

基于社区发现和LDD的复杂网络节点重要性度量

罗衍总, 高雅馨

云南大学软件学院, 云南 昆明

收稿日期: 2026年9月15日; 录用日期: 2026年10月8日; 发布日期: 2026年10月15日

摘要

复杂网络关键节点识别对舆情传播控制、疾病防控和系统稳定性维护等具有重要意义。针对K-shell分解划分粗粒度、全局最小度分解LDD忽略社区结构而难以刻画局部核心节点的问题, 本文提出基于社区发现和最小度分解的节点重要性度量方法CD-LDD+。该方法采用谱平分法划分社区诱导子图, 在社区内部执行LDD分解, 获得节点局部剥离层级; 再引入社区内标准化层级得分和平滑因子, 融合全局一阶邻居结构贡献, 构建综合评价指标。以Zachary's Karate Club网络为对象, 与度中心性、K-shell和Global LDD对比, 并通过单调性指数、Kendall秩相关系数和SIR传播模型验证。实验结果表明, CD-LDD+可减少排序并列, 提高节点区分度, 并增强节点重要性排序与传播影响力的一致性。

关键词

复杂网络, 关键节点, 社区发现, 最小度分解, 节点重要性

Measuring Node Importance in Complex Networks Based on Community Detection and LDD

Yanzong Luo, Yaxin Gao

School of Software, Yunnan University, Kunming Yunnan

Received: September 15, 2026; accepted: October 8, 2026; published: October 15, 2026

Abstract

Identifying key nodes in complex networks is of great significance for public opinion propagation

文章引用: 罗衍总, 高雅馨. 基于社区发现和 LDD 的复杂网络节点重要性度量[J]. 数据挖掘, 2026, 16(4): 154-165.
DOI: 10.12677/hjdm.2026.164014

control, disease prevention and control, and maintaining system stability. To address the limitations of K-shell decomposition, which suffers from coarse-grained partitioning, and the global minimum-degree decomposition (LDD), which overlooks community structures and thus fails to characterize local core nodes, this paper proposes a node importance measurement method based on community detection and minimum-degree decomposition, named CD-LDD+. The method first employs the spectral bisection method to partition community-induced subgraphs, then performs LDD decomposition within each community to obtain local peeling hierarchies. Furthermore, it introduces intra-community normalized layer scores and a smoothing factor, and integrates the structural contributions of global first-order neighbors to construct a comprehensive evaluation index. Using Zachary's Karate Club network as a test case, the proposed method is compared with degree centrality, K-shell, and Global LDD, and is validated through the monotonicity index, Kendall rank correlation coefficient, and the SIR propagation model. Experimental results demonstrate that CD-LDD+ can reduce ranking ties, improve node discrimination, and enhance the consistency between node importance ranking and propagation influence.

Keywords

Complex Networks, Key Nodes, Community Detection, Minimum-Degree Decomposition, Node Importance

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来, 复杂网络理论被广泛应用于社交网络、交通网络、生物网络和信息传播网络等领域[1] [2]。复杂网络中的节点通常具有明显的异质性, 少数关键节点虽然数量较少, 却可能对网络结构稳定性、信息扩散效率和动力学演化过程产生重要影响[3]-[5]。因此, 如何基于网络拓扑结构准确识别关键节点, 已成为复杂网络分析中的重要研究问题。

围绕关键节点识别, 已有研究主要从近邻属性、路径特征、特征向量和网络位置等角度展开。度中心性、半局部中心性和 H 指数等近邻指标计算简单, 但对节点局部拓扑以外的信息考虑不足[4] [6] [7]; 介数中心性、接近中心性和 Katz 中心性等路径类方法能够刻画节点在网络路径中的作用, 但在大规模网络中计算代价较高[6] [8] [9]; PageRank、LeaderRank 等特征向量类方法综合考虑邻居节点数量与质量, 但可能受到局部聚集效应影响, 使部分节点得分偏高[10] [11]。相比之下, 以 K-shell 分解为代表的网络位置类方法具有较高计算效率, 能够从壳层结构角度识别网络核心节点[5] [12]。然而, K-shell 分解存在划分粗粒度问题, 容易将拓扑位置不同的节点归入同一壳层, 从而造成大量节点重要性分值并列, 削弱排序区分能力[13]-[15]。

