

# 基于亲和传播的动态社会网络影响力扩散模型

陈云芳<sup>1</sup>, 夏涛<sup>1,2</sup>, 张伟<sup>1</sup>, 李晋<sup>3</sup>

(1. 南京邮电大学计算机学院, 江苏南京 210003; 2. 中国电信济宁分公司, 山东济宁 272000;  
3. 北京信息科技大学公共管理与传媒学院, 北京 100192)

**摘要:** 影响力最大化模型研究是近来社会网络的一个热点问题, 然而传统的独立级联模型以静态网络为基础, 且激活概率一般设定为固定值。提出一种加入衰减因数的动态社会网络影响力扩散模型—DDIC 模型, 其采用亲和传播来计算节点之间的激活概率, 依据时间片对社会网络进行动态切分, 使激活概率在不同时间片中实现了有效关联。实验结果表明 DDIC 模型中种子节点有更多机会激活它的邻居节点, 且采用亲和传播计算出的影响力值能更准确地体现 DDIC 模型的传播过程。

**关键词:** 动态社会网络; 影响力扩散; 亲和传播

中图分类号: TP393

文献标识码: A

## Influence diffusion model based on affinity of dynamic social network

CHEN Yun-fang<sup>1</sup>, XIA Tao<sup>1,2</sup>, ZHANG Wei<sup>1</sup>, LI Jin<sup>3</sup>

(1. School of Computer Science and Technology, Nanjing University of Posts and Telecommunications, Nanjing 210003, China;

2. Jining Branch of China Telecom., Jining 272000, China;

3. School of Public Administration and Communication, Beijing University of Information Science and Technology, Beijing 100192, China)

**Abstract:** Recently, influence maximization model is a hot issue in the field of social network influence, while the traditional independent cascade model is generally based on static network with a fixed value of activation probability. DDIC model, which was a dynamic network influence diffusion model with attenuation factor was proposed. It calculated the activation probability between nodes via affinity propagation, and according with dynamic segmentation of social network time slice, calculation of influence on proliferation of next time slice with the current time slice of activation probability performance decay. The experimental results show that the nodes in the DDIC model have more chances to active the neighbor and the average probability of activating of the DDIC model is higher. Further experiments show that influence value via computing with affinity propagation can reflect the process of the spread model more accurately.

**Key words:** dynamic social network, influence diffusion, affinity propagation

## 1 引言

虚拟社会所形成的人际关系网络以及各种各样的社会网络越来越多地出现在人们面前, 通过这些社会网络所表现出来的社会以及人际关系互动是许多领域的研究热点。在社会影响力传播中, 社会网络作为传播的媒介, 在个体之间相互影响、个

体之间传播观点与信息等方面发挥着巨大的作用。一条信息可以在人群中迅速地蔓延, 也有可能在很短时间内就消失。了解信息被人们所接受的程度是很有必要的, 这就需要了解信息是如何在社会网络中动态传播的, 即人们在何种程度上能够受到好友的影响而去做某件事情, “口碑效应”在什么程度下会发生。

收稿日期: 2015-09-08; 修回日期: 2016-08-29

基金项目: 国家自然科学基金资助项目(No.61272422); 北京市教育委员会人文社会科学研究计划面上基金资助项目(No.SM201411232005)

**Foundation Items:** The National Natural Science Foundation of China (No.61272422), Humanistic and Social Science Research Plan Project of Beijing Municipal Education Commission (No. SM201411232005)

影响力最大化模型研究是近来社会影响力领域的一个热点问题。“病毒式营销”开始只是针对为数不多的几个相对于其他个体具有“影响力”的个体。将一种商品首先推荐给这样的群体，然后在人群中进行扩散，大多数个体会把此商品推荐给朋友，通过口口相传使这种商品得到推广。这种首先找到一定个数的具有“影响力”的节点，然后通过这些具有“影响力”的节点去影响别的节点的问题被称为影响力最大化问题。

关于影响力最大化问题的研究大多都是在静态网络上展开。然而，网络本身是动态的，其中的个体和它们之间的交互会随时间的推移而变化。相比于动态网络，静态网络损失了节点之间的交互信息，不能很好地适应网络的变化情况。因此，研究在动态网络中进行影响力最大化模型的扩散很有必要。

## 2 相关工作

2002年，Richardson等<sup>[1]</sup>将影响力最大化问题引入到社会网络领域后引起了众多学者的关注。Kempe等<sup>[2]</sup>在2003年第一次比较系统地研究了影响力最大化模型，其总结了影响力最大化模型：独立级联（IC, independent cascade）模型和线性阈值（LT, linear thresholds）模型，并且证明了独立级联模型、线性阈值模型是NP难题，同时证明了2个模型的扩散结果函数是一个子模函数，满足收益递减原则。

