

基于广义意见动态模型的社交信任 网络意见最大化问题

曾佳媛¹, 张 广²

(1. 上海理工大学 理学院, 上海 200093; 2. 上海理工大学 管理学院, 上海 200093)

摘要: 提出了一种广义意见动态模型(GODM), 此模型可以通过动态计算每个人的表达意见来解决社交信任网络中的意见最大化问题。在模型中提出了一个新的、合理的、可解释的自信指数 α_i , α_i 由个人的社会地位与其周围人的评价共同决定。并且利用对角占优理论, 得到模型达到纳什均衡状态时的最优解析解。设计了一种具有 l_1 形式的交替方向乘子法来最大化现有的总体意见。进行了一系列实验, 实验结果表明, 此方法在4个数据集上都有较好的结果。在4个数据集上, 解决内部意见问题的平均效益分别提升了66.4%, 88.7%, 47.8%和34.1%。实验结果充分验证了所提模型的优越性。

关键词: 意见最大化; 社交信任网络; 自信指数; 有限预算

中图分类号: O 157 **文献标志码:** A

Generalized opinion dynamics model for social trust networks in opinion maximization

ZENG Jiayuan¹, ZHANG Guang²

(1. College of Science, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Business School, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: A generalized opinion dynamics model (GODM) was proposed. This model dynamically computed each person's expressed opinion to solve the opinion maximization problem for social trust networks. In the model, a new, reasonable and interpretable confidence index α_i was proposed. This index was determined by both person's social status and the evaluation of his/her predecessors. By using the theory of diagonally dominant, the optimal analytic solution of the Nash equilibrium with maximum overall opinion was obtained. In addition, an efficient traditional ADMM algorithm with l_1 -regulations to maximize the overall opinion was designed. A series of experiments were conducted, and the experimental results show that the proposed method is superior to the state-of-the-art in four datasets. The average benefit has been improved by 66.4%, 88.7%, 47.8% and 34.1% in solving the internal opinion problem. The experimental results fully verify the superiority of the proposed model.

收稿日期: 2021-12-28

基金项目: 国家自然科学基金资助项目(71901145); 上海市哲学社会科学规划项目(2019EGL010)

第一作者: 曾佳媛(1997-), 女, 硕士研究生。研究方向: 图论与组合优化。E-mail: 854789302@qq.com

通信作者: 张 广(1987-), 男, 讲师。研究方向: 博弈论及其应用。E-mail: g.zhang@usst.edu.cn

Keywords: *opinion maximization; social trust networks; confidence index; limited budget*

近年来, 大规模社交媒体网络的日益普及极大地推动了社交网络分析的发展。人们如何通过他人的社交互动形成自己的观点一直是社会科学领域的研究课题。在社交网络上, 用户可以对产品或实时新闻表达自己的意见。通过量化这些意见, 可以确定一个网络中的用户对产品或新闻的整体看法。人们可以定量研究用户意见间的相互作用, 并通过有针对性的干预来提高总体意见值。

1 相关研究

社交信任网络是某些群体(人、企业和组织)之间关系相对稳定的网络。它可以表示为有向符号加权图, 如图 1 所示。社交信任网络的研究在社区检测^[1]、情感分析^[2-4]、意见领袖检测^[5]、产品推荐^[6]、识别假新闻^[7]、监控系统^[8]及意见最大化^[9-12]等方面有广泛应用。近年来, 有许多基于社交互动的意见动态模型被提出^[9-12], Chen 等^[9]提出了一种算法来寻找对网络产生影响最大的 K 个节点。Liu 等^[11]考虑了意见最大化问题, 其目标是在多轮活动中找到种子用户集, 用来最大化目标产品的总体意见传播。除了考虑直接改变人们内部意见的干预, Abebe 等^[12]还考虑了改变人们对说服敏感性的干预。其目的是利用修改用户的敏感性来最大限度地提高纳什均衡下的总体意见。Xu 等^[10]提出了一种新的连续值意见动态模型, 该模型更符合真实场景, 取得了良好的效果。但是, 文献[10]中仍有一些可以改进的地方, 如它将每个用户的表达意见考虑为个人内部意见和周围人意见的加权平均值。然而, 在现实生活中, 每个人的性格都是不同的, 也就是说, 不同的人受别人影响的程度也不同。因此, 本文在文献[10]的基础上进行了一些改进, 建立了一个广义的社交信任网络意见动态模型来具体计算每个人的表达意见, 并解决了意见最大化问题。提出了一种新的自信指数 α_i , 这与文献[12]中随机选择的 α_i 不同, 它取决于一个人的社会地位和周围人的评价。对于不同的人类群体, α_i 的取值范围是不同的。利用对角占优理论和 Friedkin-Johnsen 模型给出了达到纳什均衡时的解析解, 实现了文献[10]中模型的推广。引入了一种成熟的优化算法——