为提高 K-shell 分解的细粒度, Yu 等提出最小度分解方法(Lowest Degree Decomposition, LDD) [16]。该方法在每一轮剥离当前残留网络中度值最小的节点集合, 并以剥离轮次刻画节点结构层级, 能够在一定程度上细化同一 K-shell 层内节点的排序。进一步地, LDD+将节点自身层级信息与直接邻居贡献相结合, 提高了节点重要性评价与传播动力学结果之间的一致性[16]。

然而, 现有 LDD 及其改进方法多直接作用于全局网络拓扑, 未充分考虑真实复杂网络中普遍存在的社区结构特征[17] [18]。针对上述问题, 本文提出一种基于社区发现和最小度分解的复杂网络节点重要性度量方法 CD-LDD+。该方法首先利用谱平分法将原始网络划分为若干社区诱导子图, 然后在各社区内部

独立执行 LDD 分解[16] [19] [20], 获得节点的局部剥离层级, 最后融合社区内标准化层级得分与全局一阶邻居贡献, 构建综合节点重要性指标。本文方法将社区结构、局部核心性和邻域结构质量相结合, 以提高复杂网络关键节点识别的区分度和合理性。本文的主要贡献在于: 将 LDD 的作用尺度由全局网络转向社区诱导子图; 引入社区内标准化层级得分以提升跨社区可比性; 融合全局一阶邻居贡献以补充节点邻域结构质量。

2. 理论基础

2.1. 复杂网络基础定义

复杂网络通常抽象为图 $G=(V, E)$, 其中 $V=\{v_1, v_2, \dots, v_n\}$ 表示节点集合, $E \subseteq V \times V$ 表示边集合。对于无向无权网络, 若节点 v_i 与节点 v_j 之间存在连接关系, 则有 $(v_i, v_j) \in E$ 。设 $A=(a_{ij})_{n \times n}$ 为网络的邻接矩阵, 当节点 v_i 与节点 v_j 相连时, $a_{ij}=1$; 否则, $a_{ij}=0$ 。节点 v_i 的度值 d_i 定义为与其直接相连的边的数量, 即:

$$d_i = \sum_{j=1}^n a_{ij} \quad (1)$$

度值是刻画节点局部连接能力的基础指标。复杂网络中的关键节点通常指在网络结构稳定、信息传播或动力学演化过程中具有较大影响作用的节点。因此, 如何基于拓扑结构准确度量节点重要性, 是复杂网络分析中的重要基础问题。

2.2. K-Shell 分解法

K-shell 分解法[12]是一种基于网络位置的节点重要性评价方法, 其核心思想是按照节点由网络边缘到核心的顺序逐层剥离。对于给定网络, 首先从 $k=1$ 开始, 递归删除当前网络中度值满足 $d_i \leq k$ 的节点及其关联边, 并将本轮被删除节点的 K-shell 值标记为 $k_s = k$; 当不存在满足条件的节点时, 令 $k = k+1$, 继续执行剥离过程, 直至所有节点均被删除。

一般而言, K-shell 值越大, 说明节点越接近网络核心区域, 节点重要性也越高。该方法计算效率较高, 适用于从整体结构层面识别核心节点。然而, 在真实复杂网络中, 同一壳层内往往包含大量拓扑位置不同的节点, 容易造成节点重要性分值并列, 难以进一步区分同层节点之间的细微差异。因此, K-shell 分解法在节点重要性的细粒度刻画方面仍存在一定局限。

2.3. 最小度分解(LDD)方法

最小度分解法(Lowest Degree Decomposition, LDD) [16]是在 K-shell 分解思想基础上提出的细化方法。与 K-shell 按固定阈值递归剥离节点不同, LDD 在每一轮根据当前残留网络的实际拓扑状态, 删除度值最小的节点集合, 并以剥离轮次作为节点层级值。

具体而言, 对于给定网络 G , 若存在孤立节点, 则将其 LDD 值记为 $L_s = 0$ 并移除; 随后设剥离轮次 $z=1$, 计算当前残留网络中所有节点的度值, 确定最小度值 $k_{\min}$, 并删除所有度值等于 $k_{\min}$ 的节点, 将其 LDD 值记为 $L_s = z$ 。完成一轮剥离后, 更新残留网络并令 $z = z+1$, 重复上述过程, 直到所有节点均被剥离。

相较于 K-shell 分解法, LDD 不依赖预设固定度阈值, 而是依据当前残留网络中的最小度节点逐轮剥离, 因此能够在同一 K-shell 壳层内部进一步细化节点层级。已有研究表明, LDD 可以看作 K-shell 分解的一种细粒度扩展, 能够在保持分解思想简洁性的同时, 提高节点重要性排序的区分能力。