自从影响力模型提出以后，许多文献都是围绕着怎么找到影响力最大化问题中的种子节点来研究的。这部分算法大体上可以分为2类：贪心算法和探索式算法。贪心算法由Kempe等提出，许多文献对贪心算法进行了改进：Leskovec等<sup>[3]</sup>提出的CELF算法运用了影响力最大化问题的子模特性，很大程度上降低了评价节点影响力；Chen等<sup>[4]</sup>提出了NewGreedy算法和MixGreedy算法。贪心算法的高时间复杂度使其在大型网络的应用受到了限制，另一种可能的方法就是使用探索式算法。在社会网络分析中，度和一些其他的基于中心性的探索式算法经常被用来评价节点的影响力。在影响力最大化问题中节点度经常被用来选择种子节点，文献[2]的实验选择具有最大度数的节点为种子节点，能够比其他探索式算法得到更好的效果。以往文献都没有考虑网络中的社区结构特性。Galstyan等<sup>[5]</sup>第一

次提出了一种基于社区结构的影响力最大化问题的解决方案，但是该方法只是局限于2个连接稀疏的社区网络，而实际中的网络一般包括很多社区网络。Cao等<sup>[6]</sup>把影响力最大化问题转化为最佳资源分配问题，将整个网络根据社区发现算法划分为若干个社区；然后将数个节点按照最佳资源分配问题的解决方法分配给每个社区节点；每个社区根据分配的节点利用影响力最大化模型来找到种子节点。

关于节点之间边的影响力分析也有很多文献进行了相关研究，Saito等<sup>[7]</sup>在研究信息传播的独立级联模型时讨论了这类问题，将影响力模型转化成了一种最大似然问题进行求解。因为该模型每次迭代过程都要对每条链接上的影响力系数进行计算，时间复杂度较高，所以并不适合大规模社交网络中的影响力度量。Barbieri等<sup>[8]</sup>在Saito等的基础上讨论了多个主题下的影响力最大化模型，其采用了最大似然估计。以上这些方法都是基于网络中的节点以往的行为进行的估计。Tang等<sup>[9]</sup>提出了基于主题的社会影响力分析的一种方法——TAP（topical affinity propagation）算法。该算法是一种亲和传播<sup>[11]</sup>聚类算法，首先使用隐藏狄利克雷模型（LDA）将合著者网络进行主题分布，然后使用亲和传播方法分析节点间不同主题之间的影响力。相比于以往的算法，TAP算法求解主题间的影响力比较简单可行，而且可以定量地分析节点间的影响力。

无论是基于节点还是基于边的影响力分析，上述影响力最大化问题的研究都是在静态网络中进行扩散的，然而网络本身是动态的，其中的个体和它们之间的交互会随时间的推移而变化。Habiba等<sup>[10]</sup>提出了一种在动态网络中进行影响力最大化问题扩散的模型，该模型将在每个时间片中进行一次扩散，上一个时间片的激活节点作为下一个时间片的初始激活节点进行扩散，直到最后一个时间片或者没有新的被激活节点时，扩散过程结束。然而，上述模型中的每个时间片是相互独立的，没有考虑到时间片之间影响力的联系，并且，模型中将影响力值设置为同一个值，很显然是违背实际情况的。

综上所述，社会网络是动态的，影响力的传播在时间片中的激活概率也不是一成不变的。为此，本文提出一种加入衰减因数的动态网络独立级联（DDIC, decay dynamic network independent cascade）模型。本文工作主要体现在2个方面：1) 影响力在某个时间片中建立以后，在后续的时间片中

如果这2个节点依然存在连接，那么这2个节点之间的影响力不应该只考虑这个时间片中的影响力，需要考虑以前影响力的累加，针对这个问题 DDIC 模型引入衰减因数；2) 在社会网络中由于存在着个体差异，个体之间的影响力不会是相同的，针对这个问题，DDIC 模型中个体之间的影响力采用亲和传播的方法来计算节点之间的影响力值。

### 3 动态网络中影响力扩散问题

#### 3.1 动态网络

静态网络独立级联模型都是基于一种合成网络来进行扩散的，这种合成网络展现了在一定的时间内所观察到的全部个体和个体之间的交互。这种网络只能展现一段时间内所有个体之间交互的叠加，并不能反映出节点和边出现的时序信息。

动态网络是由有限个静态网络按照一定的时间序列构成的一组网络。其中，每一个静态网络是网络中所有个体以及个体之间相互交互的在某个时间的一个快照。动态网络描述了在一段时间内网络的演化过程。如图1所示，上半部分前3个图表示了从时间序列  $T_1$  到时间序列  $T_3$  节点 A 至节点 E 之间的相互联系，最后一个图是时间片  $T_1$ 、 $T_2$ 、 $T_3$  合成的静态网络，下半部分的图也是一样的。由图1可以看出，节点 A 至节点 E 在 2 个部分时间片  $T_1$ 、 $T_2$ 、 $T_3$  中边是不同的，而合成的静态网络是一样的。由此，可以清晰地看出合成静态网络会损失网络演化中的时序信息。

