

基于博弈的有向时序网络两阶段社区发现算法

董继远, 刘九强

(贵州财经大学大数据统计学院, 贵阳 550000)

摘要:文中提出一种新的用于时序有向网络的两阶段社区发现算法。第1个阶段通过节点距离、源节点影响力、目标节点影响力和节点分解度4个矩阵,确定节点在网络中的重要程度;第2阶段根据节点重要程度确定社区划分的核心节点,接着分别令核心节点作为源头进行级联传播,其他节点通过博弈确定与各个领导节点的跟随度,最后选择跟随度最高的节点所领导的社区。将算法在国际贸易网络中进行实证研究表明,该算法能够适用于现实世界时序有向加权网络中。

关键词:有向动态网络;社区发现;节点影响力;级联行为

中图分类号: TP399 **文献标志码:** A **文章编号:** 1671-1807(2024)03-0154-07

近年来,研究人员对复杂网络结构进行了很多研究,反应连边紧密程度的社区结构也在其中。在经典的理解中,社区结构具有内部集群关系密集而不同社区之间关系稀疏的特征。目前有很多基于静态网络的社区划分算法,有通过矩阵计算的方法^[1],通过监督式学习如标签传播的方法^[2-3]和基于节点关键程度的方法^[4],以及通过图嵌入进行社区发现的算法^[5]。

然而,大多数真实世界的图都是动态的,因为它们随着时间的推移而变化,新数据产生了需要合并到现有图中的新顶点和边,从而使网络结构发生相应的变化。传统的静态图分析方法在满足这一需求方面面临着重大限制^[6]。使用传统的静态网络社区探索算法分析动态网络社区时,往往会忽视节点在时间维度上的关联,从而对社区结构的演化分析出现偏差。

现在学者已经提出了一些时序网络社区发现算法。例如,基于谱聚类的动态社区发现算法(spectral clustering based dynamic community discovery algorithm, SC-DCDA)^[7];基于层次聚类算法作为初始时间段内动态时序网络的社区划分算法^[8];Lin等^[9]提出的关于节点历史信息的社区发现算法;He和Chen^[10]利用独立时空的方式进行时序网络上的社区划分与演化行为。

随着贸易全球化的发展,复杂网络模型在贸易

分析中展现出很多优势,不少学者进行了相关的应用与研究。例如,谭丹和杨曼羚^[11]通过构建网络对亚太14国间机电产品贸易进行研究;蒋培祥和董志良^[12]通过网络模型对常规能源贸易网络进行分析研究;何健佳和郑添元^[13]建立了“负载-容量”模型发掘汽车供应链网络中关节节点。

本文将有序向动态网络社区划分任务分为两个步骤:第1个阶段通过节点距离、源节点影响力、目标节点影响力以及节点分解度4个矩阵,确定节点在网络中的重要程度;第2阶段确定社区划分的核心节点,接着分别令核心节点作为源头节点进行级联传播,其他节点通过博弈收益值确定与各个领导节点的跟随度,最后选择跟随度最高的节点所领导的社区。使用Huo等^[14]编制的2015—2019年共5年的全球区域投入产出表构建全球时序贸易网络,通过两阶段社区发现算法,探索动态网络中的关键节点和社区结构。

1 理论基础

1.1 有向加权网络模型

图论和矩阵法是社会网络分析中常用的数据表示方式。庞大的系统可以映射到复杂网络中,系统中的元素视为网络中的节点,系统中元素之间的关联视为网络中的连边。根据研究问题的需要连边可以选择有向与无向、赋权与不赋权。

一般的,有向复杂网络可以由 $G=(N,E,W)$ 表

收稿日期: 2023-07-22

基金项目: 贵州财经大学研究生项目(2022ZXSY035)

作者简介: 董继远(1996—),男,甘肃兰州人,硕士研究生,研究方向为复杂网络、博弈论;通信作者刘九强(1973—),男,江苏扬州人,教授,博士,研究方向为博弈论。

示。其中: $N = \{v_1, v_2, \dots, v_n\}$ 表示网络的节点集; $E = \{\langle v_i, v_j \rangle \mid v_i, v_j \in V, i \neq j\}$ 表示网络中的节点连边; $\langle v_i, v_j \rangle$ 表示节点 v_i 指向节点 v_j 的有向边; $W = \{\omega(v_i, v_j) \mid v_i, v_j \in V, i \neq j\}$ 表示图中边 $e_{\langle ij \rangle}$ 的权重。