3. 基于社区发现和最小度分解的复杂网络节点重要性度量方法

3.1. 总体思想

针对全局 LDD 在复杂网络中难以准确刻画局部核心节点的问题, 本文提出 CD-LDD+方法。整体流程分为三个阶段: 先利用谱平分法将网络划分为社区诱导子图; 然后在每个社区内部独立执行 LDD 分解, 获得节点局部剥离层级; 最后, 融合节点社区内标准化层级得分与全局一阶邻居贡献, 构建综合节点重要性指标 CD-LDD+。需要指出的是, 本文是在已有 LDD 分解思想的基础上改变其作用尺度: 由全局网络转向社区诱导子图, 并通过社区内标准化处理与邻居贡献融合形成 CD-LDD+指标。

3.2. 基于谱平分法的社区划分

为了获得较为稳定的社区划分结果, 本文选用基于图谱理论的谱平分法(Spectral Bisection)进行社区划分。该方法通过分析网络拉普拉斯矩阵的第二小特征值及其对应的费德勒向量[19][20], 能够从全局拓扑出发直接获得确定性的二分结果, 与本文实验所采用的 Zachary's Karate Club 网络[21]所具有的明显二元派系结构精确匹配; 同时, 其数学含义清晰, 以最小化社区间割边为目标, 符合“内部紧密、外部稀疏”的结构定义, 且作为确定性算法, 在固定网络和求解设置下具有优异的可解释性和可重复性, 有助于减少随机因素对后续 LDD 分解及节点排序的影响。需要说明的是, 不同社区发现算法可能产生不同的社区边界, 从而影响局部 LDD 得分, 本文结论目前基于谱平分结果, 其他算法的适用性将在后续研究中另行验证。对于网络 $G=(V,E)$ 其拉普拉斯矩阵 L 定义为:

$$L = D - A \quad (2)$$

其中, D 为度矩阵, A 为邻接矩阵。对矩阵 L 进行特征分解, 可得:

$$Lx = \lambda x \quad (3)$$

将特征值按照从小到大的顺序排列为

$$0 = \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n \quad (4)$$

其中第二小特征值 λ_2 被称为代数连通度[19], 其对应的特征向量 x_2 即为费德勒向量[19]。该向量的分量值 $x_{2,i}$ 能够反映节点在网络拓扑中的相对位置, 因此可用于指导网络二分。

具体过程如下: a) 将当前待划分节点集合构造为诱导子图, 并计算其拉普拉斯矩阵; b) 求取拉普拉斯矩阵第二小特征值对应的费德勒向量; c) 根据分量符号进行划分, 即将满足 $x_{2,i} > 0$ 的节点划入一个社区, 将满足 $x_{2,i} \leq 0$ 的节点划入另一个社区; d) 若划分过程中出现某一侧节点集合为空的情况, 则认为该子图不再适合继续划分; e) 若当前待划分子图本身不连通, 则根据其连通分支进行划分, 以避免在非连通子图上进行不稳定的谱分解; f) 当需要获得多个社区时, 优先选择当前规模最大的社区继续执行谱平分, 直至达到预设社区数量。

谱平分过程可以理解为对社区间割边规模的近似优化。对于两个节点子集 C_1 和 C_2 , 其割边权重可表示为:

$$Cut(C_1, C_2) = \sum A_{uv} \quad (5)$$

通过减少社区间割边数量, 划分结果能够尽可能满足“社区内部连接较紧密、社区之间连接较稀疏”的结构特征, 从而为后续社区内 LDD 分解提供基础。

3.3. 社区内最小度分解

在完成社区划分后, 原始网络被拆分为若干社区诱导子图。本节在每个社区内部独立执行最小度分

解 LDD [16], 以刻画节点在所属局部模块中的核心深度。与直接在全局网络上执行 LDD 不同, 社区内 LDD 能够突出节点在局部结构中的相对位置, 从而降低全局剥离顺序对局部核心节点的低估影响。

对于任一社区诱导子图 G_k , 首先复制其网络结构, 记为 $\tilde{G}_k$, 并识别其中的孤立节点。若存在孤立节点, 则将其局部 LDD 值记为 $L_{\text{local}}(v) = 0$, 并从 $\tilde{G}_k$ 中移除。随后初始化剥离轮次 $z = 1$, 在每一轮中计算当前残留子图内所有节点的度值, 并确定当前最小度值:

$$k_{\min}^{(z)} = \left\{ d_v^{(z)} \mid v \in V(\tilde{G}_k^{(z)}) \right\} \quad (6)$$