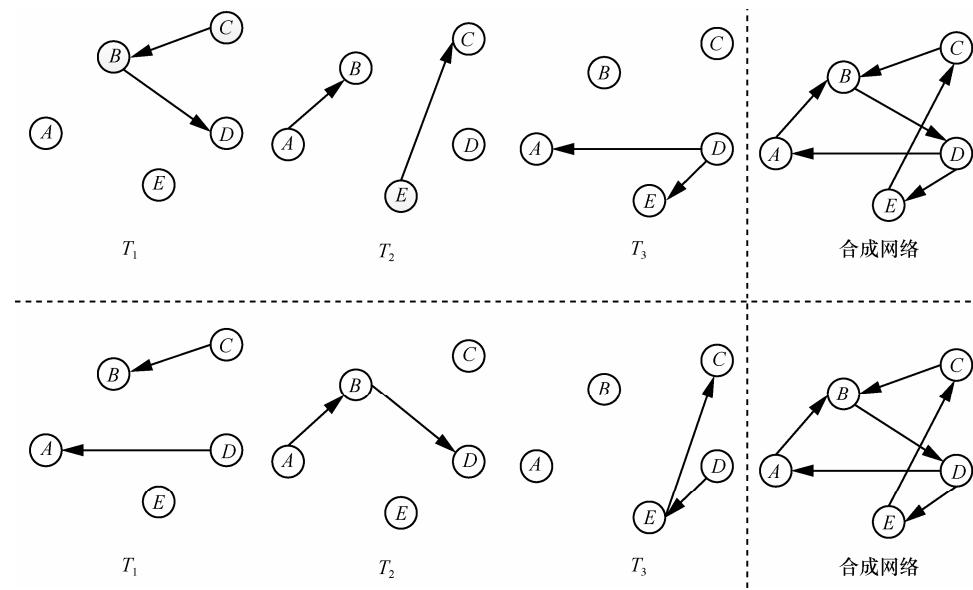


图1 基于时间片的网络与静态网络

**定义1**  $G_t(V_t, E_t)$  表示在时刻  $t$  时的静态网络， $I = \{V_1, \dots, V_n\}$  表示网络中的节点集合，其中， $V_t \in V$  表示在时刻  $t$  所观察到的所有个体， $E_t \in E$  表示在时刻  $t$  所观察到的节点间的所有有向边，这些有向边代表了节点间的互相交互。

**定义2**  $G(V, E) = \{G_1, \dots, G_t\}$  表示由  $t$  个静态网络组成的一个时间片网络，满足  $V = U_t V_t$ ， $E = U_t E_t \cup U_{V,t} (v_t, v_{t+1})$ ，其中， $(v_t, v_{t+1})$  表示从时间序列  $t$  到时间序列  $t+1$  节点的自向边。

#### 3.2 加入衰减因数的动态网络独立级联模型

DDIC 模型中的节点状态采用与静态网络中的节点状态一致的方式，也具有 2 种状态：激活态和未激活态，每个节点的状态只能从未激活态转为激活态而不能反转。

在 DDIC 模型中，首先输入的是种子节点集合  $A_0 \in I$ 。在加入衰减因数动态网络中每个已经激活的节点  $v_t$  在时间序列  $t$  的网络中去尝试激活它的未被激活的邻居节点  $w_t$ ， $w_t$  是否被激活取决于  $v_t$  和  $w_t$  之间的影响力概率。

在 DDIC 模型中激活概率定义如下：如果在时间片  $t-1$  中节点  $v$  和节点  $w$  有链接，而在时间片  $t$  中，节点  $v$  和节点  $w$  也有链接时，那么在时间片  $t$  中节点  $v$  和节点  $w$  之间的激活概率为

$$p_{v_t w_t} = p'_{v_t w_t} + \frac{p_{v_{t-1} w_{t-1}}}{\alpha} \quad (1)$$

其中， $p'_{v_t w_t}$  表示在时间片  $t$  中节点  $v$  对节点  $w$  的影

响概率,  $p_{v_{t-1}w_{t-1}}$  表示在时间片  $t-1$  中节点  $v$  对节点  $w$  的影响概率。在时间片中加入衰减因数  $\alpha$  表示为: 节点  $v$  在时间片  $t$  中尝试激活节点  $w$  时, 如果在时间片  $t-1$  中节点  $v$  已经尝试过激活节点  $w$ , 那么节点  $w$  在决定是否被激活时会考虑节点  $v$  上一次的尝试激活。

如果当  $w_t$  有多个邻居节点处于激活状态时, 这些激活节点对  $w_t$  的影响是随机的、独立的。如果在时刻  $t$  的网络中  $v_t$  成功地把它的邻居节点  $w_t$  激活, 那么在下一个时间片中不管  $v_{t+1}$  和  $w_{t+1}$  之间是否存在边  $(v_{t+1}, w_{t+1}) \in E_{t+1}$ ,  $w_{t+1}$  都是具有影响力的节点。如果在时间序列  $t$  的静态网络中  $v_t$  没有将  $w_t$  成功激活, 那么在以后的时间序列中, 如果  $v_T$  和  $w_T$  中存在边  $(v_T, w_T) \in E_T$ ,  $v_T$  将尝试激活  $w_T$ 。如果整个扩散过程没有新的被激活节点或者扩散已经达到最后一个时间片, 那么扩散结束。