交替方向乘法, 并利用该算法所衍生的特殊形式—— l_1 正则化形式解决了意见最大化问题。




图 1 社会信任网络及其图表示
Fig.1 A social trust network and its graph representation

2 模型构建

2.1 模型中使用的定义和引理

定义 1^[13] 对于矩阵 $A = (a_{ij})_{n \times n}$, 若其对角元素的绝对值大于非对角元素的绝对值之和, 即 $|a_{ii}| >$

$\sum_{j \neq i} |a_{ij}|, i = 1, 2, \dots, n$, 则 $A = (a_{ij})_{n \times n}$ 严格对角占优。

引理 1^[13] 若 $A = (a_{ij})_{n \times n}$ 是严格对角占优矩阵, 则 $\det A \neq 0$ 。

2.2 纳什均衡

定义 2 纳什均衡是博弈论中一种解的概念, 它是指满足下面性质的策略组合: 任何一位玩家在此策略组下单方面改变自己的策略(其他玩家策略不变)都不会提高自身的收益。

在一个博弈过程中, 无论对方的策略选择如何, 当事人一方都会选择某个确定的策略, 则该策略被称为支配性策略。如果任意一位参与者在其他所有参与者的策略确定的情况下, 其选择的策略是最优的, 那么, 这个组合就被定义为纳什均衡。当每个博弈者的均衡策略都达到自己期望收益的最大值时, 这个策略组合被称为纳什均衡。

2.3 Friedkin-Johnsen 模型

社交信任网络可以表示为有向符号加权图 $G = (V, E)$, 其中, $V = \{1, 2, \dots, n\}$ 为节点集, E 为弧集(有向边集)。 ω_{ij} 为从 i 到 j 的有向边 (i, j) 的权重,

权重大小表明了关系的强度。 $\mathbf{A} = (a_{ij})$ 是 G 的邻接矩阵,若存在 $(i, j) \in E$,则 $a_{ij} = \omega_{ij}$,否则, $a_{ij} = 0$ 。

$\mathbf{D}$ 为对角矩阵,其中,对角线元素 $d_{ii} = \sum_{j=1}^n |a_{ij}|$, $\mathbf{L} = \mathbf{D} - \mathbf{A}$, $\mathbf{L}$ 为拉普拉斯矩阵。

Friedkin-Johnsen 模型^[14]是一个著名的连续值意见动态模型。在这个模型中,每个节点 $i \in V$ 都有一个初始的内部意见 $s_i \in [-1, 1]$ 。在每次迭代中,节点 i 的表达意见更新为

$$z_i = \frac{s_i + \sum_{j \in N^+(i)} \omega_{ij} z_j}{1 + \sum_{j \in N^+(i)} \omega_{ij}}$$

式中: $N^+(i)$ 为节点 i 的出邻居集合; z_i, z_j 分别为节点 i, j 的表达意见。

由上面的公式不难发现, $z_i \in [-1, 1]$ 。在社交游戏中,此迭代结果会逐渐收敛,最终达到纳什均衡状态。

2.4 社交信任网络的广义意见动态模型

从 Friedkin-Johnsen 模型可以看出,对于每个节点 i ,其表达的意见是其内部意见与周围节点意见的加权平均值。然而,在现实生活中,人们的性格是不同的,每个人受到他人影响的程度也是不同的。因此,建立了一个广义的社交信任网络意见动态模型。