为方便计算,用 $A_{m \times m}$ 表示网络 G 的邻接矩阵,其中 $m = |V|$ 表示图的节点数, A 中元素 $a_{ij} = \omega(v_i, v_j)$, 在无权图中, $\omega(v_i, v_j)$ 取 1 或 0, 在加权图中, $a_{ij} = \omega(v_i, v_j)$ 表示边 $e_{\langle ij \rangle}$ 的权重。

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mm} \end{pmatrix} \quad (1)$$

通过邻接矩阵的 n 次幂可以得到节点对间长度为 n 的路径数量。

现实生活中,网络中的节点与边都是随时间发生变化的,因此按时间段选取结点并在这些时间节点对不停变化的某个网络进行快照处理就构建出了时序网络模型,用 $G = \{G_1, G_2, G_3, \dots\}$ 来表示,其中 $G_t = \{N_t, E_t, W_t\}$ 表示在 t 时刻的切片网络, N_t, E_t, W_t 分别代表 t 时刻的节点集、边集以及连边权重的集合,用 A_t 表示 G_t 对应的邻接矩阵。

1.2 独立级联传播模型

独立级联模型(independent cascade)^[15] 研究信息在网络中的传播最大化。独立级联模型是一种经典的扩散模型,该模型假定网络中每个节点根据是否受信息影响而处于激发 B^* 或者非激发 B 两种状态。处于非激发的节点会受其邻居节点的影响转为激发状态,同时激发状态是不可逆的,即处于激发状态的节点不会转变为非激发状态。在传播的初期只有设定的节点处于激发状态,其余节点均处于非激发状态,当节点 $Node_i$ 在时刻 a 转变为激发状态,那么它将在 $a+1$ 时刻尝试激发它的邻居节点,传播过程将在网络中没有新的节点会被激发时停止。

通过将节点看作博弈参与者、博弈者的不同策略组成策略空间和所有节点的不同策略选择获得不同的效用值,便可将博弈的思想引入网络分析当中。本文的网络节点集 $N = \{1, 2, \dots, n\}$, 表示博弈中参与者的集合,用 $S = \prod_{i=1}^n S_i$ 表示全图的策略空间。在每次传播过程中,节点是否被激发(B^*),取决于需要与其邻居依次进行协调博弈的收益。收益矩阵见表 1。当其激发时获得的总收益大于某个阈值时,则选择转变为激发状态。

表 1 节点收益矩阵

节点状态	B^*	B
B^*	(1,1)	(0,0)
B	(0,0)	(1,1)

2 两阶段动态有向网络社区发现算法

提出一种两阶段的动态有向网络社区发现算法,该算法主要包括两个部分:①通过构建网络邻接矩阵,计算节点的重要程度,挖掘出网络中的局部核心节点与全局核心节点;②将网络中的局部核心节点作为社区中心节点,让每个核心节点作为源头向其余节点进行标签传播,将每个跟随者节点通过与其邻居间的协调博弈进行策略选择(更改或不更改当前标签)得到对当前核心节点的关联度,在所有核心节点进行标签传播结束后,各个跟随者节点选择加入关联度最高的社区,得到最终的社区划分结果。

2.1 阶段 1: 节点关键程度

在有向图中,节点强度可以根据连边方向的不同分为节点的出强度 S_i^{out} 以及节点入强度 S_i^{in} , 结合两者可以定义节点交叉强度。

定义 1: 节点交叉强度。在有向网络中,某个节点的交叉强度由该节点的入强度与出强度正相关,可以用式(2)表示,通过这个节点同社区中的负邻居数与不同社区中的负邻居数的和来确定。

$$S_i = \lambda S_i^{\text{in}} + (1 - \lambda) S_i^{\text{out}} = \lambda \sum_{p \in Ne_i^{\text{in}}} \omega_{pi} + (1 - \lambda) \sum_{q \in Ne_i^{\text{out}}} \omega_{iq} \quad (2)$$

式中: λ 为一个介于 0 与 1 的常数,可以根据研究的需求确定,当其大于 0.5 时,表示入强度对节点重要性的影响更大,若小于 0.5 则表示出强度对节点的重要性影响更大; ω_{pi} 为有向边 $e_{\langle pi \rangle}$ 的权重; ω_{iq} 为有向边 $e_{\langle iq \rangle}$ 的权重; $Ne_i^{\text{in}}, Ne_i^{\text{out}}$ 分别为节点 i 的入邻居所构成的集合与出邻居构成的集合。