图 2 简单描述了 DDIC 模型的过程, 开始选择节点  $A$  为种子节点, 在  $T=1$  的网络中节点  $A$  激活了它的邻居节点  $B$ 。在  $T=2$  的网络中节点  $A$  又激活了它的邻居节点  $D$ , 此时节点  $A$  和节点  $B$  中已经没有了边, 而节点  $B$  一样具有影响力并且激活了它的 2 个邻居节点。在  $T=3$  的网络中种子节点  $A$  和它的邻居节点  $C$  又重新连接, 并且节点  $A$  成功激活了节点  $C$ 。

DDIC 模型可以分为 2 个步骤来理解。1) 对于每个时刻对应的静态网络采取“抛硬币”来确定网络中对应的节点间的通路边。节点  $v$  和节点  $w$  在时刻  $t$  的边概率值  $p_{v_t w_t}$  表征了这个边在多大程度上能够被选为通路边, 图 3 简单描述了图 2 的 3 个时间序列的时间片网络通过“抛硬币”的方式产生的通路边。2) 选择合适的节点作为模型开始的种子节点也就是那些能够使更多的节点被激活的节点。首先

在  $T=1$  的静态网络中种子节点进行扩散, 此时的扩散就是根据步骤 1) 找到的通路边进行的扩散, 如果种子节点的邻居节点与种子节点之间有通路边, 该邻居节点就会被激活。在  $T=1$  的静态网络中扩散后已经处于激活态的节点集合作为  $T=2$  的静态网络的种子节点, 按照同样的方法在  $T=2$  的静态网络中进行扩散, 重复这一过程直到模型结束, 最终得到的节点集合为最后一个时间序列中激活的节点总数。

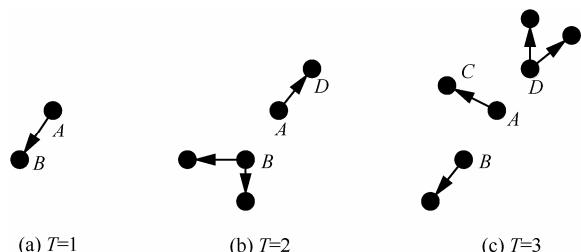


图 3 基于时间片网络的通路边

Kempe 等证明了静态网络中的独立级联模型是一个 NP 难题。静态网络中的独立级联模型相当于在同一个时间序列网络中展开的, 而加入衰减因数的动态网络独立级联模型在每个时间序列中的扩散过程和在静态网络中的扩散过程是一样的。所以, 加入衰减因数的动态网络独立级联模型也是一个 NP 难题。Kempe 等证明了对于应用静态网络中独立级联模型的任意实例, 影响力结果函数具有子模特性。对于基于时间片网络的独立级联模型来说, 影响力结果函数也具有子模特性。

### 3.3 基于亲和传播的激活概率

独立级联模型在进行影响力的扩散时节点间的激活概率为了简化模型统一设置成 0.01 或者的一个定值, 这显然是不符合现实情况的, 在现实中每个人对他的朋友的影响程度是不同的。

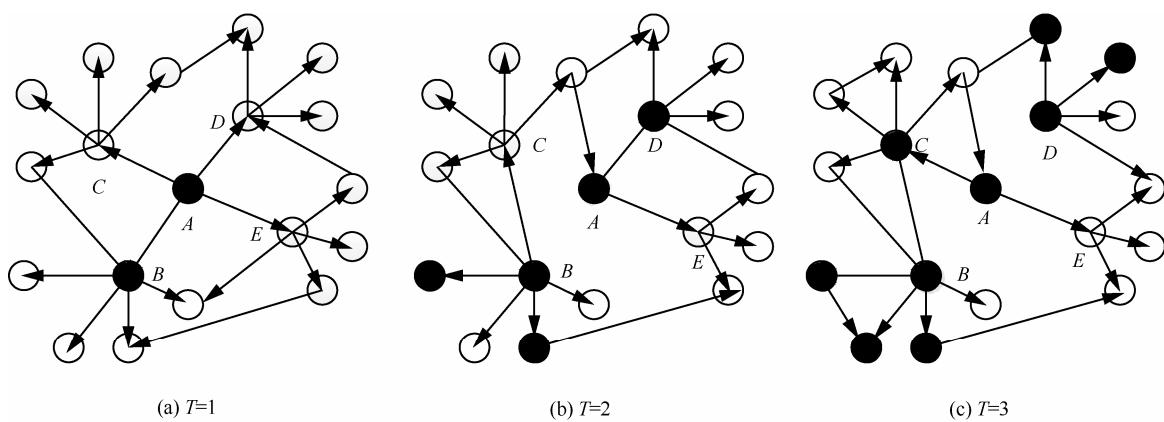


图 2 基于时间片网络的独立级联模型

本节对 TAP 算法进行了改进, 使节点相似性函数只涉及单个主题, 具体如式(2)所示。

$$g(v_i, v_j) = \begin{cases} \frac{w_{ij}}{\sum_{j \in NB(i)} (w_{ij} + w_{ji})}, & j \neq i \\ \frac{\sum_{j \in NB(i)} w_{ji}}{\sum_{j \in NB(i)} (w_{ij} + w_{ji})}, & j = i \end{cases} \quad (2)$$