首先写出社交游戏的共识成本函数

$$c(z_i) = \alpha_i (z_i - s_i)^2 + (1 - \alpha_i) \sum_{j \in N^+(i)} |\omega_{ij}| (z_i - \text{sgn}(i, j) z_j)^2$$

式中: $\text{sgn}(i, j)$ 表示 ω_{ij} 的符号; α_i 为节点 i 的自信指数, α_i 反映了一个人在社交网络中的自信程度。

在社交网络中, α_i 越高,表明这个人在发表意见的时候更倾向于关注自己的想法,而不会轻易被他人的意见所影响。在此模型中,自信指数与一个人的社会地位和别人对他的评价,即与其在网络中的重要性以及周围人对他的评价有关。

定理 1 设 $\mathbf{A} = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_n)$ 为对角矩阵,其中, α_i 为节点 i 在社交信任网络中的自信指数,则矩阵 $(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})$ 是可逆的。 $\mathbf{I}$ 为单位矩阵。

证明 矩阵 $(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})$ 的对角元素为

$$(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})_{ii} = \alpha_i + (1 - \alpha_i) \sum_{j \in N^+(i)} |\omega_{ij}|$$

其非对角元素之和为 $(1 - \alpha_i) \sum_{j \in N^+(i)} |\omega_{ij}|$ 。又因为 $0 < \alpha_i < 1$,由引理 1 可知, $(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})$ 为对角占优矩阵。

定理 2 令 $\mathbf{s}$ 为内部意见向量,其第 i 个元素为 s_i , $\mathbf{z}^*$ 为达到纳什均衡状态下的表达意见向量,则 $\mathbf{z}^* = (\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1} \mathbf{A} \mathbf{s}$ 。

证明 在纳什均衡状态下,计算使节点 i 的代价函数达到最小的表达意见 z_i^* ,即 $c'(z_i^*) = 0$ 。因此,

$$c'(z_i^*) = 2\alpha_i(z_i^* - s_i) + 2(1 - \alpha_i) \cdot \sum_{j \in N^+(i)} |\omega_{ij}| (z_i^* - \text{sgn}(i, j) z_j^*) = 0$$

化简可得

$$z_i^* = \frac{\alpha_i s_i + (1 - \alpha_i) \sum_{j \in N^+(i)} \omega_{ij} z_j^*}{\alpha_i + (1 - \alpha_i) \sum_{j \in N^+(i)} |\omega_{ij}|} \quad (1)$$

即

$$(\alpha_i + (1 - \alpha_i) \sum_{j \in N^+(i)} |\omega_{ij}|) z_i^* = \alpha_i s_i + (1 - \alpha_i) \sum_{j \in N^+(i)} \omega_{ij} z_j^*$$

引入意见向量 $\mathbf{s}$ 和 $\mathbf{z}^*$,可将等式写为矩阵形式, $(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})\mathbf{z}^* = \mathbf{A} \mathbf{s}$ 。由定理 1 可知, $(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})$ 可逆。因此,可以得到 $\mathbf{z}^* = (\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1} \mathbf{A} \mathbf{s}$ 。

2.4.1 PageRank 算法

PageRank 算法是 Larry 在 1994 年提出的算法,用于显示网络中节点的重要性。对于某个网页 v_i ,PageRank 值 $r(v_i) = \frac{1-d}{N} + d \left(\frac{r(u_1)}{d_{u_1}^+} + \dots + \frac{r(u_n)}{d_{u_n}^+} \right)$, $i = 1, 2, \dots, n$ 。其中: u_i 表示所有指向 v_i 的网页; $d_{u_i}^+$ 表示指向 v_i 的网页个数(v_i 的入度); N 为社交网络中的节点个数; d 为阻尼系数,一般来说 $d = 0.85$ 。在大型社交网络中,每个节点的 PageRank 值可能会很小,因此,通过将每个值除以最大值来将它标准化。