为了发现节点的重要性,引用王雨和郭进利^[16] 的方法,构建效率矩阵 E 、以源节点为中心的影响力矩阵 L 和以目标节点为中心的影响力矩阵 T 。

(1)效率矩阵 E , 其中元素 $E_{ij} = 1/d_{ij}$, 为从节点 i 出发至节点 j 最短路径长度的倒数。

(2)以源节点为中心的影响力矩阵 L , 矩阵元素为 $A_{ij}^{d_{ij}} / \sum_{k=1}^n A_{kj}^{d_{ij}}$, 表示从节点 i 出发至节点 j 最短路径数与从节点 i 出发路径长度为 d_{ij} 的路径数目的比值。

(3)以目标节点为中心的影响力矩阵 T , 其中元素为 $A_{ij}^{d_{ij}} / \sum_{k=1}^n A_{kj}^{d_{ij}}$, 表示从节点 j 出发至节点 i 最短

路径数与从其他节点出发至节点 i 的长度为 d_{ij} 的路径数目的比值。

在社区划分任务中,具有较高重要性的节点往往处于相同的社区中,为了发现有效的社区发现核心节点,受 Shahriari 和 Klammar^[17]在符号网络社区划分中基于混合度与信息扩散的算法(signed degree mixing and information diffusion, SDMID)的启发,引入了节点分解度矩阵 D ,其中元素

$$D_{ij} = p | \deg_{in}(i) - \deg_{in}(j) | + (1-p) | \deg_{out}(i) - \deg_{out}(j) | \quad (3)$$

式中: p 为一个介于 0 与 1 的常数,可以根据研究的需求确定,本文中取值为 0.5; $\deg_{in}(i)$ 、 $\deg_{out}(i)$ 分别为节点 i 的入度与出度。

结合节点分解度矩阵与前面 3 个矩阵进行赋权加总,构建影响力-分解度矩阵,采用(0,1,2)三标度法对 4 个矩阵进行两两比较,比较矩阵见表 2,其中, b_{ij} 取值为 0 时表示 i 不如 j 重要,取值为 1 时表示 i 与 j 同等重要,当取值为 2 时则表示 i 比 j 更重要。接着利用极差法将比较矩阵转化为判断矩阵,并进行一致性检验得到矩阵权重。

比较矩阵的构建考虑到,效率矩阵 E 通过距离直接体现了节点间的亲疏关系,而且在比较节点间的影响比例值大小时,首先要考虑的是两节点之间的距离,然后再去考虑当距离相同时,最短路径数对比例值的影响。因此可认为效率矩阵 E 比其他两个矩阵更加重要;而矩阵 L 和 T 都是基于最短路径数来研究节点间的相互影响的,区别仅在于侧重点不同, L 考虑到影响节点对网络中所有待评估节点的影响, T 考虑到网络中所有影响节点对待评估节点的影响,这两种情况都需要考虑在内,无法比较其好坏,因此认为这两个矩阵具有同等的重要性。在社区划分的任务中,关键值较高的节点相对集中,会划分子同一社区当中,因此为了选取相对分散的聚类核心节点,节点的分解度矩阵 D 较其余 3 个矩阵赋予更高的权重。

经过一致性检验,4 个矩阵权重分别为 $w_E = 2/9$, $w_T = 1/18$, $w_L = 1/18$, $w_D = 2/2$, 这样得到影响力矩阵为 $M = 2/9E + 1/18T + 1/18L + 2/3D$, 其中元素 m_{ij} 表示节点 i 对节点 j 的影响力。

表 2 比较矩阵

矩阵	E	L	T	D
E	1	2	2	0
L	0	1	1	0
T	0	1	1	0
D	2	2	2	1

以综合影响力矩阵为基础结合节点交叉强度,最终节点的重要度为

$$C_i = S_i \sum_{k=1, i \neq k}^n I_k m_{ki} \quad (4)$$

式中: $I_k m_{ki}$ 为节点 i 在网络中的相对影响力; $I_k = \frac{1}{n-1} \sum_{j=1, j \neq k}^n \frac{1}{d_{kj}}$ 为节点 k 到网络中其他节点的距离的倒数的平均值。

