某些偶然连接或噪声边在多个网络层中重复出现时, 仅依据跨层频率进行累积, 可能使其在聚合网络中获得较高权重, 进而削弱社区内部连接与社区间连接之间的区分度. 为克服这一局限, GBS(Graph-Based System) 引入图核方法, 通过度量节点在不同层中的邻域结构相似性来计算融合权重, 在一定程度上融入了局部拓扑信息, 但其图核计算复杂度较高, 难以扩展至大规模网络[9,19]. SCML(Spectral Clustering on Multi-Layer graphs) 采用协同矩阵分解方法, 联合分解各层邻接矩阵以提取统一的节点表示, 能够捕捉跨层潜在关联, 但该算法对参数设置较为敏感[7,9]. PMM(Principal Modularity Maximization) 通过引入灵活的层间耦合项, 允许耦合强度根据节点参与度自适应调整, 试图更好地平衡各层贡献, 但当各层社区结构差异较大时, 基于全局模块度优化的目标仍易陷入局部最优, 难以充分保留层内局部拓扑特征[20]. 总体而言, 如何在融合过程中系统性地融入局部结构相似性, 增强真实连接的权重, 同时避免信息损失, 仍是一个亟待解决的关键问题.

针对噪声边干扰问题, 部分方法通过学习低维表示或低秩近似进行降噪. MPBTV 和 DGFM3 将多重模块度最大化等价转化为平衡全变分最小化问题, 利用图 MBO(Merriman-Bence-Osher) 方案和截断特征分解技术实现高效求解, 但需预先指定社区数量, 且在噪声水平不均时社区识别困难[21]. 张量分解型方法通过低秩结构在一定程度上抑制噪声, 但高维张量的存储与迭代计算开销随节点数和层数增长而显著增加, 限制了其在大规模真实网络上的应用[13-15]. 更为关键的是, 上述方法在网络聚合或表示学习过程中并未显式对噪声边进行结构性削弱, 导致偶然共现边仍可能保留较高权重并干扰社区划分. 因此, 设计一种能在聚合过程中直接增强可信连接, 抑制噪声干扰的高效机制, 是提升多重网络社区检测性能的重要方向.

综合来看, 现有方法在同时利用网络局部信息丰富融合维度, 抑制噪声干扰以增强结构可分性方面仍存在不足. 特别地, 网络聚合型方法因其可解释性和计算效率而具有广泛应用前景, 但目前方法在融合时大多仅依赖跨层共现频率, 未能充分挖掘节点对在局部结构上的相似性, 导致信息损失和噪声干扰问题较为突出.

因此, 本文提出一种基于跨层连接频率与局部结构精炼的多重网络社区检测方法 CNPML. 该方法属于传统无监督, 拓扑结构驱动的网络聚合框架, 不依赖节点属性, 社区标签或模型训练. 首先, 算法统计节点对在不同网络层中的连接情况, 并结合各层结构贡献和层内边权信息构建初始加权融合图, 以描述连接关系的跨层稳定性; 其次, 利用归一化共同邻居指标刻画节点对的局部邻域重叠程度, 并将其作为局部结构调节因子修正融合权重; 在此基础上, 进一步对融合图进行结构精炼, 对局部相似性较高但尚未直接连接的节点对进行补边, 对缺乏局部结构支持的已有连接进行抑制, 从而增强社区内部连接的紧密性及社区边界的可分性; 最后, 在精炼后的加

权融合图上采用 Louvain 算法[22] 获得最终社区划分.

本文的主要工作概括如下: 1) 提出一种基于跨层连接频率与局部结构精炼的多重网络社区检测方法 CNPML, 从连接的跨层稳定性和节点对的邻域重叠程度刻画连接可靠性, 弥补单一频率聚合在局部拓扑信息表达方面的不足; 2) 设计一种基于共同邻居的融合图结构精炼策略, 通过补边与弱连接删除改善融合图的结构表达, 且不依赖监督信息或迭代模型训练; 3) 将所提出的融合与结构精炼框架统一应用于无权和加权多重网络, 多个真实多重网络上的实验结果表明, CNPML 均取得了较好的社区检测结果.

1　相关工作

1.1　网络聚合型多重网络社区检测

网络聚合型方法通过将多个网络层转换为单一加权网络, 再利用现有单层社区检测算法获得统一社区划分[8-10,23]. 该类方法建模过程清晰, 计算开销相对较低, 并具有较好的结构可解释性, 因此成为无监督多重网络社区检测的重要技术路线.

早期聚合方法通常对不同网络层的邻接矩阵进行线性叠加, 或将节点对在各层中的出现次数作为融合边权. 跨层共现频率能够反映节点连接获得多种关系支持的程度, 但难以进一步刻画节点对的局部拓扑关系. CDMA 方法通过分析不同邻接矩阵之间的关联, 结合节点连接的跨层统计信息和高阶结构构建统一网络表示[24]. 该方法扩展了简单线性聚合所利用的结构信息, 但仍主要围绕已有连接进行融合. GBS 方法利用图核度量不同网络层中的邻域结构相似性, 使融合网络能够包含一定的局部拓扑信息[19], 但图核构造与相似性计算会增加算法开销, 且其主要作用是调整已有边权, 未进一步修正融合图中的连接关系.

总体而言, 现有网络聚合方法主要通过跨层共现统计或结构相似性确定融合边权, 较少同时考虑加权网络中的层内连接强度, 具有较高局部结构支持的候选缺失连接, 以及局部结构支持较弱的已有连接. 因此, 如何在保持网络聚合方法轻量化和可解释性的基础上, 联合利用跨层共现信息与局部邻域信息, 并对融合网络进行结构精炼, 是本文重点研究的问题.

1.2　局部结构相似性研究

局部结构相似性通过比较节点邻域的重叠关系刻画节点之间的拓扑接近程度, 已广泛应用于链路预测和社区检测[16]. 在复杂网络中, 同一社区内部节点通常共享较多邻居, 因此局部结构信息能够为节点的潜在社区归属提供依据[25].

共同邻居 (Common Neighbor, CN) 是典型的局部结构相似性指标. Jiang 等基于共同邻居节点聚类熵构建接近相似性度量, 验证了共同邻居信息对社区检测的促进作用[26]. 在此基础上, Asmi 等将聚集系数与共同邻居相似性结合用于局部社区扩展[27]; Xiang 等研究了多种局部结构指标对社区检测性能的影响, 说明邻域重叠信息有助于增强社区结构表达[28]. 现有局部结构相似性研究主要面向单层网络, 而在多重网络中, 跨层频率反映连接的重复性, 局部结构相似性反映连接的邻域支持程度[29-30], 二者具有互补性. 因此, 本文采用归一化共同邻居减弱节点度差异的影响, 并将其与跨层频率结合, 用于融合边权计算和融合图结构精炼, 以提高社区内部连接与社区边界的可区分性.