当前残留子图中所有度值等于 $k_{\min}^{(z)}$ 的节点构成第 z 轮剥离节点集合:

$$V_{\text{stripped}}^{(z)} = \left\{ v \in V(\tilde{G}_k^{(z)}) \mid d_v^{(z)} = k_{\min}^{(z)} \right\} \quad (7)$$

对于集合 $V_{\text{stripped}}^{(z)}$ 中的所有节点赋予相同的局部 LDD 值, 即:

$$L_{\text{local}}(v) = z, \quad v \in V_{\text{stripped}}^{(z)} \quad (8)$$

完成赋值后, 将这些节点及其关联边从当前残留子图中移除, 得到下一轮残留子图 $\tilde{G}_k^{(z+1)}$ 。随后令 $z = z + 1$, 重复上述过程, 直到社区诱导子图中的所有节点均被剥离。由此, 每个节点最终获得一个局部 LDD 层级值, 该值反映其在所属社区中的结构嵌套深度。

3.4. 综合重要性指标构建

由于不同社区在节点规模和内部连接密度上存在差异, 直接比较各社区中的局部 LDD 层级并不合理。为提高跨社区节点得分的可比性, 本文引入社区内标准化层级得分。

设节点 v_i 属于社区 C_k , 其局部 LDD 值为 $L_{\text{local}}(v_i)$, 社区 C_k 的节点集合为 V_{C_k} , 节点数量为 $|V_{C_k}|$ 。记社区 C_k 中局部 LDD 值严格小于节点 v_i 的节点数量为:

$$N_{<i}^{(k)} = \left| \left\{ v \in V_{C_k} \mid L_{\text{local}}(v) < L_{\text{local}}(v_i) \right\} \right| \quad (9)$$

则节点 v_i 的社区内标准化层级得分定义为:

$$S_i = \frac{N_{<i}^{(k)} + 1}{|V_{C_k}| + \theta} \quad (10)$$

其中, θ 为结构平滑因子, 用于降低小规模社区中节点层级变化对得分造成的放大效应。本文将 θ 定义为全网平均社区规模:

$$\theta = \frac{N}{K} \quad (11)$$

其中, N 为全网节点总数, K 为社区数量。该标准化处理能够在保留节点局部层级优势的同时, 增强不同社区之间节点得分的可比性。

在此基础上, 受 LDD+中邻居贡献思想启发[16], 本文进一步融合全局一阶邻居结构贡献, 构建最终的 CD-LDD+指标:

$$\text{CD-LDD}^+(v_i) = S_i + \alpha \sum_{v_j \in \Gamma(v_i)} S_j \quad (12)$$

其中, $\Gamma(v_i)$ 表示节点 v_i 在全局网络中的一阶邻居集合, S_j 为邻居节点 v_j 的社区内标准化层级得分, α 为邻居贡献调节系数。需要说明的是, 邻居集合并不局限于节点所属社区内部, 而是基于全局网络的一阶邻接关系计算。

因此, CD-LDD+既能够刻画节点在所属社区中的局部核心性, 又能够通过全局邻居贡献补充其跨社区连接价值和邻域结构质量。该指标将社区结构、局部核心层级和邻居结构质量相结合, 有助于提高复杂网络关键节点识别的区分度和合理性。

3.5. 算法复杂度分析

设复杂网络 $G=(V,E)$ 的节点数和边数分别为 n 和 m , 划分后得到 K 个社区。社区 c 的节点数和内部边数分别记为 n_c 和 m_c , 满足 $\sum_{c=1}^K n_c = n$ 和 $\sum_{c=1}^K m_c \leq m$ 。CD-LDD+主要包括谱平分、社区内 LDD 分解、层级得分标准化和全局邻居贡献计算四个阶段。

在谱平分阶段, 构造待划分子图的稀疏拉普拉斯矩阵需要 $O(n_q + m_q)$ 时间。本文代码采用稀疏特征值算法计算两个最小特征值及其对应特征向量。设第 q 次谱分解的迭代次数为 I_q , 对应子图节点数和边数为 n_q 和 m_q , 则该阶段的时间复杂度为

$$O\left(\sum_{q=1}^{K-1} I_q (n_q + m_q)\right) \quad (13)$$

本文实验设置 $K=2$, 只进行一次谱平分, 因此该阶段可表示为 $O(I(n+m))$ 。

对于社区 c , 设第 r 轮 LDD 剥离前的残留节点数为 $n_{c,r}$, 剥离轮数为 L_c 。每轮需要遍历当前残留节点以计算最小度和确定待删除节点, 而全部节点和边在删除过程中只被处理有限次, 因此社区内 LDD 的时间复杂度为