2.4.2 平均入评价

在社交网络中,每个节点都有 2 个身份:源节点(出节点)和目标节点(入节点)。作为一个目标节点,指向它的边的符号和权值代表它的入邻居对它的评价。在这里,对于节点 i ,使用平均入评价 $m(i)$ 来表示它的入邻居对它的平均评价,即

$$m(i) = \frac{\sum_{j \in N^-(i)} \omega_{ij}}{d_i^-}, \text{ 其中, } N^-(i) \text{ 为节点 } i \text{ 的入邻居集合, } d_i^- \text{ 为节点 } i \text{ 的入邻居数量。}$$

2.4.3 自信指数 α_i

网络中每个用户节点的自信程度与其在网络中的影响力大小和别人对其的评价密切相关。因此,这里的自信指数 α_i 由 PageRank 值和平均入评价加权求得,其计算公式为

$$\alpha_i = qm(i) + (1-q)r(i) \quad (2)$$

式中: $m(i)$, $r(i)$ 分别表示节点 i 的平均入评价和 PageRank 值; q 为常数, 且满足 $0 \leq q \leq 1$ 。

q 越大, 说明在定义自信指数时更注重周围人的评价; q 越小, 说明更注重 PageRank 值, 即每个个体在社会网络中的重要性。这里取 $q = 0.5$, 也就是平均入评价和 PageRank 值同等重要。

在真实的社交信任网络中, 一个用户对另一个用户的评价可能是负面的。由于 PageRank 值可能很小, 所以, α_i 可能为负, 这样是不符合实际意义的。因此, 引入线性整流函数, 将 α_i 的值限制在 $(0, 1)$ 内, 则式 (2) 变为

$$\alpha_i = \text{RELU}(qm(i) + (1-q)r(i)) \quad (3)$$

这里 $\text{RELU}(x) = \max\{0.0001, x\}$ 。有必要提的一点是, 为了使得 $\alpha_i > 0$, 这里的 RELU 函数是在一般的 RELU 函数上作了一些调整。从式 (3) 中可以看出, 如果一个人在网络中很重要或者周围人对他的评价较高, 那么, 这个人的自信指数就会比较大。

定义 3 总体意见 $p(z^*)$ 表示纳什均衡状态下所有用户表达意见的总和, $p(z^*) = \sum_i z_i^* = \mathbf{1}^T(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1}\mathbf{A}\mathbf{s}$, 这里的 $\mathbf{1}$ 是全 1 向量。

定义 4 在社交信任网络中, 为了提高整个网络的总体意见, 需要付出一定的费用来改变其中一些人的内部意见, 这些费用的总和称为预算。

定义 5 在社交信任网络中通过预算改变了一部分人的内部意见, 会使得总体意见增加。总体意见的增加量被称为效益。

3 社会信任网络中的意见最大化

定义 6 给定社交信任网络 G 、内部意见向量 $\mathbf{s}$ 和预算 μ , 内部意见问题的目标是找出每个用户节点的内部意见的修改情况 $\Delta\mathbf{s}$, 以最大化总体意见 $p(z^*)$ 。

$$\begin{aligned} & \max \mathbf{1}^T(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1}\mathbf{A}(\mathbf{s} + \Delta\mathbf{s}) \\ & \text{s.t.} \begin{cases} -1 \leq s_i + \Delta s_i \leq 1, & i = 1, 2, \dots, n \\ \|\Delta\mathbf{s}\|_1 \leq \mu \end{cases} \end{aligned}$$

为了解决内部意见问题, 使用一种传统的优化算法——交替方向乘子法 (ADMM 算法) 来进行求解。

3.1 利用 ADMM 算法解决内部意见问题

ADMM 算法是 Gabay 和 Mercier 提出的一种混合了双上升法的可分解性和乘数法优越性的收敛算法^[15]。当目标函数中有多个变量时, 对于凸

优化问题的求解是困难的。ADMM 算法利用变量分离法将问题分解成几个简单的子问题, 然后并行求解, 这样可以得到原问题的最优解^[16]。它是一种简单但强大的算法, 非常适合于解决分布式凸优化, 特别是应用统计和机器学习中出现的问题。