2　相关理论与算法实现

2.1　相关定义与符号描述

本文研究对象为无向多重网络, 主要符号和描述见表 1.

表 1　主要符号说明

符号	含义
$G^{(l)}=(V,E^{(l)})$	第l层网络
m	网络层数
$(u,v)\in E$	节点对u与v之间存在边
$f(u,v)$	节点对(u,v)的跨层出现频率
$CN(u,v)$	节点对(u,v)的共同邻居数量
$S(u,v)$	节点对(u,v)的归一化共同邻居指标
α_l	第l层网络的层贡献权重
β	局部结构调节系数
θ_{add}	补边阈值
θ_{rem}	删边阈值
$w_{\text{init}}(u,v)$	节点对(u,v)的初始融合权重
$w_{\text{final}}(u,v)$	节点对(u,v)的最终融合权重
$G_{\text{perturbed}}$	结构精炼后的融合图

约定 1(多层网络)　设$G=(V,E)$表示一个单层网络, 其中$V=\{v_1,\ldots,v_n\}$为顶点集合, E为边集合. 多层网络定义为$\Gamma=\{G^{(1)},\ldots,G^{(m)}\}$, 其中$G^{(l)}=(V^{(l)},E^{(l)})$表示第$l$层网络, $l=1,\cdots,m$, m为网络层数.

约定 2(多重网络)　若多层网络的各层具有相同的顶点集, 即$V^{(1)}=V^{(2)}=\ldots=V^{(m)}=V$, 则称其为多重网络: $\Gamma=\{G^{(1)},\ldots,G^{(m)}\}$, 其中$G^{(l)}=(V,E^{(l)})$, 上标$l$表示第$l$层.

约定 3(加权多重网络) 若多重网络中任意两节点之间的连边具有权值, 则称该网络为加权多重网络.

约定 4(节点共同邻居) 对于任意两个相连节点 u和 v, 其共同邻居个数定义为 $cn(u,v)=|N(u)\bigcap N(v)|$, 其中$N(u)$和$N(v)$分别表示与节点$u$和$v$相邻的节点集合.

约定 5(多重网络社区检测) 多重网络社区检测问题指将给定的多重网络划分为c个社团: $C=(C_1,C_2,\ldots,C_c)$, 其中 $\bigcup_{i=1}^{c}C_i=V$, 且 $C_i\bigcap C_j=\varnothing\ (i\neq j)$.

2.2 方法概述

多重网络中的同一节点对可能在多个网络层中重复连接, 其跨层出现频率能够反映连接关系在不同关系层中的重复程度[20]. 同时, 在多重网络中, 同一社区内部节点通常共享较多邻居, 因此局部邻域重叠也能够为节点之间的潜在社区关系提供结构依据[30]. 跨层频率主要描述连接的跨层稳定性, 而共同邻居主要描述节点对的局部结构一致性, 二者具有一定的互补性.

基于上述考虑, 本文提出一种融合局部结构一致性与跨层频率的多重网络社区检测方法 CNPML, 其整体框架如图 1 所示. 该方法主要包括多重网络加权融合, 结构精炼和社区检测三个环节. 首先, 统计节点对在不同网络层中的连接情况, 并根据各层边规模计算层贡献权重. 对于加权多重网络, 层内边权参与融合权重计算, 从而构建初始加权融合图. 其次, 在初始融合图的无权拓扑结构上计算归一化共同邻居指标, 并利用局部结构信息进一步调节已有边的融合权重. 在此基础上, 对局部结构相似性较高但尚未连接的节点对进行补边, 对局部结构支持较弱的已有连接进行删除, 以调整融合图的连接关系. 最后, 在处理后的加权融合图上执行 Louvain 算法, 获得最终社区划分结果.

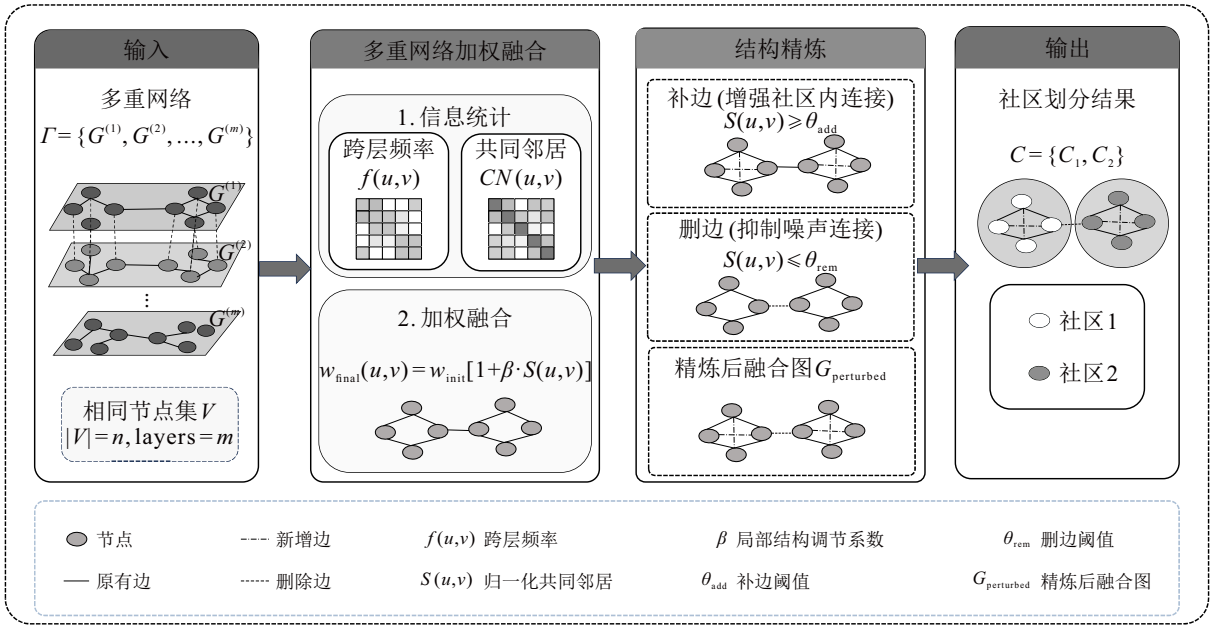

图 1 CNPML 算法框架

2.3 多重网络加权融合策略

不同网络层在边规模, 连接密度和边权分布等方面通常存在差异, 因而对整体社区结构的贡献程度并不完全相同. 不适宜直接对各层邻接矩阵进行等权叠加; 若仅统计节点对的跨层出现次数, 又难以充分利用加权网络中的连接强度以及节点之间的局部结构关系. 因此, 本文从跨层连接重复性, 网络层贡献和局部结构融合三个方面构建多重网络加权融合表示.