$$O\left(n_c + m_c + \sum_{r=1}^{L_c} n_{c,r}\right) \quad (14)$$

在最坏情况下, 每轮仅删除一个节点, 此时其上界为 $O(n_c^2 + m_c)$ 。所有社区的局部 LDD 总时间复杂度为

$$O\left(\sum_{c=1}^K (n_c^2 + m_c)\right) \quad (15)$$

对局部 LDD 层级进行排序并利用二分查找计算社区内标准化得分需要 $O\left(\sum_{c=1}^K n_c \log n_c\right)$ 时间, 其上界为 $O(n \log n)$ 。全局一阶邻居贡献计算需要遍历全部节点及其邻接关系, 时间复杂度为 $O(m+n)$ 。因此, CD-LDD+的最坏时间复杂度可以表示为

$$O\left(\sum_{q=1}^{K-1} I_q (n_q + m_q) + \sum_{c=1}^K n_c^2 + n \log n + m\right) \quad (16)$$

在采用邻接表和稀疏拉普拉斯矩阵存储的条件下, 算法总体空间复杂度为 $O(n+m)$ 。

4. 仿真实验与分析

4.1. 实验设置与评价指标

本文选取 Zachary's Karate Club 网络[21]作为实验数据集。该网络包含 34 个节点和 78 条边, 记录了空手道俱乐部成员之间的社交关系, 具有明显社区结构, 适合用于验证复杂网络关键节点识别方法。该网络规模适中, 便于对比不同方法在局部核心节点识别上的表现。

为评估 CD-LDD+方法的有效性, 同时进行对比验证, 实验选取四种节点重要性评价方法: 度中心性

(Degree, DC)、K-shell 分解法(KS)、全局最小度分解(Global LDD)以及本文提出的 CD-LDD+方法。其中, 度中心性能够反映节点的一阶邻居数量, K-shell 分解法能够刻画节点所处的全局壳层位置, 全局 LDD 方法则在 K-shell 的基础上进一步细化剥离层级。通过与上述方法对比, 可以较为全面地检验 CD-LDD+在局部社区核心性刻画和节点排序精细化方面的改进效果。

节点重要性评价方法不仅需要识别高影响力节点, 还应尽量减少节点得分并列。若大量节点获得相同分值, 则说明该方法难以区分节点之间的细微结构差异。为此, 本文采用单调性指数[14]-[16] M 衡量不同评价方法的区分能力, 其定义如下:

$$M = \left(1 - \frac{\sum_{r \in R} n_r (n_r - 1)}{n(n-1)} \right)^2 \quad (17)$$

式中, n 为节点总数, R 为不同分值集合, n_r 为得分为 r 的节点数量。 M 的取值范围为 $[0,1]$, M 越接近 1, 说明并列节点越少, 节点排序区分能力越强[15] [16]。

为进一步检验节点排序与实际传播能力之间的一致性, 本文采用 SIR 模型[22]进行传播模拟。实验中依次选取每个节点作为唯一初始感染源, 其余节点为易感态; 感染节点以概率 β 感染其易感邻居, 并以概率 γ 转变为恢复态, 传播过程持续到网络中不存在感染态节点为止。根据传播动力学理论[22], 该网络的理论传播阈值 $\beta_c = 0.1477$ 。本文实验中设置传播率 $\beta = 1.5\beta_c = 0.2216$ 且恢复率设定为 $\gamma = 1.0$ 。每个节点作为初始感染源时均独立运行 1000 次 SIR 模拟, 并以最终恢复节点数量的平均值作为其传播影响力:

$$F(i) = \frac{1}{T} \sum_{t=1}^T R_i^{(t)} \quad (18)$$

其中, $T=100$ 为独立模拟次数; $R_i^{(t)}$ 表示以节点 i 为初始感染源时第 t 次模拟得到的最终恢复节点数。

排序一致性采用 Kendall τ 系数[23]衡量, 其计算公式为:

$$\tau = \frac{n_c - n_d}{\sqrt{(n_0 - n_1)(n_0 - n_2)}} \quad (19)$$

其中, n_c 和 n_d 分别表示一致节点对和不一致节点对的数量, $n_0 = \frac{n(n-1)}{2}$ 、 n_1 和 n_2 分别表示两个排序序列中由于并列值产生的修正项。 τ 越大, 说明节点重要性排序越接近 SIR 模拟得到的传播影响力排序。