3.2 算法的步骤

要解决的优化问题为

$$\begin{aligned} & \min_{x, z} f(x) + g(z) \\ & \text{s.t.} \quad \mathbf{A}x + \mathbf{B}z = c \end{aligned}$$

这里, $x \in \mathbb{R}^n, z \in \mathbb{R}^m, \mathbf{A} \in \mathbb{R}^{p \times n}, \mathbf{B} \in \mathbb{R}^{p \times m}, c \in \mathbb{R}^p$ 。此问题的增广拉格朗日函数为

$$L_\rho(x, z, y) = f(x) + g(z) + \mathbf{y}^T(\mathbf{A}x + \mathbf{B}z - c) + \frac{\rho}{2}\|\mathbf{A}x + \mathbf{B}z - c\|_2^2$$

ADMM 算法迭代更新公式为

$$\begin{aligned} x^{k+1} &:= \arg \min_x L_\rho(x, z^k, y^k) \\ z^{k+1} &:= \arg \min_z L_\rho(x^{k+1}, z, y^k) \\ y^{k+1} &:= y^k + \rho(\mathbf{A}x + \mathbf{B}z - c) \end{aligned}$$

这里, $\rho > 0, c \in \mathbb{R}^p$ 为对偶变量, 这是 ADMM 算法的原始迭代形式。

3.3 采用 ADMM 算法解决内部意见问题

需要解决的内部意见问题为

$$\begin{aligned} & \max \mathbf{1}^T(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1}\mathbf{A}(\mathbf{s} + \Delta\mathbf{s}) \\ & \text{s.t.} \begin{cases} -1 \leq s_i + \Delta s_i \leq 1, & i = 1, 2, \dots, n \\ \|\Delta\mathbf{s}\|_1 \leq \mu \end{cases} \end{aligned}$$

因为, $\mathbf{1}^T(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1}\mathbf{A}\mathbf{s}$ 是常值, 可将问题写为如下形式:

$$\begin{aligned} & \max \mathbf{1}^T(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1}\mathbf{A}\Delta\mathbf{s} \\ & \text{s.t.} \begin{cases} -1 - s_i \leq \Delta s_i \leq 1 - s_i, & i = 1, 2, \dots, n \\ \|\Delta\mathbf{s}\|_1 \leq \mu \end{cases} \end{aligned}$$

为了简化, 令 $l(x) = -\mathbf{1}^T(\mathbf{A} + (\mathbf{I} - \mathbf{A})\mathbf{L})^{-1}\mathbf{A}x, x = \Delta\mathbf{s}$, $a_i = -1 - s_i, b_i = 1 - s_i$, 这样问题便可简写为

$$\begin{aligned} & \min l(x) + \lambda(\|x\|_1 - \mu) \\ & \text{s.t.} \quad a \leq x \leq b \end{aligned}$$

它等价于以下可以直接用 ADMM 算法解决的形式:

$$\begin{aligned} & \min l(x) + \lambda(\|z\|_1 - \mu) \\ & \text{s.t.} \begin{cases} a \leq x \leq b \\ x = z \end{cases} \end{aligned}$$

在这里, 变量 x, z, u 的更新为

$$\begin{aligned} x^{k+1} &:= \arg \min_x \left(l(x) + \frac{\rho}{2} \|x - z^k + u^k\|_2^2 \right) \\ z^{k+1} &:= S_{\lambda/\rho}(x^{k+1} + u^k) \\ u^{k+1} &:= u^k + x^{k+1} - z^{k+1} \end{aligned}$$

由以上公式可以得到每一步迭代的解析解为

$$x_i^{k+1} := \begin{cases} a_i, & z_i^k - u_i^k - \frac{\Delta_i}{\rho} < a_i \\ z_i^k - u_i^k - \frac{\Delta_i}{\rho}, & a_i < z_i^k - u_i^k - \frac{\Delta_i}{\rho} < b_i \\ b_i, & b_i < z_i^k - u_i^k - \frac{\Delta_i}{\rho} \end{cases} \quad (4)$$