2.2 阶段 2: 节点社区发现

在确定节点重要性后,基于级联模型发现网络中的社区结构。为了设置级联行为的发起者,定义了局部中心节点。

定义 2: 局部中心节点。 当一个节点的领导度高于其所有邻居节点的领导度时,则将其定义为局部中心节点。

在时序网络建模中,第 t 期节点的演化行为会收到前期经验的影响,因此节点在决策过程中,不仅仅要考虑节点的收益值,还需要总结前期的经验。为此,当第 $t-1$ 期节点 $Node_i$ 为局部中心节点时,第 t 期它的领导度只需要高于 80% 邻居的领导度时,则将其设定为第 t 期的局部中心节点。

在获得局部中心节点集合后,依次令领导节点作为信息传播的源节点,其他节点设置为跟随者节点,在传播的开始将该领导节点的策略选择设定为 B^* 即激发状态,其他节点的策略选择设定为未激发状态 B ,接着按随机次序对跟随者节点进行信息传播,当转变策略收益值大于当前的阈值时,便依一定概率转变为激发状态 B^* ,并更新对领导节点 l 的归属感 C_{li} ,在所有领导节点迭代结束后,跟随者节点将最终选择接入归属感最大的一个或多个局部中心节点社区。在所有迭代结束后,使用余弦相似度对相似度较高的社区进行合并操作。算法流程见算法 1。

算法 1: 基于级联行为博弈的社区发现算法

Input: Network $G=(V, E, W)$;
Leader nodes list LL

Output: C

```

1  for  $l$  in  $LL$  do
2       $l$ 's behavior  $\leftarrow B^*$ 
3      threshold  $\leftarrow 0.5$ 
4      followerlist  $\leftarrow V - \{l\}$ 
5      for  $f$  in followerlist do
6           $f$ 's behavior  $\leftarrow B$ 
7          randomly generate node sequence  $S_d$ 
8      for  $i$  in  $S_d$  do
9          if payoff( $i$ ) > threshold then
10              $i$ 's behavior  $\leftarrow B^*$ 
11              $CM_{li}$   $\leftarrow 1/(t * * 2)$ 
12             update threshold

```

算法中阈值按二分搜索法逐渐变化,搜索上界 T_u ,下界 T_l 的初始值分别设置为 1 和 0, 阈值 $threshold = (T_u + T_l)/2$, 如果所有节点都分配给至少一个社区, 则减小上限, 否则增大下限。在算法中, 将迭代次数设置为 20。

3 实证分析

3.1 数据来源及预处理

引用 Huo 等^[14]编制的 2015—2019 年共 5 年的全球区域投入产出表, 每张区域投入产出表由 245 个经济体的 135 个部门构成, 表的架构如图 1 所示。

3.2 评价措施

引入模块度^[18]和标准化互信息^[19]评估社区划分的效果。

模块度 Q_G 的计算方法为

$$Q_G = \frac{1}{2w} \sum_i \sum_j \left(w_{ij} - \frac{w_i w_j}{2w} \right) \delta(C_i, C_j) \quad (5)$$

式中: w_{ij} 为节点 i 指向 j 的连边权重; w_i 为以节点 i 为源节点的总权重; w_j 为以节点 j 为目标节点的总权重; $\delta(C_i, C_j)$ 为一个表现节点 i 与 j 是否在同一社区的示性函数, 当两个节点处于同一个社区时取值为 1, 否则取值为 0。模块度的数值表现出社区之间连边紧密、连边稀疏的程度, 模块度越高表明划分结果越理想。

最大标准化互信息 (NMI_{\max})^[19]能够表示重叠社团结构的相似度, 取值为 $0 \sim 1$, 取值越大表明社团结构的相似程度越高, 计算公式为