其中,  $NB(i)$  表示节点  $i$  的邻居节点集合,  $w_{ij}$  表示节点  $i$  到节点  $j$  的边的权重值, 这个权重值的定义可以有多种形式, 如在通话记录网络中可以定义为节点  $i$  和节点  $j$  之间的通话时长。式(2)可以解释为: 如果节点  $v_i$  和节点  $v_j$  之间有较高的相似性或者权重, 那么节点  $v_i$  和节点  $v_j$  之间有比较大的影响力; 如果节点  $v_i$  的邻居节点都认为节点  $v_i$  对自己有较高的影响力, 那么节点  $v_i$  对自己具有较大影响力是有信心的。

对节点相似性函数  $g(v_i, v_j)$  进行对数归一化得到相似性矩阵。

$$b_{ij} = \log \frac{g(v_i, v_j)}{\sum_{k \in NB(i) \cup \{i\}} g(v_i, v_k)} \quad (3)$$

其中,  $b_{ij}$  表示节点  $j$  和节点  $i$  之间的特征函数值与节点  $i$  的所有邻居节点的特征函数值的比值, 这个比值越大说明在节点  $i$  的邻居节点中节点  $j$  相对于其他节点对节点  $i$  越有影响力。

TAP 算法利用因子图理论推导出了基于主题的亲和传播影响力算法的更新规则, 在此基础上对更新规则做了调整使更新规则只在一个主题内展开, 即不考虑主题的影响。

$$r_{ij} = b_{ij} - \max_{k \in NB(j)} \{b_{ik} + a_{ik}\} \quad (4)$$

$$a_{jj} = \max_{k \in NB(j)} \min \{r_{kj}, 0\} \quad (5)$$

$$a_{ij} = \min(\max \{r_{ij}, 0\}, -\min \{r_{ji}, 0\} - \max_{k \in NB(j) \setminus \{i\}} \min \{r_{kj}, 0\}), \quad i \in NB(j) \quad (6)$$

更新规则  $r$  表示了节点  $i$  对节点  $j$  对其有影响的积累证据。更新规则  $a$  表示节点  $j$  认为自己可以影响节点  $i$  的积累证据。

更新规则  $a$  和  $r$  说明了节点  $j$  对节点  $i$  的影响力, 而对于一个社会网络图希望得到的影响力概率值是一个介于[0,1]之间的值  $p_{ij}$ , 并且表示节点  $i$  对于节点  $j$  的影响程度, 所以定义为

$$p_{ij} = \frac{1}{1 + e^{-(r_{ji}, a_{ji})}} \quad (7)$$

### 算法 1 基于亲和传播的激活概率算法

输入 社会网络图  $G(V, E)$

输出 节点间的影响力概率值

1) 计算节点间特征函数值( $v_i, v_j$ ) //计算节点间的相似性值

- 2) 计算  $b_{ij}$  //根据式(3)计算  $b_{ij}$  的值
- 3) 初始化所有  $r_{ij} \leftarrow 0$  //初始化所有  $r_{ij}$  的值为 0
- 4) Repeat //进行迭代计算
  - 5) for  $e_{ij}$  do
  - 6)     更新  $r_{ij}$ ; //根据式(4)计算  $r_{ij}$  的值
  - 7) end
  - 8) for  $v_j$  do
  - 9)     更新  $a_{jj}$ ; //根据式(5)计算  $a_{jj}$  的值
  - 10) end
  - 11) for  $e_{ij}$  do
  - 12)     更新  $a_{ij}$ ; //根据式(6)计算  $a_{ij}$  的值
  - 13) end
- 14) until convergence //直到收敛
- 15) for  $e_{ij}$  do
- 16)     计算  $p_{ij}$ ; //根据式(7)计算  $p_{ij}$  的值
- 17) end //  $p_{ij}$  为计算出的节点间影响力

## 4 实验分析

实验采用“9·11 事件”的数据集, 该数据集一共包含 400 个节点以及这 400 个节点之间相互联系的 10 个时间片。在每个时间片中, 如果 2 个人之间有电话联系, 那么 2 个人之间就会有一条边且通话时长为边的权重值。每个时间片中所含有的边数如表 1 所示。

表 1 每个时间片中所含有的边数

时间序列	边数
$T_1$	631
$T_2$	617
$T_3$	627
$T_4$	625
$T_5$	627
$T_6$	629
$T_7$	603
$T_8$	622
$T_9$	632
$T_{10}$	662