4.2. 社区划分与局部结构分析

为验证本文方法对网络中观结构的刻画能力, 首先采用谱平分法对 Karate Club 网络进行社区划分, 网络原始拓扑结构与社区划分结果如下图 1 所示。谱平分后网络被划分为两个社区, 规模分别为 16 和 18。该结果能够较好反映 Karate Club 网络中存在的派系结构, 为后续在社区内部执行局部 LDD 分解提供基础。

在获得社区划分结果后, 本文分别在两个社区诱导子图内部执行 LDD 分解, 得到节点在所属社区中的局部剥离层级。下图 2 将社区 C1 和社区 C2 的局部 LDD 分解结果合并展示。可以看出, 不同社区内部的节点层级存在明显差异: 社区 C1 中节点 1、2、3、4 等处于较高剥离层级, 说明其在该社区内部具有较强局部稳定性; 社区 C2 中节点 33 和节点 34 位于较高层级, 反映出其在对应社区内部具有较重要的结构地位。

与直接在全局网络上执行 LDD 不同, 社区内 LDD 能够从局部模块角度刻画节点的相对核心程度。对于一些全局壳层值不突出、但在所属社区中具有较强凝聚作用的节点, CD-LDD+可通过社区内标准化层级得分对其进行补偿, 从而避免全局剥离顺序对局部核心节点造成低估。




Figure 1. Network topology comparison chart

图 1. 网络拓扑对比图




Figure 2. Local LDD decomposition results for two communities

图 2. 两个社区的局部 LDD 分解结果

4.3. 节点排序与传播影响力对比

不同节点重要性评价方法的单调性指数 M 和 Kendall τ 结果如下表 1 所示。

Table 1. Monotonicity index and ranking correlation comparison for different node importance evaluation methods

表 1. 不同节点重要性评价方法的单调性指数与排序相关性对比

方法	单调性指数 M	Kendall 相关系数 τ
Degree (DC)	0.7079	0.7307
K-shell (KS)	0.4958	0.6692
Global LDD	0.6463	0.6938
Proposed CD-LDD+	0.9472	0.7733

由表 1 可见, K-shell 方法的单调性指数为 0.4958, 在四种方法中最低, 说明其粗粒度壳层划分容易造成较多节点并列。Global LDD 的 M 值为 0.6463, 相比 K-shell 有一定提升, 表明最小度分解能够在一定程度上细化节点层级。Degree 方法的 M 值为 0.7079, 说明度值在 Karate Club 网络中具有一定区分能力, 但其主要反映直接邻居数量, 缺乏对节点所处社区位置和邻域质量的综合刻画。

相比之下, CD-LDD+ 的 M 值达到 0.9472, 为四种方法中最高, 说明本文方法能够显著减少节点排序并列现象, 提高节点重要性评价的分辨率。该结果表明, 将社区内局部 LDD 层级与全局一阶邻居贡献相结合, 有助于更细致地区分不同节点之间的结构差异。

从 Kendall τ 结果看, Degree 方法的 τ 为 0.7307, 说明节点度值与传播能力之间存在较强相关性; K-shell 和 Global LDD 的 τ 分别为 0.6692 和 0.6938, 均低于 Degree。本文方法 CD-LDD+ 的 τ 达到 0.7733, 说明其排序结果与 SIR 传播影响力之间具有最高一致性。相比 Global LDD, CD-LDD+ 在社区内部执行局部分解, 能够更准确刻画节点在所属模块中的核心程度, 同时邻居贡献项补充了节点所连接邻居的结构质量, 因此能够提升传播能力预测的准确性。

为进一步观察不同方法识别出的高排名节点在传播过程中的动态表现, 本文选取各方法排名前 5 的节点作为初始感染源集合进行 SIR 模拟, 结果如图 3 所示。




Figure 3. SIR propagation results for the Top-5 nodes using different methods

图 3. 不同方法 Top-5 节点的 SIR 传播结果

由图 3 可见, CD-LDD+ 与 Degree 方法的累计感染比例整体较高, 最终传播规模接近, 并均明显高于 K-shell 和 Global LDD。这说明本文方法识别出的高排名节点具有较强传播能力。需要指出的是, Degree 在 Karate Club 这类小规模社交网络中具有一定天然优势, 但结合表 1 可知, CD-LDD+ 在保持较好传播效果的同时, 还具有更高的排序区分度和更强的传播一致性, 因此综合表现更优。