定义 1 跨层出现频率 对于多重网络$\Gamma=\{G^{(1)},\ldots,G^{(m)}\}$, 任意节点对$(u,v)$的跨层出现频率定义为

$$f(u,v)=\frac{\sum_{l=1}^{m}\mathbb{I}^{(l)}(u,v)}{m},\tag{1}$$

式中$\mathbb{I}^{(l)}(u,v)$为指示函数, 若节点对(u,v)在第l层中存在直接连接则为 1, 否则为 0.

在此基础上, 构建初始无向融合图$G_{\text{init}}=(V,E_{\text{init}})$, 其节点集合为所有层节点的并集, 边权由跨层频率决定. 跨层频率越高, 说明节点对在越多网

络层中存在直接连接, 其关系具有更高的跨层重复性. 同时, 不同层边规模不同, 跨层重复性并不直接等同于社区连接可靠性, 仍需结合局部结构信息进行判断. 因此, 进一步引入层贡献权重以刻画不同网络层的重要性.

定义 2 层贡献权重　第l层贡献权重定义为

$$\alpha_l = \frac{|E^{(l)}|}{\sum_{k=1}^{m} |E^{(k)}|}, \tag{2}$$

式中$|E^{(l)}|$表示第l层中的边数. 边规模较大的网络层通常能够提供更加稳定和丰富的结构信息, 因此在融合过程中应具有更高贡献权重. 基于层贡献权重, 节点对(u,v)的初始融合权重定义为

$$w_{\text{init}}(u,v) = \sum_{l=1}^{m} \alpha_l \mathbb{I}^{(l)}(u,v) w'^{(l)}(u,v), \tag{3}$$

式中$w'^{(l)}(u,v)$为节点u和v在第l层中的层内边权. 然而, 仅依赖跨层频率仍难以有效区分真实社区内边与偶然关联边. 部分节点对虽然在多个网络层中重复出现, 但其局部拓扑结构缺乏一致性, 仍可能属于跨社区噪声连接. 因此, 本文进一步利用归一化共同邻居指标刻画节点对之间的局部结构一致性.

定义 3 归一化共同邻居　在由初始融合边构成的无权拓扑图上, 节点对(u,v)的归一化共同邻居指标定义为

$$S(u,v) = \frac{CN(u,v)}{\min(|N(u)|, |N(v)|)}. \tag{4}$$

$S(u,v)$越大, 说明节点u与v的邻域重叠程度越高, 二者具有更强的局部结构一致性. 归一化处理能够减小节点度差异对共同邻居数量的影响.

最后, 在初始融合权重基础上, 采用乘性增强方式构建最终融合权重:

$$w_{\text{final}}(u,v) = w_{\text{init}}(u,v)[1 + \beta S(u,v)], \tag{5}$$

式中β为局部结构调节系数. 式 (5) 以初始融合权重作为连接的基础权重, 并利用归一化共同邻居对其进行局部结构修正. 当节点对同时具有较高的初始融合权重和较强的邻域重叠时, 其最终权重将进一步提高; 当初始融合权重较低时, 局部结构信息不会使其获得过高权重.

为根据不同网络中跨层连接与局部结构之间的一致程度调节局部结构项的作用, 本文进一步对参数β进行全局自适应调节:

$$\beta = \max(0, 1-\rho), \tag{6}$$

式中ρ为$w_{\text{init}}(u,v)$与$S(u,v)$之间的皮尔逊相关系数. 当二者具有较高相关性时, 说明跨层频率已经能够较好刻画社区结构, 此时应减弱局部结构增强作用; 反之, 当二者相关性较低时, 则说明仅依赖频率难以有效检测潜在社区, 此时需要增强局部拓扑对融合权重的修正能力.

2.4　结构精炼与社区检测

经过加权融合后, 初始融合图能够综合表示节点对的跨层连接信息和局部结构关系, 但其中仍可能存在局部结构支持较弱的已有连接, 同时也可能遗漏部分邻域重叠程度较高的潜在连接. 因此, 本文进一步基于归一化共同邻居对融合图的连接关系进行结构精炼.

情况 1 高相似度无连接补偿　对于满足$S(u,v) \geqslant \theta_{\text{add}}$且在融合图中尚未直接连接的节点对, 添加一条权重为$w_{\text{add}} = S(u,v)$的连接边, 用以补偿潜在但被多重噪声掩盖的结构关系. 若$(u,v) \notin E_{\text{init}}$且$S(u,v) \geqslant \theta_{\text{add}}$, 则结构精炼后的边集为

$$E_{\text{perturbed}} = E_{\text{init}} \bigcup \{(u,v)\}. \tag{7}$$

该操作利用节点之间的邻域重叠信息补充潜在连接, 使局部结构关联较强的节点能够在融合图中形成直接联系. 需要说明的是, 本文在融合前将各层边权归一化至$[0,1]$区间, 且α_l为归一化层贡献权重, 因此已有边权和新增边权均表示节点对连接强度的相对可靠性, 而非原始物理量意义下的边权.

情况 2 低相似度有连接删除　对于共同邻居较少的已有边, 当$S(u,v) \leqslant \theta_{\text{rem}}$时删除该边, 从而减少跨社区噪声连接对划分结果的干扰. 若$(u,v) \in E_{\text{init}}$且$S(u,v) \leqslant \theta_{\text{rem}}$, 则重新定义其权重为

$$w(u,v) = 0. \tag{8}$$

该约束显式抑制了那些频繁出现但缺乏局部结构支持的连接.

归一化共同邻居指标$S(u,v)$反映节点对邻域结构的重叠比例. 在同一社区节点通常具有较强邻域重叠的前提下, 高相似度但尚未连接的节点对具有较强的局部结构一致性, 其直接连接可能因网络稀疏性或噪声干扰而缺失, 因此对其进行补边有助于恢复潜在的社区内部连接. 相反, 低相似度已有边的两个端点具有较低的邻域重叠程度, 说明该连接与周围局部拓扑结构的一致性较弱, 删除此类边有助于抑制缺乏局部结构支持的连接. 因此, 补边和删边使融合图中的直接连接关系与局部邻域结构更加一致, 从而增强社区结构的可分性.

最后, 在结构精炼后的融合图$G_{\text{perturbed}} = (V, E_{\text{perturbed}})$上采用基于模块度最大化的 Louvain 算法

进行社区检测. 结构精炼过程通过调整融合图中的局部连接模式, 为 Louvain 算法提供具有更强社区区分度的加权网络表示.