本文一共进行了 3 组对比实验, 分别是: 静态网络和动态网络中的独立级联模型与 DDIC 模型贪心算法对比; 动态网络与加入衰减因数的动态网络独立级联模型 3 种算法对比; 激活概率设置为固定值 0.04 与亲和传播概率对比。在实验中设定模拟传播次数  $R$  为 100 次, 为了简化计算将衰减因数  $\alpha$  的值设置为 0.5。

#### 4.1 静态网络与 DDIC 模型使用贪心算法的对比

该实验选择 3 种网络:  $T_1$  时间片网络、10 个时间片合成的静态网络、加入衰减因数的动态网络。图 4(a)表示了在 3 种网络中使用贪心算法最终的激活节点数目进行对比。可以看出, 在加入衰减因数的动态网络中独立级联模型中激活的节点数目比在单一的时间片中以及合成静态网络中激活的节点数目要多很多, 这主要是因为在静态网络中每个节点只有一次机会去激活它的邻居节点, 而在加入衰减因数的动态网络中一个节点, 可以有多次机会去激活它的邻居节点, 所以加入衰减因数的动态网络激活的节点数目要比静态网络中激活的数目多。

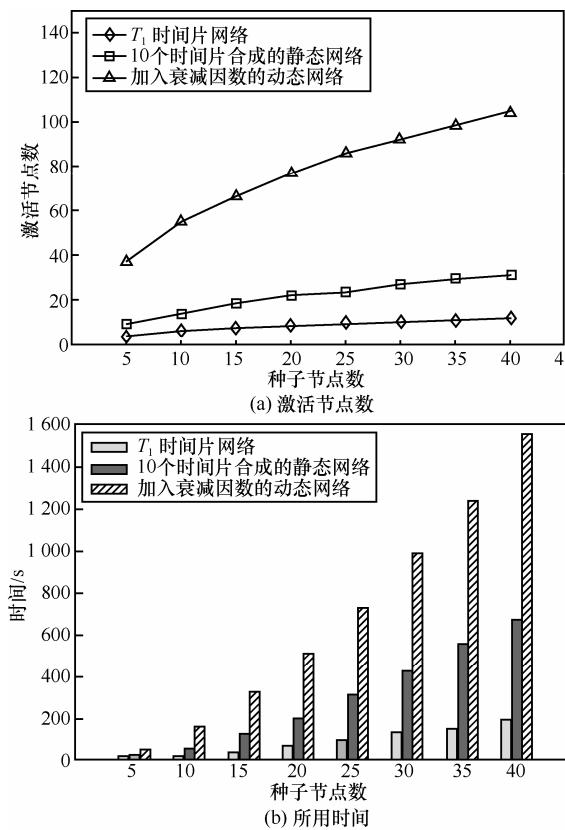


图 4 3 种网络中使用贪心算法进行扩散对比

图 4(b)表示了在 3 种网络中使用贪心算法最终的所用时间对比。可以看出, 在加入衰减因数的动

态网络中, 使用贪心算法进行确定种子节点集比在静态网络中使用贪心算法确定种子节点集所用的时间要长。这是因为在静态网络中一个节点只有一次机会去影响它的邻居节点, 所以整个扩散过程一般在扩散 3 轮左右就可完成, 而在加入衰减因数的动态网络中一个节点有多种机会去激活它的邻居节点, 所以激活的节点数目多, 整个扩散过程比较长, 一般要扩散 7 轮左右才可以结束扩散过程, 而贪心算法要进行 100 次的模拟传播。所以这样加入衰减因数的动态网络在使用贪心算法进行确定种子节点的传播中要比静态网络所使用的时间要长。

由图 4 还可以看出, 在合成静态网络中的激活节点数目和所用时间都比在一个时间片中要大, 这是因为合成的网络中的边比单一的时间片网络要多, 所以激活节点的数目要多。

#### 4.2 贪心算法、NewGreedy 算法、HT 算法在 DDIC 模型中扩散的情况

该实验选择文献[4]中提出的 NewGreedy 和文献[8]提出的 HT 算法与贪心算法进行对比。由于 DDIC 模型和静态网络中的独立级联模型一样都是 NP 难题, 同时都具有子模特性, 贪心算法以及改进后的贪心算法同样能够在 DDIC 模型中使用。

如图 5(a)所示, 在加入衰减因数的动态网络中使用贪心算法、NewGreedy 算法、HT 算法以及随机选择算法(在 400 个节点中随机选择  $n$  个节点作为种子节点集)对独立级联模型进行种子节点集的确定的结果对比。由图 5(a)可以看出, 在准确率上, 贪心算法和 NewGreedy 相差不大, 而 HT 算法表现比前面 2 种算法要稍差一些, 这是因为 HT 算法在进行种子节点确定的时候是基于去边的方法, 这种方法会损失掉很多边所以造成结果不准确。而随机选择算法的结果会出现震荡, 因为通过随机数的方法找的点是不可靠的。图 5(b)表示了 3 种算法及随机选择算法所用时间对比, 可以看出贪心算法所用的时间是最长的, 比 NewGreedy 和 HT 算法要长很多, 其次是 NewGreedy 算法, 最好的是 HT 算法。因为随机选择算法比前 3 种算法所用时间少很多, 故在图 5(b)中不能表现出来。