4.4. 参数与代表节点分析

CD-LDD+ 中邻居贡献调节系数 α 用于平衡节点自身社区内层级得分与邻居结构贡献。如下图 4 所示, 参数敏感性实验表明, 当 $\alpha = 0$ 时, 算法仅考虑节点在社区内部的局部 LDD 层级, 此时 τ 值为 0.5400,

说明单独使用社区内层级信息不足以全面刻画节点传播能力。随着 α 增大, τ 值整体上升; 当 α 位于 0.8 至 1.0 区间时, τ 稳定在 0.7733 左右, 达到较优水平。因此, 本文主实验取 $\alpha = 0.8$ 。该结果表明, 适当引入邻居结构质量能够增强 CD-LDD+对传播影响力的预测能力, 但当邻居贡献权重继续增大后, 性能提升趋于稳定。




Figure 4. Correlation coefficient τ for different α values

图 4. 不同 α 取值对应的相关系数 τ 值

为了进一步解释 CD-LDD+的排序作用机制, 本文选取 Karate Club 网络中的代表性节点进行排名对比, 结果如下表 2 所示。

Table 2. Ranking comparison of representative nodes across methods

表 2. 代表性节点在不同方法下的排名对比

节点编号	DC 排名	KS 排名	Global LDD 排名	CD-LDD+排名
1	2	1	1	1
34	1	10	10	2
3	4	3	3	3
33	3	9	9	4

由表 2 可见, 节点 1 在 K-shell、Global LDD 和 CD-LDD+中均排名第 1, 说明其作为派系核心节点的结构地位较为稳定。节点 3 在各方法中也保持较高排名, 表明其同时具有较强局部连接能力和一定传播潜力。相比之下, 节点 34 和节点 33 更能体现 CD-LDD+的改进作用。节点 34 在 Degree 方法中排名第 1, 说明其直接连接能力较强, 但在 K-shell 和 Global LDD 中均仅排名第 10, 表明传统壳层分解或全局 LDD 未能充分体现其在所属社区中的局部核心地位; CD-LDD+将其提升至第 2, 说明社区内 LDD 分解和邻居贡献融合能够有效识别这类局部领袖节点。节点 33 也呈现类似现象, 其在 K-shell 和 Global LDD 中均排名第 9, 而在 CD-LDD+中提升至第 4。综上, CD-LDD+并非简单偏向高度节点, 而是在社区局部

核心性和全局邻居贡献之间进行综合平衡, 从而提高复杂网络关键节点识别的合理性。

5. 结束语

针对传统 K-shell 分解法区分度不足以及全局 LDD 方法对局部核心节点刻画不充分的问题, 本文在已有 LDD 及 LDD+思想基础上, 引入社区发现机制, 提出了一种基于社区发现和最小度分解的复杂网络节点重要性度量方法 CD-LDD+。该方法首先利用谱平分法对原始网络进行社区划分, 再在各社区诱导子图内部独立执行最小度分解, 并结合节点的社区内标准化层级得分和全局一阶邻居贡献构建综合评价指标。以 Zachary's Karate Club 网络为实验对象的结果表明, 本文方法在节点排序区分度和与 SIR 传播影响力的一致性方面均表现较好, 能够在一定程度上弥补传统壳层分解方法对局部核心节点识别不足的问题。后续研究将进一步在更多真实网络上验证该方法的适用性, 并探讨不同社区发现算法、有向加权网络及动态网络场景下节点重要性评估方法的扩展问题。