$$z_i^{k+1} := \begin{cases} z_i^{k+1} - u_i^k - \frac{\lambda}{\rho}, & z_i^{k+1} - u_i^k > \frac{\lambda}{\rho} \\ 0, & -\frac{\lambda}{\rho} < z_i^{k+1} - u_i^k < \frac{\lambda}{\rho} \\ z_i^{k+1} - u_i^k + \frac{\lambda}{\rho}, & z_i^{k+1} - u_i^k < -\frac{\lambda}{\rho} \end{cases} \quad (5)$$

$$u_i^{k+1} := u_i^k + x_i^{k+1} - z_i^{k+1} \quad (6)$$

此算法收敛于全局最优解，迭代停止条件设为 $\|x_i^{k+1} - z_i^{k+1}\| < 10^{-4}$ 。经过一定次数的迭代，可以得到最优结果。现介绍算法1的伪代码。

利用ADMM算法解决内部意见问题。

输入: $G = (V, E)$, 预算 μ , 内部意见向量 s 。

输出: 内部意见调整量 Δs 。

将 Δs 初始化为全零向量, $k = 0$ 。

对于 $i = 1 : n$,

当 $\|x_i^k - z_i^k\| \geq 10^{-4}$,

由式(4)~(6)分别计算 $x_i^k, z_i^k, u_i^k, k = k + 1$ 。

由 $\Delta s_i = x_i$, 更新 Δs 。

算法1的第1行是将 Δs 初始化为全零向量。第2~5行是使用ADMM算法寻找最优解的过程。这里设置的停止条件为 $\|x_i^k - z_i^k\| < 10^{-4}$ 。最后一行是更新 Δs 。初始内部意见向量是用3种方法随机选择的。

4 实验研究

本文进行了一系列实验来评估所提出的方法。从以下2个方面进行实验：首先，将所提模型获得的结果与文献[10]中的模型进行比较；其次，为了进一步说明所提模型的优越性，将所提模型与其他启发式方法进行比较，所有的实验结果都表明了所提方法的优越性。

4.1 数据集

实验中使用到的数据集如下：a. Alpha。b. OTC。Alpha和OTC边上的权重为 $[-10, 10]$,

将它归一化为 $[-1, 1]$ 。c. WikiElec。d. WikiRfa。这2个网络中的边的符号、权重与信任密切相关。关于这些网络的具体数据详见斯坦福实验数据集(SNAP)。

4.2 内部意见的初始化

为了模拟不同的情况，随机选择服从特定分布的值来初始化内部意见向量 s 。对于每个网络，使用3种方式来初始化内部意见。a. 服从均匀分布 $s \sim U(-1, 1)$ ；b. 服从正态分布 $s \sim N(0, 1)$ ；c. 与节点度正相关, $s_i \propto \sum_j |a_{ji}|$ 。为了保证实验结果的公平性，复现了文献[10]中提到的方法，并在同一台计算机上进行实验。在实验中，设 $\mu = 200$, $q = 0.5$, 实验结果如表1所示。

表1 解决内部意见问题的平均效益
Tab.1 Average benefit in solving internal opinion problem

数据集	方法	平均效益
Alpha	文献[10]中模型	277
	所提模型	461
OTC	文献[10]中模型	318
	所提模型	600
WikiElec	文献[10]中模型	1115
	所提模型	1648
WikiRfa	文献[10]中模型	1000
	所提模型	1341

从表1可以看出，所提模型与文献[10]中的模型相比具有明显的优势。加入自信指数后，更加符合实际场景。每个人都有不同的个性，有些人更注重自己的意见，而有些人则更注重周围人的意见。例如，小孩很容易受到他人的影响，而老人或在社交网络中有较大影响力的人不容易受到他人的影响。由式(2)可知， α_i 越高，人越自信，表达意见的时候会越关注自己的观点，而不单纯是自己内部意见和周围人意见的加权均值。

4.3 对比实验

为了更好地体现此模型的优势，仿照文献[10]，将其与其他3种启发式方法(Rand, Trust, IO)进行比较。a. Rand^[17]：对节点随机排序。b. Trust^[9]：通过计算邻接矩阵相应列的和来表示节点的信任和。被大多数用户节点信任的用户节点在网络中可能会有较强的影响力，因此，按照节点信任总和降序对节点进行排序。c. IO^[18]：如果能够说服那些具有消极内部意见的用户节点，让