2.5 CNPML 算法伪代码与时间复杂度

设多重网络包含m个网络层和n个节点. 令$|E^{(l)}|$表示第l层边数, 所有网络层的总边数为$M=\sum_{l=1}^{m}|E^{(l)}|$, 初始融合图的边数为$M_f$, 平均度为$\bar{d}$. 在特征统计与加权融合阶段, 算法需要依次遍历各层边集, 完成跨层出现频率, 层贡献权重和初始融合边权的计算, 因此该阶段时间复杂度为$O(M)$. 在局部结构计算阶段, 算法需要对融合图中的节点对计算共同邻居. 采用邻接表求交时, 单条边的计算开销与节点度相关, 所有融合边的总体复杂度可近似表示为$O(M_f\bar{d})$. 在结构精炼阶段, 算法根据共同邻居信息生成候选补边, 并遍历已有边执行补边和删边操作, 其主要开销由局部邻域搜索决定, 时间复杂度为$O(n^2)$. 最后, 在精炼后的加权融合图上执行 Louvain 算法. 若算法经过T轮迭代达到稳定状态, 则该阶段时间复杂度约为$O(TM_f)$. 综上, CNPML 的总体时间复杂度为$O(M+M_f\bar{d}+n^2+TM_f)$. 在实际稀疏多重网络中, 通常有M_f与M处于相同数量级, 且平均度$\bar{d}$和迭代次数T相对较小, 因此算法总体时间复杂度可简化为$O(n^2)$. 算法运行开销主要随网络边数增长, 表现出较好的计算效率.

3 实验分析

3.1 对比算法和多重网络介绍

为全面评估 CNPML 在多重网络社区检测任务中的有效性, 本文使用 4 个具有真实社区标签的多重网络, 包括 Artificial[31], AUCS[32], 3sources[33] 和 Flickr[24], 用于评价检测结果与真实划分之间的一致性; 4 个无真实社区标签的多重网络, 包括 Florentine[34], Tailorshop[35], Fao[31] 和 Drosophila[31], 用于基于多重网络模块度评价检测所得社区结构的质量; 以及两个具有代表性的加权网络 London[36] 和 Pierreauger[37], 用于考察算法对层内边权信息的利用能力. 实验网络统计信息如表 2 所示. 对所有网络均使用其无向版本并采用相同预处理方式: 原始网络数据使用. mpx 格式存储, 使用文献提供的 read_data() 函数解析文件, 提取节点列表与边列表, 获得各层邻接关系; 对具有真实社区标签的数据集, 同时读取社区标签. 对每一层, 若存在重复边则合并, 不添加自环, 不删除孤立节点. 所有层共享同一节点集合, 构成标准多重网络, 层间不进行跨层边连接.

算法1 CNPML社区检测算法

Input: 多重网络$\Gamma=\{G^{(1)},G^{(2)},\ldots,G^{(m)}\}$, 参数$\theta_{\text{add}}$, θ_{rem}

Output: 社区划分结果$\mathcal{C}$

1 遍历各网络层, 计算节点对跨层出现频率$f(u,v)$与各层贡献权重α_l;

2 计算初始融合权重$w_{\text{init}}(u,v)$, 构建初始融合图G_{init};

3 在G_{init}的无权拓扑上计算归一化共同邻居指标$S(u,v)$;

4 计算局部调节系数β并计算最终融合权重$w_{\text{final}}(u,v)$;

5 for每个候选非边(u,v) **do**

6 **if:** $S(u,v)\geqslant\theta_{\text{add}}$ **then**

7 添加边并赋予权重;

8 for每条已有边$(u,v)\in E_{\text{init}}$ **do**

9 **if:** $S(u,v)\leqslant\theta_{\text{rem}}$ **then**

10 删除该边;

11得到精炼后的优化融合图$G_{\text{perturbed}}$;

12 在$G_{\text{perturbed}}$上执行Louvain算法;

13 return社区划分结果$\mathcal{C}$;

表 2 实验网络统计信息

网络	层数	节点数	边数	是否加权	社区数
Artificial	2	500	4662	否	10
AUCS	5	61	620	否	8
3sources	3	169	10259	否	6
Flickr	2	10364	537213	否	7
Florentine	2	16	35	否	–
Tailorshop	4	39	552	否	–
Fao	364	214	318346	否	–
Drosophila	7	8215	43366	否	–
London	3	369	441	是	–
Pierreauger	16	514	7153	是	–

为增强实验对比的代表性, 本文选取 7 种传统无监督多重网络社区检测方法作为基线, 包括 3 种基于单层扩展的算法 PMM[20], MPBTV[21] 和 DGFM3[21], 3 种基于网络聚合的算法 CDMA[24], GBS[19] 和 SCML[9], 以及 1 种基于张量分解的算法 WPTTD[14]. 这些算法覆盖本领域常用的设计范式, 既能从聚合型角度检验 CNPML 相对于同类框架的改进, 也能从不同原理的算法中观察其泛化优势. 对比方法优先采用原作者公开实现代码, 相关参数按照原论文推荐值或公开代码默认设置进行配置. 所有算法使用相同的数据预处理结果, 并在相同软硬件环境下运行. 实验平台为 Windows 11 操作系统, 硬件配置为 Intel Core i5-9300H 2.40 GHz 处理器和 16 GB 内存. 由于 Louvain 算法具有不稳定性, 故以下所有精度结果均为运行 10 次取其中位数.

3.2 评价指标

常用的社区检测评价指标包括归一化互信息(Normalized Mutual Information, NMI)[38], 调整兰德指数 (Adjusted Rand Index, ARI)[39] 和多重网络模块度Q[6]. 当网络具备已知社区结构时, 通常采用 NMI 和 ARI 量化真实社区划分与检测所得社区划分之间的一致性. NMI 和 ARI 数值越高, 表明检测出的社区划分结果与真实社区结构越吻合. 当网络真实社区划分未知时, 可采用多重网络模块度Q作为评价指标, Q值越大, 表明社区检测效果越好.

3.3 社区检测实验结果

为系统评估 CNPML 算法的性能, 本文在社区结构已知, 未知两类网络及加权多重网络上进行实验. 表 3 给出了各算法在具有真实社区标签网络上的 ARI 和 NMI 结果, 表 4 和表 5 分别给出了各算法在无真实社区标签网络和加权多重网络上的模块度结果. 表中"–"表示相应算法因网络规模过大而未能得出有效结果, 表 5 中缺失的算法则表明其无法适应加权多重网络. 最优结果以粗体标示, 次优结果以下划线标示.