在静态网络中也同样做了这 3 个算法的对比, 得到的结果和在加入衰减因数的动态网络上的结果是一致的。可以得出结论: 贪心算法在静态网络和基于时间片网络中确定种子节点集是准确的, 但是

由于时间复杂度太大, 贪心算法不适合节点和链接较多的网络; NewGreedy 在 2 种网络中确定种子节点集时准确程度和贪心相差不大而且具有较小的时间复杂度, 适合在大型网络中使用; HT 算法虽然有较好的时间复杂度, 但结果的准确性稍差一点。

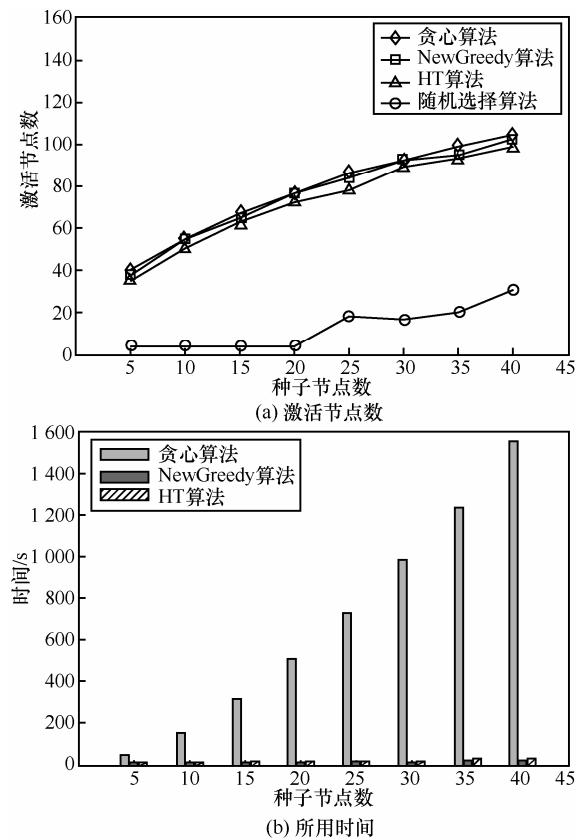


图 5 在加入衰减因数动态网络中 3 种算法及随机选择算法的对比

### 4.3 亲和传播的比较分析

在 DDIC 模型使用固定激活概率和使用亲和传播的影响力之间的结果对比, 该实验中分别对 2 种

节点间激活概率值的设定方法进行实验对比。其中, 方法 1 是将节点间的激活概率统一设置为平均概率值 0.04, 方法 2 是使用亲和传播求出的概率值作为节点间激活概率值, 如表 2 所示, 在这部分实验中使用贪心算法来确定种子节点集。

表 2 亲和传播概率的平均值

时间序列	亲和传播平均概率
$T_1$	0.039
$T_2$	0.040
$T_3$	0.039
$T_4$	0.039
$T_5$	0.040
$T_6$	0.038
$T_7$	0.040
$T_8$	0.038
$T_9$	0.038
$T_{10}$	0.039

表 3 为在 DDIC 模型中用 2 种方法所确定的排名前 20 的影响力节点, 通过对比可以发现 2 种方法所找到的节点的排名是不一样的。

图 6 所示为 DDIC 模型中 2 种设定激活概率进行扩散的对比, 可以看出在激活概率设定为 0.04 的扩散结果中, 激活节点数目要比使用亲和传播影响力概率值所激活的节点数目多, 这可能是因为使用亲和传播所求出的一部分影响力是大于平均影响力 0.04, 而大部分影响力是低于 0.04, 这样造成了第一种方法要比第二种方法所激活的节点数目多。而且, 使用亲和传播求出的概率值是根据边与边的权重值计算出来的相邻节点之间的影响力概率值, 比统一设置成 0.04