它们的内部意见变成积极的内部意见, 那么, 总体意见就会增加。因此, 取节点的内部意见, 对节点进行升序排序。实验结果如表 2 和图 2 所示。从实验结果可以看出, 所提模型在所有数据集上都具有优势。

表 2 本文方法与其他启发式方法相比的平均效益
Tab.2 Average benefit of this method compared with other heuristic methods

初始化方法	启发式方法	数据集			
		Alpha	OTC	WikiElec	WikiRfa
Uniform	Ours	463	532	1 550	1 340
	Rand	41	21	13	29
	Trust	225	83	275	298
	IO	23	25	144	34
Normal	Ours	452	578	1 581	1 341
	Rand	26	20	87	14
	Trust	250	112	205	378
	IO	36	23	233	15
Degree	Ours	454	569	1 545	1 375
	Rand	18	14	29	40
	Trust	250	92	297	329
	IO	260	120	8	174




图 2 本文方法与其他启发式方法相比的平均效益柱状图
Fig.2 Histogram of average benefit of this method compared with other heuristic methods

5 结束语

提出了一种广义的社交信任网络意见动态模型来解决社交信任网络中的意见最大化问题。与其他方法不同的是, 所提模型引入了一个新的自信指数, 并利用 ADMM 算法求解了内部意见问题。在 4 个数据集上的实验结果证明了该模型的

有效性。今后还将考虑使用接近中心性、度中心性等来估计 α_i , 以及用此模型解决固定部分点的表达意见使得总体意见最大化的问题。

参考文献:

[1] LI F Z, WU J, XUE S, et al. Detecting the evolving community structure in dynamic social networks[J]. *World Wide Web*, 2020, 23(2): 715–733.

[2] GARG S, PANWAR D S, GUPTA A, et al. A literature review on sentiment analysis techniques involving social media platforms[C]//*Proceedings of the Sixth International Conference on Parallel, Distributed and Grid Computing*. Wagnaghat: IEEE, 2020: 254–259.

[3] BHATIA B, VERMA A, ANJUM, et al. Analysing cyberbullying using natural language processing by understanding jargon in social media[M]//AURELIA S, HIREMATH S S, SUBRAMANIAN K, et al. *Sustainable Advanced Computing*. Singapore: Springer, 2021: 397–406.

[4] AGARWAL Y, SHARMA D K, KATARYA R. Sentiment/opinion review analysis: detecting spams from the good ones[C]//*Proceedings of the 4th International Conference on Information Systems and Computer Networks*. Mathura: IEEE, 2019: 557–563.

[5] JAIN L, KATARYA R. A systematic survey of opinion leader in online social network[C]//*Proceedings of the 2018 International Conference on Soft-Computing and Network Security*. Coimbatore: IEEE, 2018: 1–5.

[6] KATARYA R, ARORA Y. Capsmf: a novel product recommender system using deep learning based text analysis model[J]. *Multimedia Tools and Applications*, 2020, 79(47): 35927–35948.

[7] KATARYA R, MASSOUDI M. Recognizing fake news in social media with deep learning: a systematic review[C]//*Proceedings of the 4th International Conference on Computer, Communication and Signal Processing*. Chennai: IEEE, 2020: 1–4.

[8] GUPTA A, KATARYA R. Social media based surveillance systems for healthcare using machine learning: a systematic review[J]. *Journal of Biomedical Informatics*, 2020, 108: 103500.

[9] CHEN S, FAN J, LI G L, et al. Online topic-aware influence maximization[J]. *Proceedings of the VLDB Endowment*, 2015, 8(6): 666–677.

[10] XU P H, HU W B, WU J, et al. Opinion maximization in social trust networks[C]//*Proceedings of the 29th International Joint Conference on Artificial Intelligence*. Huawei: Unknown Publishers, 2020: 1251–1257.

[11] LIU X Y, KONG X N, YU P S. Active opinion maximization in social networks[C]//*Proceedings of the 24th ACM SIGKDD International Conference on*