$$NMI_{\max} = \frac{I(X, Y)}{\max[H(X), H(Y)]} \quad (6)$$

式中: $H(X)$ 和 $H(Y)$ 分别为 X 与 Y 的信息熵; $I(X, Y)$ 为 X 与 Y 的交互信息。

3.3 基于 MRIO(国际多区域投入产出表)的动态贸易网络构建

提取出区域投入产出表的中间流量矩阵, 首先

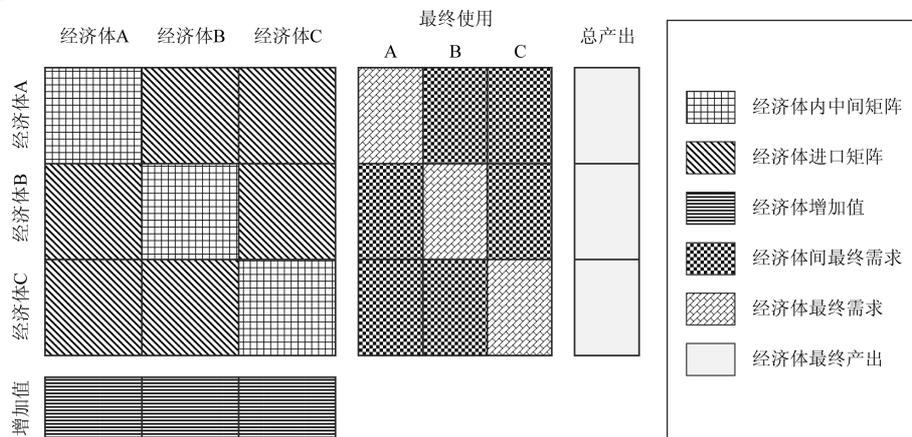


图 1 全球区域投入产出表分解示意图

计算经济体 A 与经济体 B 之间的贸易流 x_{AB} , 空间自相关理论认为距离越远对对方的依赖程度越低, 据此构建基于效率的影响力矩阵, 矩阵中元素 r_{AB} 表示经济体 A 与 B 之间无权网络距离的倒数, 当 $r_{AB} = 0$ 时表示 A 经济体向 B 经济体没有任何直接或间接的贸易关系, 当 $r_{AB} = 1$ 时表示 A 经济体向 B 经济体存在直接的贸易流关系, 当 $0 < r_{AB}$ 时, 表示 A 经济体向经济体 B 虽然没有直接贸易联系, 但是会通过中介经济体产生一定贸易流量。显然, 通常情况下 $r_{AB} \neq r_{BA}$ 。

$$x_{AB} = \sum_k \sum_t g_{AB}^k \quad (7)$$

式中: g_{AB}^k 为经济体 A 的 k 部门流向经济体 B 的 t 部门的贸易量; t 为区域投入产出表中的 135 部门。通过这种方式方法得到 245×245 的贸易流量矩阵:

$$\mathbf{X} = \begin{bmatrix} x^{11} & x^{12} & \cdots & x^{1n} \\ x^{21} & x^{22} & \cdots & x^{2n} \\ \vdots & \vdots & & \vdots \\ x^{n1} & x^{n2} & \cdots & x^{nm} \end{bmatrix} \quad (8)$$

式中: 当 k 取全部 135 个部门时, \mathbf{X} 为国际贸易流量矩阵; 当 k 按照不同需求选取不同的部门时, 便可以构成国际间不同部门的贸易矩阵。

提取出 5 个贸易矩阵后, 以 1 年为时间结点, 各个经济体为网络节点, 经济体之间的流量作为加权有向边, 便可以构成一个关于国际贸易的时序有向加权网络。但是直接利用得到的矩阵构建网络, 连线太多不利于进行网络特征分析, 因此, 根据经济体 A 总投入的均值作为阈值, 若经济体 A 对于经济体 B 的贸易流出大于阈值 t , 则定义经济体 A 对经济体 B 有贸易流出, 否则经济体 A 对经济体 B 没有有贸易流出。这样最终得到的贸易网络可以表示为

$$t_r^{<AB>} = \begin{cases} x_{AB}, & x^{AB} > t \\ 0, & x^{AB} < t \end{cases} \quad (10)$$

式中： t_r 为贸易网络的邻接矩阵。

得到的加权贸易网络基本信息见表3。5年间网络中节点数均为234,相较于整张投入产出表,有11个经济体因为总进出口量不高或编制过程中经济数据获取的原因而未能在贸易网络中出现,但是这些经济体占总体不到5%,没有这些节点对整体网络分析的影响不大。总体来说,5年中连边数的变化不大,连边的平均权重大致呈现逐年增加的趋势,也反映出随着时间变化,经济体之间的贸易是逐渐增加的。

表3 2015—2019年贸易网络基本信息

年份	节点数	边数	边平均权重
2015	234	6 097	971.35
2016	234	6 141	950.55
2017	234	6 043	1 061.40
2018	234	6 128	1 140.32
2019	234	6 041	1 134.99

3.4 区域间贸易关键节点

通过实验,网络中的节点关键程度的前20的经济体见表4,其中每年前20个最关键的节点中都有法国、美国、中国、印度、土耳其、意大利、加拿大、日本、荷兰、新加坡、英国、瑞士、俄罗斯、比利时、韩国、德国和西班牙这17个经济体,可以得出在国际贸易网络中这些网络承担着比较关键的所用。实际上,这些经济体在国际贸易的进口、出口以及中转过程中分别扮演着不同的重要角色,对世界贸易网络的形成起着不可或缺的作用。