表 3 给出了各算法在具有已知真实社区标签网络上的 ARI 和 NMI 结果. CNPML 在 8 组结果中取得 7 组最优值. 在 Artificial 和 3sources 这类结构清晰但单层稀疏的网络上, CNPML 的 ARI 与 NMI 均取得最优的性能表现, 说明 CNPML 将跨层连接信息与局部结构相似性结合, 并通过补边和删边调整融合网络中的局部连接关系, 从而增强了社区内部连接与社区间连接之间的区分度. 在层间差异大的 AUCS 网络上, CNPML 的 NMI 达到 0.8545, 为所有方法中的最高值; 其 ARI 为 0.7163, 低于 SCML 的 0.7474, 但高于其余对比方法. 该结果说明, CNPML 获得的社区划分在整体类别信息一致性方面表现较好, 但在节点对划分一致性方面仍有一定提升空间. 在大规模网络 Flickr 上, CNPML 的 ARI 和 NMI 分别为 0.7152 和 0.7259, 均高于表中获得有效结果的对比方法. Flickr 节点规模较大, 传统谱分解或高阶结构计算方法在当前实验环境下受到一定限制. CNPML 主要依据边集统计和局部邻域信息构建融合网络, 在该数据集上表现出较好的检测效果.

表 3　CNPML 与对比算法在真实社区结构已知网络上的性能比较

网络	指标	CDMA	PMM	GBS	SCML	WPTTD	MPBTV	DGFM3	CNPML
AUCS	ARI	0.6890	0.4409	0.6603	**0.7474**	0.5148	0.6343	0.7150	0.7163
	NMI	0.8053	0.7133	0.7876	0.8432	0.6374	0.8092	0.7172	**0.8545**
3sources	ARI	0.7273	0.6536	0.2982	0.6292	0.6348	0.8240	0.8240	**0.8376**
	NMI	0.6911	0.5510	0.4355	0.5333	0.4958	0.7780	0.7890	**0.8103**
Artificial	ARI	0.3840	0.0412	0.0004	0.0412	0.3466	0.7299	0.8180	**0.8720**
	NMI	0.5148	0.2480	0.0756	0.2480	0.4589	0.7713	0.7850	**0.8540**
Flickr	ARI	0.1707	0.0287	–	0.3445	0.3765	–	–	**0.7152**
	NMI	0.3069	0.2884	–	0.4602	0.4589	–	–	**0.7259**

表 4　CNPML 与对比算法在真实社区结构未知网络上的模块度比较

网络	C	CDMA	PMM	GBS	SCML	WPTTD	MPBTV	DGFM3	CNPML
Tailorshop	3	0.1369	0.2263	0.0354	0.2380	0.1407	0.1185	0.2209	**0.2685**
Florentine	5	0.0562	0.3735	0.4211	0.3786	0.0964	0.4098	**0.4250**	**0.4250**
Fao	4	0.1250	0.1334	0.0162	0.2084	0.2091	0.0509	0.1940	**0.3244**
Drosophila	76	0.2650	0.2008	–	−0.0047	–	–	–	**0.4652**

表 5　CNPML 与对比算法在加权网络上的模块度比较

网络	C	CDMA	PMM	GBS	SCML	WPTTD	CNPML
London	145	0.0043	0.2157	0.0144	0.5064	0.0081	**0.5499**
Pierreauger	76	0.3760	0.1542	0.1177	0.1941	0.3561	**0.6162**

表 4 给出了各算法在 Tailorshop, Florentine, Fao 和 Drosophila 四个无真实社区标签网络上的模块度结果. CNPML 在 Tailorshop, Fao 和 Drosophila 网络上取得最高值, 在 Florentine 网络上与 DGFM3 并列最优. 其中, CNPML 在 Tailorshop 和 Fao 网络上的模块度分别为 0.2685 和 0.3244, 说明融合权重与结构精炼能够改善社区内部连接的紧密程度.

为验证算法对边权信息的利用能力, 本文在 London 和 Pierreauger 两个加权网络上进行实验. 如表 5 所示, CNPML 的模块度Q分别达到 0.5499 和 0.6162, 均高于其他对比算法. 这是因为与无权网络相比, 加权网络不仅包含连接关系, 还反映不同连接之间的强度差异. CNPML 在初始融合阶段利用层内

边权, 使高强度连接在融合网络中获得相应体现; 随后利用局部结构相似性进一步修正边权和连接关系, 从而提高融合网络的社区结构表达能力.

综合表 3–表 5, CNPML 在多数数据集和评价指标上取得最优或具有竞争力的结果, 说明 CNPML 在本文所选数据集和实验设置下具有较好适用性, 也进一步说明跨层频率, 层内边权和局部结构信息的联合利用能够提高融合网络的社区可分性.

3.4 CNPML 参数分析

为考察补边阈值θ_{add}和删边阈值θ_{rem}对 CNPML 性能的影响, 本文在 3sources, RM 和 AUCS 三个具有真实社区标签的网络上开展参数敏感性实验. 补边阈值θ_{add}的取值范围为$[0.5, 0.9]$, 步长为 0.1; 删边阈值θ_{rem}的取值范围为$[0.05, 0.30]$, 步长为 0.05. 图 2 给出了不同阈值组合下的 NMI 结果, 其中颜色越深