参考文献

- [1] Albert, R. and Barabási, A. (2002) Statistical Mechanics of Complex Networks. *Reviews of Modern Physics*, **74**, 47-97. <https://doi.org/10.1103/revmodphys.74.47>
- [2] Newman, M.E.J. (2003) The Structure and Function of Complex Networks. *SIAM Review*, **45**, 167-256. <https://doi.org/10.1137/s003614450342480>
- [3] Ait Rai, K., Machkour, M. and Antari, J. (2023) Influential Nodes Identification in Complex Networks: A Comprehensive Literature Review. *Beni-Suef University Journal of Basic and Applied Sciences*, **12**, Article No. 18. <https://doi.org/10.1186/s43088-023-00357-w>
- [4] Chen, D., Lü, L., Shang, M., Zhang, Y. and Zhou, T. (2012) Identifying Influential Nodes in Complex Networks. *Physica A: Statistical Mechanics and Its Applications*, **391**, 1777-1787. <https://doi.org/10.1016/j.physa.2011.09.017>
- [5] Kitsak, M., Gallos, L.K., Havlin, S., Liljeros, F., Muchnik, L., Stanley, H.E., et al. (2010) Identification of Influential Spreaders in Complex Networks. *Nature Physics*, **6**, 888-893. <https://doi.org/10.1038/nphys1746>
- [6] Freeman, L.C. (1978) Centrality in Social Networks Conceptual Clarification. *Social Networks*, **1**, 215-239. [https://doi.org/10.1016/0378-8733\(78\)90021-7](https://doi.org/10.1016/0378-8733(78)90021-7)
- [7] Lü, L., Zhou, T., Zhang, Q. and Stanley, H.E. (2016) The H-Index of a Network Node and Its Relation to Degree and Coreness. *Nature Communications*, **7**, Article No. 10168. <https://doi.org/10.1038/ncomms10168>
- [8] Freeman, L.C. (1977) A Set of Measures of Centrality Based on Betweenness. *Sociometry*, **40**, 35-41. <https://doi.org/10.2307/3033543>
- [9] Katz, L. (1953) A New Status Index Derived from Sociometric Analysis. *Psychometrika*, **18**, 39-43. <https://doi.org/10.1007/bf02289026>
- [10] Brin, S. and Page, L. (1998) The Anatomy of a Large-Scale Hypertextual Web Search Engine. *Computer Networks and ISDN Systems*, **30**, 107-117. [https://doi.org/10.1016/s0169-7552\(98\)00110-x](https://doi.org/10.1016/s0169-7552(98)00110-x)
- [11] Lü, L., Zhang, Y., Yeung, C.H. and Zhou, T. (2011) Leaders in Social Networks, the Delicious Case. *PLOS ONE*, **6**, e21202. <https://doi.org/10.1371/journal.pone.0021202>
- [12] Dorogovtsev, S.N., Goltsev, A.V. and Mendes, J.F.F. (2006) k-Core Organization of Complex Networks. *Physical Review Letters*, **96**, Article ID: 040601. <https://doi.org/10.1103/physrevlett.96.040601>
- [13] Zeng, A. and Zhang, C. (2013) Ranking Spreaders by Decomposing Complex Networks. *Physics Letters A*, **377**, 1031-1035. <https://doi.org/10.1016/j.physleta.2013.02.039>
- [14] Bae, J. and Kim, S. (2014) Identifying and Ranking Influential Spreaders in Complex Networks by Neighborhood Coreness. *Physica A: Statistical Mechanics and Its Applications*, **395**, 549-559. <https://doi.org/10.1016/j.physa.2013.10.047>
- [15] 熊才权, 古小惠, 吴歆韵. 基于 K-shell 位置和两阶邻居的复杂网络节点重要性评估方法[J]. *计算机应用研究*, 2023, 40(3): 738-742.
- [16] Yu, Y., Jing, M., Zhao, N. and Zhou, T. (2025) Lowest Degree Decomposition of Complex Networks. *Chaos, Solitons & Fractals*, **199**, Article ID: 116765. <https://doi.org/10.1016/j.chaos.2025.116765>
- [17] Fortunato, S. (2010) Community Detection in Graphs. *Physics Reports*, **486**, 75-174. <https://doi.org/10.1016/j.physrep.2009.11.002>

-
- [18] Wang, Z., Huang, R., Yang, D., Peng, Y., Zhou, B. and Chen, Z. (2024) Identifying Influential Nodes Based on the Disassortativity and Community Structure of Complex Network. *Scientific Reports*, **14**, Article No. 8453. <https://doi.org/10.1038/s41598-024-59071-x>
- [19] Fiedler, M. (1973) Algebraic Connectivity of Graphs. *Czechoslovak Mathematical Journal*, **23**, 298-305. <https://doi.org/10.21136/cmj.1973.101168>
- [20] Newman, M.E.J. (2006) Finding Community Structure in Networks Using the Eigenvectors of Matrices. *Physical Review E*, **74**, Article ID: 036104. <https://doi.org/10.1103/physreve.74.036104>
- [21] Zachary, W.W. (1977) An Information Flow Model for Conflict and Fission in Small Groups. *Journal of Anthropological Research*, **33**, 452-473. <https://doi.org/10.1086/jar.33.4.3629752>
- [22] Kermack, W.O. and McKendrick, A.G. (1927) A Contribution to the Mathematical Theory of Epidemics. *Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character*, **115**, 700-721. <https://doi.org/10.1098/rspa.1927.0118>
- [23] Kendall, M.G. (1938) A New Measure of Rank Correlation. *Biometrika*, **30**, 81-93. <https://doi.org/10.1093/biomet/30.1-2.81>