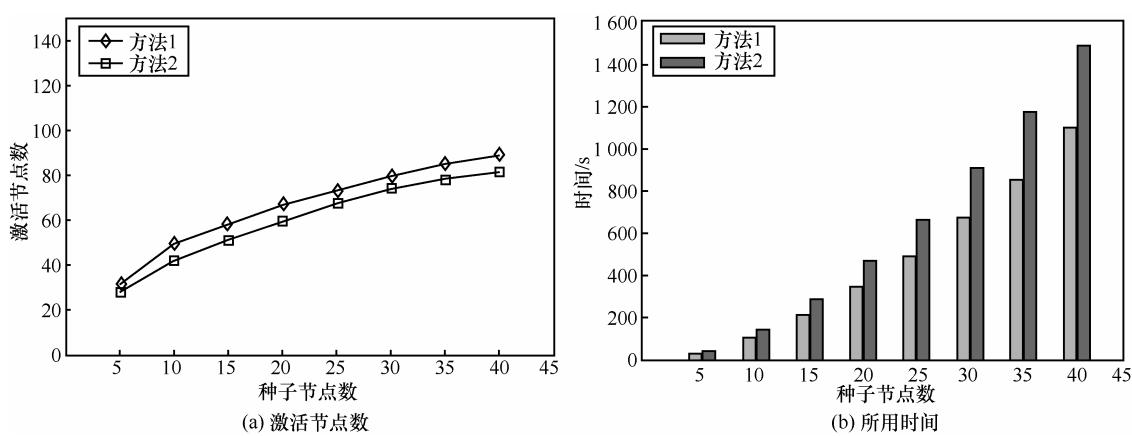


图 6 在 DDIC 模型中 2 种设定激活概率方法进行扩散的对比

表3 在DDIC模型中用2种方法所确定的排名前20的影响力节点

方法	排名前20的影响力节点																			
	平均概率为0.04	1	5	0	3	2	13	23	41	20	61	14	7	52	18	19	4	24	49	82
亲和传播概率	1	5	0	2	13	3	12	41	19	92	61	21	52	18	158	15	120	38	49	103

能更加准确地表现出DDIC模型的传播过程。

## 5 结束语

本文以独立级联模型为基础,研究了独立级联模型在动态网络中的扩散问题,并且提出了加入衰减因数的独立级联模型。与传统的动态网络中的独立级联模型不同,本文提出的加入衰减因数的独立级联模型DDIC将动态网络中各时间片之间的影响力关联起来,并采用亲和传播来计算相邻节点之间的影响力概率值,使模型更能贴近真实的社会网络影响力传播。本文通过对比实验可以得到以下结论:加入衰减因数的独立级联模型中由于每个节点有多次机会激活它的邻居节点,所以比静态网络中激活的节点数目要多;DDIC模型由于引入衰减因数使平均激活概率比不引入衰减因数的动态网络要高,所以激活的节点数目也多;在静态网络中适用的贪心算法在DDIC模型中也同样适用;在DDIC模型中采用亲和传播计算节点之间的影响力与将影响力值设置为固定值所得到的种子节点是不同的,亲和传播能更好地体现出DDIC模型的传播过程。

## 参考文献:

- [1] RICHARDSON M, DOMINGOS P. Mining knowledge-sharing sites for viral marketing[C]//KDD '02 Proceedings of the Eighth ACM SIGKDD International Conference. 2002: 61-70.
- [2] KEMPE D, KLEINBERG J M, TARDOS A. Maximizing the spread of influence through a social network[C]//The 9th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2003: 137-146.
- [3] LESKOVEC J, KRAUSE A, GUESTRIN C. Cost-effective outbreak detection in networks[C]//The 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2007: 420-429.
- [4] CHEN W, WANG Y, YANG S. Efficient influence maximization in social networks[C]//Proceedings of the 15th ACM SIGKDD International Conference. 2009: 199-208.
- [5] GALSTYAN A, MUSOYAN V, COHEN P R. Maximizing influence propagation in networks with community structure[J]. Physical Review E Statistical Nonlinear & Soft Matter Physics, 2009, 79(2): 711-715.
- [6] CAO T Y, WU X D, WANG S, et al. OASNET: an optimal allocation approach to influence maximization in modular social networks[J]. ACM Symposium on Applied Computing, 2010: 1088-1094.
- [7] SAITO K, NAKANO R, KIMURA M. Prediction of information diffusion probabilities for independent cascade model[J]. Knowledge-

Based Intelligent Information and Engineering Systems Lecture Notes in Computer Science, 2008: 67-75.

- [8] BARBIERI N, BONCHI F, MANCO G. Topic-aware social influence propagation models[J]. Knowledge and Information Systems, 2013: 2012,37(3): 81-90.
- [9] TANG J, SUN J M, WANG C. Social influence analysis in large-scale networks[C]//The 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2009: 807-816.
- [10] FREY B J, DUECK D. Clustering by passing messages between data points[J]. Science, 2007, 315(5814): 972-976.
- [11] HABIBA T W B, BERGER-WOLF T Y. Maximizing the extent of spread in a dynamic network[J]. Technical Report 20. DIMACS, 2007.

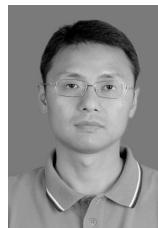
## 作者简介:



陈云芳(1976-),男,江苏镇江人,博士,南京邮电大学副教授,主要研究方向为网络安全、社会网络、大数据分析等。



夏涛(1989-),男,山东济宁人,硕士,中国电信济宁分公司工程师,主要研究方向为社会计算、社会影响力。



张伟(1973-),男,江苏泰兴人,博士,南京邮电大学教授,主要研究方向为社会网络分析、隐私保护、恶意代码分析等。



李晋(1977-),女,山西长治人,北京信息科技大学讲师,主要研究方向为网络与新媒体传播。