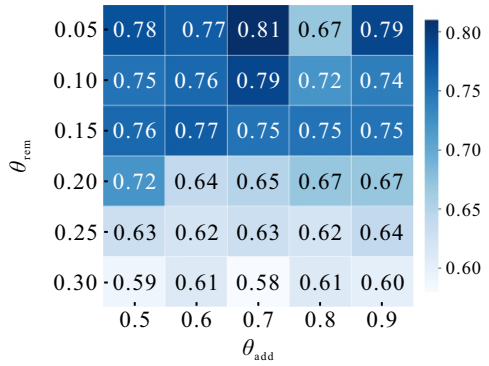

(a) 3sources

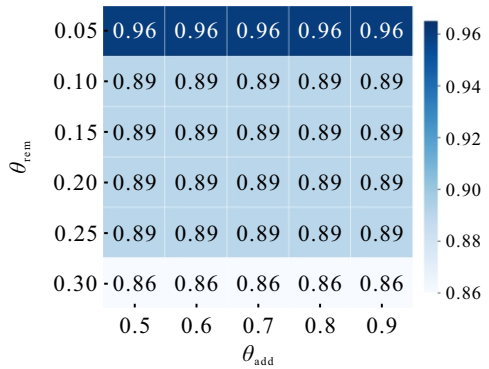

(b) RM

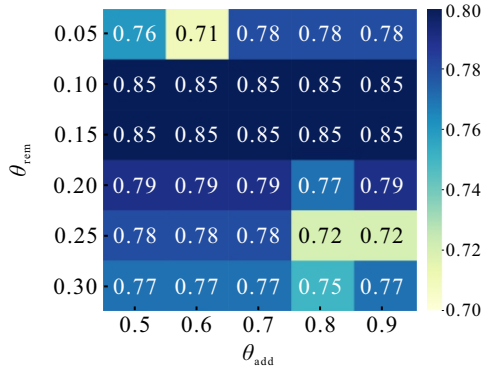

(c) AUCS

图 2 CNPML 在不同参数组合下的 NMI 结果

表示 NMI 越高. 选择上述三个网络是因为其结构特征具有一定差异: 3sources 的社区数量适中, 但连接相对稀疏; RM 的社区数量较少, 连接较为稠密; AUCS 的连接密度和社区粒度介于二者之间. 因此, 这三个网络能够用于分析不同网络结构下补边阈值与删边阈值的作用.

由图 2(a) 可知, 在 3sources 网络上, 当$\theta_{\text{add}} = 0.7$, $\theta_{\text{rem}} = 0.05$时, CNPML 取得最高 NMI. 该参数组合能够补充局部结构支持较强的潜在连接, 同时避免删除过多已有连接, 因而更适合连接相对稀疏的网络. 由图 2(b) 可知, 在 RM 网络上, NMI 随θ_{add}变化较为稳定, 并在$\theta_{\text{rem}} = 0.05$时达到最高值. 这是因为 RM 的社区内部连接较为稠密, 对补边操作的依赖较小, 采用较小的删边阈值能够避免过度改变原有社区结构. 由图 2(c) 可知, 在 AUCS 网络上, NMI 随θ_{add}变化同样较为稳定, 当$\theta_{\text{rem}} \in [0.10, 0.15]$时取得较高值, 而随着$\theta_{\text{rem}}$进一步增大, NMI 有所下降. 适度删边能够削弱局部结构支持较弱连接的干扰, 但过度删边可能破坏规模相对较小的社区.

综合三个网络的实验结果, $\theta_{\text{add}} \in [0.6, 0.8]$可作为补边阈值的初始搜索范围. 对于连接相对稀疏的网络, 建议设置$\theta_{\text{add}} \approx 0.7$, $\theta_{\text{rem}} \in [0.05, 0.10]$; 对于社区数量较少且连接较为稠密的网络, 建议设置$\theta_{\text{rem}} \approx 0.05$, 而$\theta_{\text{add}}$可在较大范围内进行选择; 对于连接密度适中且社区规模相对较小的网络, 建议设置$\theta_{\text{rem}} \in [0.10, 0.15]$. 上述参数范围是根据三个网络得到的经验性参考, 并非适用于所有多重网络的统一最优设置, 实际应用时仍需结合目标网络的连接密度和社区结构进行调整.

3.5 消融实验

为验证 CNPML 中局部结构增强与结构精炼模块的作用, 本文在全部 10 个真实多重网络上开展消融实验, 并设置 4 种方法进行比较: 完整方法 CNPML; 移除高相似度无连接补偿模块的 CNPML-C; 移除低相似度已有边删除模块的 CNPML-D; 以及仅依据跨层频率构建聚合网络的 CNPML-E. 除被移除的模块外, 各方法采用相同的数据预处理方式, 参数设置和 Louvain 配置. 实验结果如表 6 所示.

由表 6 可知, 完整 CNPML 在 10 个网络上均取得最优结果. 这表明, 仅依据跨层频率构建融合图难以充分区分社区内部连接与跨社区连接, 归一化共同邻居修正和结构精炼能够进一步改善融合图的社区可分性. 不同模块的作用与网络结构特征有关. 在 AUCS, 3sources 和 London 上, 移除补边或删边所引

表 6　各方法在 10 个真实网络上的 NMI 和Q结果

指标	网络	CNPML	CNPML-C	CNPML-D	CNPML-E
NMI	AUCS	**0.8545**	0.7223	0.7221	0.6517
NMI	3sources	**0.8103**	0.5910	0.5827	0.5124
NMI	Artificial	**0.8540**	0.7649	0.7317	0.7255
NMI	Flickr	**0.7259**	0.6976	0.5177	0.3837
Q	London	**0.5499**	0.4687	0.4631	0.3965
Q	Pierreauger	**0.6162**	0.3213	0.5265	0.2417
Q	Tailorshop	**0.2685**	0.2176	0.2269	0.1884
Q	Florentine	**0.4250**	0.4062	0.4212	0.3745
Q	Fao	**0.3244**	0.2049	−0.0122	0.2052
Q	Drosophila	**0.4652**	0.2846	0.3882	0.2453

起的性能下降较为接近, 说明这些网络中潜在缺失连接与弱结构连接同时存在, 补边和删边均发挥了作用. 对于 Pierreauger, Tailorshop, Florentine 和 Drosophila, 移除补边后的性能下降更大. 这类网络单层连接较为稀疏, 部分具有相似邻域的节点可能缺少直接连接. 因此, 高相似度无连接补偿能够补充潜在的社区内部连接, 其作用相对更加明显. 相比之下, 删边模块在 Artificial, Flickr 和 Fao 上的贡献更大. Flickr 具有较大的节点规模和边规模, 多层聚合后容易保留局部结构支持不足的连接; 移除删边模块后, 其 NMI 由 0.7259 下降至 0.5177, 说明抑制弱结构连接有助于减少噪声边对社区边界的干扰. Artificial 中也表现出类似现象, 移除删边造成的性能下降大于移除补边, 表明该网络的性能改善更多来自对已有连接的筛选.

总体而言, 补边与删边并非在所有网络上具有相同贡献: 补边更适合恢复稀疏网络中的潜在社区内部连接, 删边则更有利于抑制边规模较大或跨层冗余较强网络中的弱结构连接. 完整 CNPML 在全部网络上均优于各消融版本, 说明局部结构增强, 补边和删边模块具有互补作用.

3.6　算法运行时间与可扩展性分析

为考察 CNPML 的计算效率及其对不同规模多重网络的适应性, 本文在 10 个网络上与 6 种代表性方法进行运行时间比较. 所有算法均使用相同的预处理网络, 并在相同软硬件环境下运行. 运行时间记录从算法接收处理后的网络数据开始, 至输出最终社区划分结束, 不包含参数搜索过程. 图 3 中"×"表示相应算法在当前实验环境下未能完成运行或未获得有效社区划分.