3.5 贸易网络社区

社区划分结果如图2所示,图2中横坐标表示社区包含节点的数量,纵坐标表示包含一定数目节点的社区数。试验结果表明,国际贸易网络社区数目逐年减少,经济体之间的贸易联系逐渐变得紧密,展现出贸易倾向于全球化的趋势。

模块度 Q_G 的实验结果见表5,各个年度中,模块度均高于0.49,这表明本文的算法在贸易有向网络重叠社区划分任务中有较好的表现。

表6展示了每一年国际贸易网络社区划分结果的 NMI_{max} 值。表6中显示,除了2016年,其余年份的国际贸易网络划分结果相关程度逐年提升。结合划分结果可以看出,国际贸易网络社区演化较为稳定,同时社区在演化过程中有小社区向大社区中融合的趋势。

表4 2015—2019年国际贸易网络关键节点排名

排名	2015年	2016年	2017年	2018年	2019年
1	美国	法国	美国	美国	美国
2	法国	美国	法国	中国	中国
3	中国	中国	中国	法国	法国
4	德国	印度	德国	德国	德国
5	英国	德国	印度	印度	荷兰
6	意大利	英国	英国	荷兰	意大利
7	印度	荷兰	荷兰	英国	英国
8	荷兰	意大利	韩国	意大利	印度
9	西班牙	韩国	意大利	西班牙	西班牙
10	日本	日本	日本	韩国	新加坡
11	瑞士	西班牙	新加坡	日本	日本
12	韩国	瑞士	西班牙	新加坡	韩国
13	新加坡	新加坡	瑞士	瑞士	比利时
14	加拿大	比利时	比利时	比利时	瑞士
15	比利时	加拿大	土耳其	土耳其	加拿大
16	俄罗斯	土耳其	加拿大	加拿大	土耳其
17	土耳其	俄罗斯	俄罗斯	俄罗斯	俄罗斯
18	泰国	沙特阿拉伯	丹麦	沙特阿拉伯	丹麦
19	澳大利亚	丹麦	沙特阿拉伯	丹麦	沙特阿拉伯
20	巴西	中国香港	澳大利亚	澳大利亚	澳大利亚

表5 2015—2019年国际贸易网络社区划分结果模块度 Q_G

年份	2015	2016	2017	2018	2019
模块度	0.497 7	0.497 4	0.499 4	0.499 7	0.499 4

表6 2015—2019年国际贸易网络社区划分结果

NMI_{max} 值对比

年份	2015	2016	2017	2018	2019
2015	1.000 0	0.418 9	0.524 6	0.655 1	0.558 0
2016	0.418 9	1.000 0	0.388 4	0.408 0	0.388 7
2017	0.524 6	0.388 4	1.000 0	0.613 9	0.523 8
2018	0.655 1	0.408 0	0.613 9	1.000 0	0.707 2
2019	0.558 0	0.388 7	0.523 8	0.707 2	1.000 0

4 结论

提出了一种两阶段有向动态网络社区划分算法,并将该算法在基于全球投入产出表提取出的2015—2019年国际贸易有向加权时序网络上进行了实证分析,得到以下结论。

(1)在第1个阶段,通过网络进阶矩阵构建出节点距离矩阵、源节点影响力矩阵、目标节点影响力矩阵和节点分解度矩阵4个矩阵,通过矩阵计算节点之间的影响力,结合节点交叉乔杜获得节点在整个网络中的影响力。

(2)第2阶段根据节点的影响力和历史记忆信息,确定每个时段的局部中心节点,接着依次以局部中心节点为信息源进行级联传播,获得跟随节点对各个局部中心节点的服从度后加入服从度最高的局部中心节点所领导的社区,最后合并相似度较高的社区,得到最终的社区划分结果。