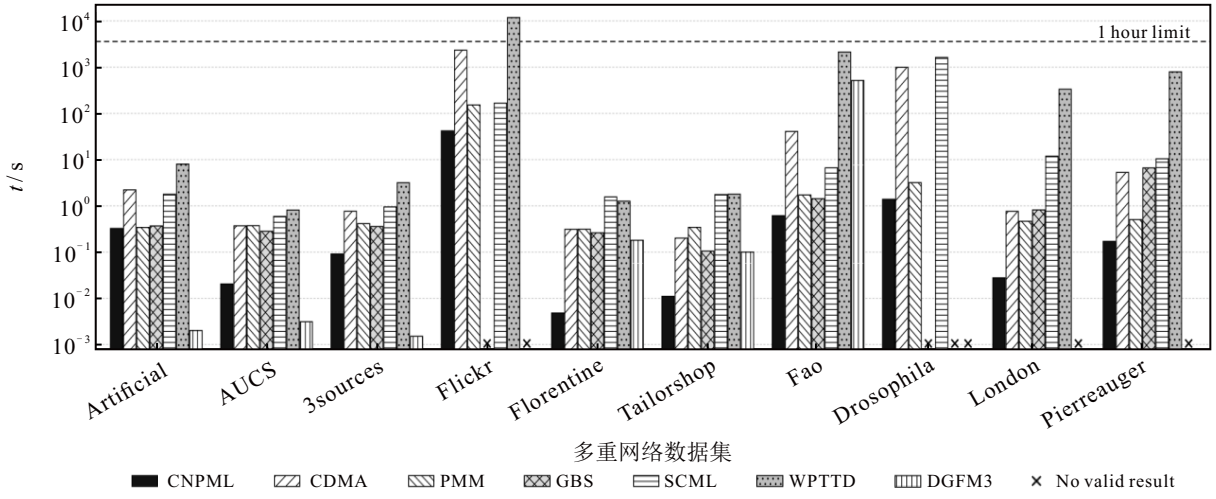

图 3　CNPML 与对比算法在所有网络上的运行时间对比结果

由图 3 可知, CNPML, CDMA, PMM 和 SC-ML 在 10 个网络上均能完成运行并获得有效社区划分, 均实现零失败. CNPML 在 10 个网络上的图示运行时间均不超过 41.9 s, 并在 AUCS, 3sources 等中小规模网络上达到毫秒级. 与同样实现零失败的 CDMA, PMM 和 SCML 相比, CNPML 在多数网络上的运行时间更短, 且在 Flickr, Drosophila 等大规模网络上的效率优势更为明显. GBS 和 WPTTD 在 Drosophila 网络上未获得有效结果, DGFM3 则在 Flickr, Drosophila, London 和 Pierreauger 四个网络上未能正常完成运行. 以 Flickr 网络为例, CNPML 相较于最快的 CDMA 和最慢的 WPTTD 分别实现约 55 倍和 283 倍的加速. 上述结果表明, CNPML 在保持较高运行成功率的同时, 在本文所选网络和实验环境下具有较好的计算效率及大规模网络适应性.

除运行时间外, CNPML 的规模适用性还受到网络层数, 边数和内存空间的共同影响. 实际空间复杂度为$O(n^2)$. 因此, CNPML 在算法定义上不存在固定的节点规模上限, 在存储和计算资源充分时, 理论上能够处理包括百万节点在内的有限规模多重网络,

但其实际可扩展性受到网络拓扑和计算资源的明显制约.

4 结 论

本文针对传统多重网络聚合方法对局部拓扑信息利用不足, 以及跨层频率融合可能保留弱结构连接的问题, 提出一种融合局部结构一致性与跨层频率的无监督社区检测方法 CNPML. 该方法首先结合跨层连接信息, 层贡献权重及层内边权构建初始加权融合图, 随后利用归一化共同邻居修正融合权重, 并通过补充高局部相似性节点对之间的潜在连接, 删除局部结构支持较弱的已有连接, 对融合网络进行结构精炼, 最后采用 Louvain 算法获得社区划分结果. 在多个无权和加权多重网络上的实验结果表明, CNPML 在多数数据集和评价指标上取得较优或具有竞争力的结果. 尽管 CNPML 在算法定义上不存在固定的节点规模上限, 但当前实现需要显式计算并存储全部节点对的共同邻居信息, 空间开销随节点数呈二次增长, 因而尚不具备普通计算平台上的百万节点处理能力. 未来将面向百万节点多重网络研究可扩展的社区检测算法, 重点从局部候选节点对筛选, 跨层稀疏表示, 共同邻居信息的分块计算以及并行化处理等方面进一步降低时间和空间开销.

参考文献 (References)

[1] 邓琨, 李文平, 陈丽, 等. 一种新的基于标签传播的复杂网络重叠社区识别算法[J]. 控制与决策, 2020, 35(11): 2733-2742.
(Deng K, Li W P, Chen L, et al. A novel algorithm for overlapping community detection based on label propagation in complex networks[J]. Control and Decision, 2020, 35(11): 2733-2742.)

[2] Nakis N, Lehmann S, Christakis N A, et al. Modeling roles and trade-offs in multiplex networks[J]. Nature Communications, 2026, 17: 3622.

[3] 吴宗柠, 狄增如, 樊瑛. 多层网络的结构与功能研究进展[J]. 电子科技大学学报, 2021, 50(1): 106-120.
(Wu Z N, Di Z R, Fan Y. The structure and function of multilayer networks: Progress and prospects[J]. Journal of University of Electronic Science and Technology of China, 2021, 50(1): 106-120.)

[4] 赵兴旺, 张珧溥, 梁吉业. 基于 2 阶段集成的多层网络社区发现算法[J]. 计算机研究与发展, 2023, 60(12): 2832-2843.
(Zhao X W, Zhang Y P, Liang J Y. Two-stage ensemble-based community discovery algorithm in multilayer networks[J]. Journal of Computer Research and Development, 2023, 60(12): 2832-2843.)

[5] De Domenico M, Solé-Ribalta A, Cozzo E, et al. Mathematical formulation of multilayer networks[J]. Physical Review X, 2013, 3(4): 041022.

[6] Mucha P J, Richardson T, Macon K, et al. Community structure in time-dependent, multiscale, and multiplex networks[J]. Science, 2010, 328(5980): 876-878.

[7] Paul S, Chen Y G. Spectral and matrix factorization methods for consistent community detection in multi-layer networks[J]. The Annals of Statistics, 2020, 48(1): 230-250.

[8] Tang W, Lu Z D, Dhillon I S. Clustering with multiple graphs[C]. Proceedings of the 9th IEEE International Conference on Data Mining. Miami Beach, 2009: 1016-1021.