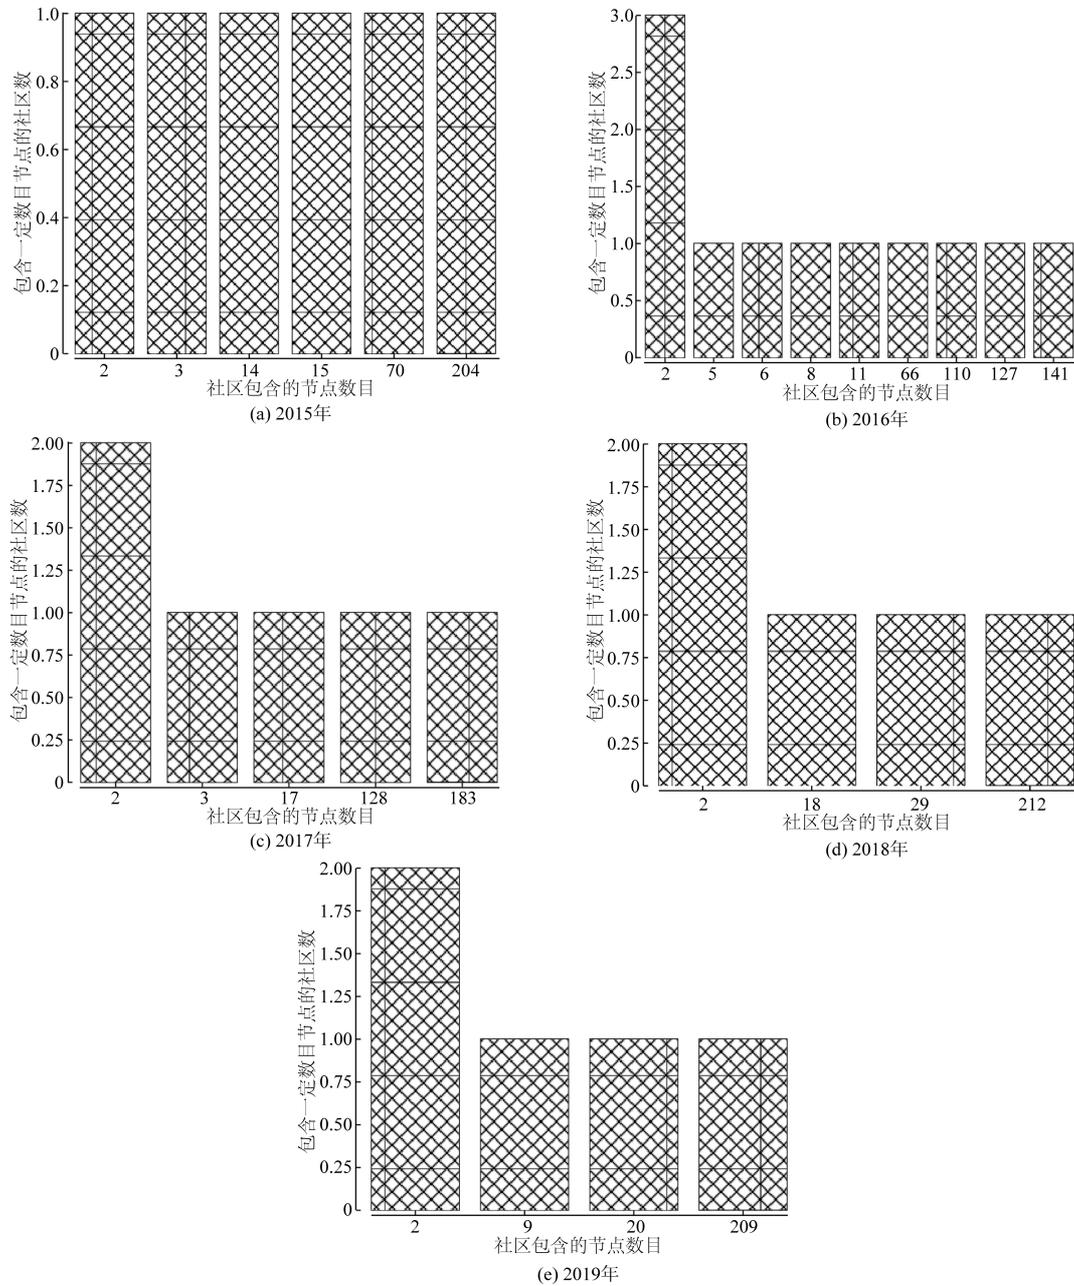


图2 2015—2019年国际贸易网络社区-节点分布

(3)算法在国际贸易加权有向时序网络的实验中,每一年的贸易网络社区划分的模块度 Q_G 均高于 0.49,表明该算法在实际网络的应用中有较好的表现。 NMI_{max} 值表明,贸易网络社区逐渐趋于稳定,经济体之间的贸易合作有聚合在一起的趋势。

参考文献

- [1] TANG J X, WANG C. Spectral clustering-based network community detection with node attributes[J]. *Statistics and Its Interface*, 2019, 12(1): 123-133.
- [2] WANG C, DENG Y, LI X, et al. A label-based nature heuristic algorithm for dynamic community detection [C]//PRICAI 2019: Trends in Artificial Intelligence. Berlin: Springer International Publishing, 2019: 621-632.
- [3] FAN Z, DU X. Self-SLP: community detection algorithm in dynamic networks based on self-paced and spreading label propagation [C]//PRICAI 2023: Trends in Artificial Intelligence. Singapore: Springer, 2024: 310-322.
- [4] YANG T, CHI Y, ZHU S, et al. Directed network community detection: a popularity and productivity link model [C]//Proceedings of the 2010 SIAM International Conference on Data Mining. Philadelphia: Society for Industrial and Applied Mathematics, 2010: 742-753.

- [5] ZHU J, WANG C, GAO C, et al. Community detection in graph: an embedding method[J]. *IEEE Transactions on Network Science and Engineering*, 2022, 9(2): 689-702.
- [6] SENGUPTA D, SUNDARAM N, ZHU X, et al. GraphIn: an online high performance incremental graph processing framework[C]//*European Conference on Parallel Processing*. Berlin: Springer, 2016: 319-333.
- [7] 杨煜, 段威威. 基于谱聚类的社交网络动态社区发现算法[J]. *计算机应用*, 2023, 43(10): 3129-3135.
- [8] 李敏. 动态时序网络的社区演化研究[D]. 武汉: 华中科技大学, 2015.
- [9] LIN Y R, CHI Y, ZHU S, et al. Facetnet: a framework for analyzing communities and their evolutions in dynamic networks[C]//*Proceedings of the 17th International Conference on World Wide Web*. Beijing: WWW, 2008: 21-25.
- [10] HE J, CHEN D. A fast algorithm for community detection in temporal network[J]. *Physica A: Statistical Mechanics and Its Applications*, 2015, 429: 87-94.
- [11] 谭丹, 杨曼羚. 亚太14国机电产品贸易网络格局演变及特征分析[J]. *科技和产业*, 2023, 23(4): 1-7.
- [12] 蒋培祥, 董志良. 常规能源国际贸易网络演化特征研究[J]. *复杂系统与复杂性科学*, 2021, 18(4): 66-73.
- [13] 何建佳, 郑添元. 引力模型下多级供应链网络鲁棒性研究[J]. *科技和产业*, 2022, 22(1): 224-230.
- [14] HUO J, CHEN P, HUBACEK K, et al. Full-scale, near real-time multi-regional input-output table for the global emerging economies(EMERGING)[J]. *Journal of Industrial Ecology*, 2022, 26(4): 1218-1232.
- [15] KLEINBERG J. Cascading behavior in networks: algorithmic and economic issues [J]. *Algorithmic Game Theory*, 2007, 24: 613-632.
- [16] 王雨, 郭进利. 基于多重影响力矩阵的有向加权网络节点重要性评估方法[J]. *物理学报*, 2017, 66(5): 19-30.
- [17] SHAHRIARI M, KLAMMA R. Signed social networks: link prediction and overlapping community detection[C]//*Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*. Paris: IEEE/ACM, 2015: 1608-1609.
- [18] GÓMEZ S, JENSEN P, ARENAS A. Analysis of community structure in networks of correlated data[J]. *Physical Review E*, 2009, 80(1): 016114.
- [19] MCDAID A F, GREENE D, HURLEY N. Normalized mutual information to evaluate overlapping community finding algorithms[J]. *Computer Science*, 2011. DOI: 10.48550/arXiv.1110.2515.

Two-stage Community Discovery Algorithm for Directed Dynamic Network Based on Game Theory

DONG Jiyuan, LIU Jiuqiang

(Department of Big Data Statistics, Guizhou University of Finance and Economic, Guiyang 550000, China)

Abstract: A new two-stage community detection algorithm for time series directed networks is presented. In the first stage, the importance of nodes in the network is determined by four matrices: node distance, source node influence, target node influence and node decomposition degree. The second stage determines the core node of the community division according to the importance of the nodes, then makes the core node as the source for cascade dissemination, other nodes determine the degree of follow with each leading node through the game, and finally the community led by the node with the highest degree of follow is selected. An empirical study on the algorithm is carried out in the International trade network show that the algorithm can be applied to the real world time series weighted network.

Keywords: dynamic network; community detection; node influence; independent cascade