[9] Dong X W, Frossard P, Vandergheynst P, et al. Clustering on multi-layer graphs *via* subspace analysis on Grassmann manifolds[J]. IEEE Transactions on Signal Processing, 2014, 62(4): 905-918.

[10] Li X M, Xiong N N, Yu W, et al. Research on a multilayer network community detection algorithm based on local information expansion[J]. Big Data Mining and Analytics, 2025, 8(6): 1282-1306.

[11] Aguiar I, Taylor D, Ugander J. A tensor factorization model of multilayer network interdependence[J]. Journal of Machine Learning Research, 2024, 25(282): 1-54.

[12] 陈超洋, 周勇, 池明, 等. 基于复杂网络理论的大电网脆弱性研究综述[J]. 控制与决策, 2022, 37(4): 782-798.
(Chen C Y, Zhou Y, Chi M, et al. Review on large grid vulnerability based on complex network theory[J]. Control and Decision, 2022, 37(4): 782-798.)

[13] Jing B Y, Li T, Lyu Z Y, et al. Community detection on mixture multilayer networks via regularized tensor decomposition[J]. The Annals of Statistics, 2021, 49(6): 3181-3205.

[14] Peng S Y, Yang M L, Yang Z J, et al. A weighted prior tensor train decomposition method for community detection in multi-layer networks[J]. Neural Networks, 2024, 179: 106523.

[15] Kolda T G, Bader B W. Tensor decompositions and applications[J]. SIAM Review, 2009, 51(3): 455-500.

[16] 徐森, 刘轩绮, 陈朝峰, 等. 一种基于概率分布分层图聚类网络的社区检测模型[J]. 控制与决策, 2025, 40(6): 1969-1974.
(Xu S, Liu X Q, Chen C F, et al. A community detection model based on hierarchical graph clustering network with probability distribution[J]. Control and Decision, 2025, 40(6): 1969-1974.)

[17] Hu S W, Yang H, Tang F Q. Multilayer network community detection based on triangular motif and attribute information[J]. Journal of Complex Networks, 2025, 13(5): cnaf035.

[18] Li H M, Sewell D K. Model-based edge clustering for weighted networks with a noise component[J]. Computational Statistics & Data Analysis, 2025, 209: 108172.

[19] Wang H, Yang Y, Liu B, et al. A study of graph-based system for multi-view clustering[J]. Knowledge-Based Systems, 2019, 163: 1009-1019.

[20] Tang L, Wang X F, Liu H. Community detection *via*

heterogeneous interaction analysis[J]. Data Mining and Knowledge Discovery, 2012, 25(1): 1-33.

[21] Bergermann K, Stoll M. Gradient flow-based modularity maximization for community detection in multiplex networks[J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2025, 383(2298): 20240244.

[22] 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, 2008(10): P10008.

[23] Kojaku S, Radicchi F, Ahn Y Y, et al. Network community detection *via* neural embeddings[J]. Nature Communications, 2024, 15: 9446.

[24] Li C Y, Guo X J, Lin W J, et al. Multiplex network community detection algorithm based on motif awareness[J]. Knowledge-Based Systems, 2023, 260: 110136.

[25] 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.

[26] Jiang W, Zhang X, Zhu W. Community detection using closeness similarity based on common neighbor node clustering entropy[J]. KSII Transactions on Internet and Information Systems, 2022, 16(8): 2587-2605.

[27] Asmi K, Lotfi D, El M M. A new local algorithm for overlapping community detection based on clustering coefficient and common neighbor similarity[C]. Proceedings of the ArabWIC 6th Annual International Conference Research Track. Rabat, 2019: 1-6.

[28] Xiang J, Hu K, Zhang Y, et al. Enhancing community detection by using local structural information[J]. Journal of Statistical Mechanics: Theory and Experiment, 2016, 2016(3): 033405.

[29] Gerald T, Zaatiti H, Hajri H, et al. A hyperbolic approach for learning communities on graphs[J]. Data Mining and Knowledge Discovery, 2023, 37: 1090-1124.

[30] 陈梅, 王欢, 付豪杰, 等. 基于弱边识别与有向传播机制的社区检测算法[J]. 控制与决策, 2026, 41(6): 1676-1686.
(Chen M, Wang H, Fu H J, et al. Community detection algorithm based on weak edge identification and directed propagation mechanism[J]. Control and Decision, 2026, 41(6): 1676-1686.)

[31] De Domenico M. Datasets released for reproducibility[EB/OL]. [2025-07-28]. https://manliodedomenico.com/data.php.

[32] Rossi L, Magnani M. Towards effective visual analytics on multiplex and multilayer networks[J]. Chaos, Solitons & Fractals, 2015, 72: 68-76.

[33] MLG. 3Sources dataset[EB/OL]. (2021-09-24)[2024-07-28]. http://mlg.ucd.ie/datasets/3sources.html.

[34] Padgett J F, Ansell C K. Robust action and the rise of the medici, 1400-1434[J]. American Journal of Sociology, 1993, 98(6): 1259-1319.

[35] UTM Research Team. Multilayer networks datasets[EB/OL]. (2026-02-24)[2026-06-15]. https://github.com/phdutm2009/multilayer-networks-datasets.

[36] De Domenico M, Solé-Ribalta A, Gómez S, et al. Navigability of interconnected networks under random failures[J]. Proceedings of the National Academy of Sciences of the United States of America, 2014, 111(23): 8351-8356.

[37] De Domenico M, Lancichinetti A, Arenas A, et al. Identifying modular flows on multilayer networks reveals highly overlapping organization in interconnected systems[J]. Physical Review X, 2015, 5: 011027.

[38] Danon L, Díaz-Guilera A, Duch J, et al. Comparing community structure identification[J]. Journal of Statistical Mechanics: Theory and Experiment, 2005, 2005(9): P09008.

[39] Hubert L, Arabie P. Comparing partitions[J]. Journal of Classification, 1985, 2(1): 193-218.

作者简介

陈梅 (1973−), 女, 教授, 博士, 主要研究方向为人工智能、数据挖掘, E-mail: mei.chen.lzjtu@hotmail.com;

付豪杰 (2003−), 男, 硕士生, 主要研究方向为数据挖掘、复杂网络, E-mail: 1946531363@qq.com;

王欢 (2000−), 男, 硕士生, 主要研究方向为数据挖掘、复杂网络, E-mail: 1694608671@qq.com;

陈永旭 (1987−), 男, 博士生, 主要研究方向为数据挖掘、复杂网络, E-mail: 360777033@qq.com;

周启辉 (2000−), 男, 硕士生, 主要研究方向为数据挖掘、复杂网络, E-mail: 2021740486@qq.com.