



融合用户传播风险和节点影响力分析的虚假信息传播控制方法

荆军昌, 张志勇, 宋斌, 班爱莹, 高东钧

引用本文:

荆军昌, 张志勇, 宋斌, 班爱莹, 高东钧. 融合用户传播风险和节点影响力分析的虚假信息传播控制方法[J]. 智能系统学报, 2024, 19(2): 360–369.

JING Junchang, ZHANG Zhiyong, SONG Bin, et al. Disinformation diffusion control method integrating user propagation risk and node influence analysis[J]. *CAAI Transactions on Intelligent Systems*, 2024, 19(2): 360–369.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202210009>

您可能感兴趣的其他文章

异质信息网络中基于网络嵌入的影响力最大化

Influence maximization based on network embedding in heterogeneous information networks
智能系统学报. 2021, 16(4): 757–765 <https://dx.doi.org/10.11992/tis.202009047>

基于渗流模型的影响力最大化算法

An influence maximization algorithm based on percolation model
智能系统学报. 2019, 14(6): 1262–1270 <https://dx.doi.org/10.11992/tis.201906039>

基于加权聚类集成的标签传播算法

Label propagation algorithm based on weighted clustering ensemble
智能系统学报. 2018, 13(6): 994–998 <https://dx.doi.org/10.11992/tis.201806011>

融合情感极性和逻辑回归的虚假评论检测方法

Detection of fake reviews based on emotional orientation and logistic regression
智能系统学报. 2016, 11(3): 336–342 <https://dx.doi.org/10.11992/tis.201603027>

基于影响力控制的热传导算法

Heat conduction controlled by the influence of users and items
智能系统学报. 2016, 11(3): 328–335 <https://dx.doi.org/10.11992/tis.201603042>

基于粒子群优化的Elman神经网络无模型控制

Elman model-free control method based on particle swarm optimization algorithm
智能系统学报. 2016, 11(1): 49–54 <https://dx.doi.org/10.11992/tis.201507025>

DOI: 10.11992/tis.202210009

网络出版地址: <https://link.cnki.net/urlid/23.1538.TP.20240104.1716.002>

融合用户传播风险和节点影响力分析的 虚假信息传播控制方法

荆军昌^{1,2}, 张志勇^{1,2}, 宋斌^{1,2}, 班爱莹^{1,2}, 高东钧^{1,2}

(1. 河南科技大学 信息工程学院, 河南 洛阳 471023; 2. 河南科技大学 河南省网络空间安全应用国际联合实验室, 河南 洛阳 471023)

摘要: 在线社交网络中虚假信息传播蔓延成为当前网络空间安全治理面临的重要挑战。提出一种融合用户传播风险和节点影响力分析的虚假信息传播控制方法 DDC-UPRNI (disinformation diffusion control method integrating user propagation risk and node influence analysis)。综合考虑虚假信息传播特征空间的多样性和复杂性, 通过自注意力机制实现用户传播虚假信息行为维度、时间维度和内容维度特征的嵌入表示, 运用改进的无监督聚类 K-means++ 算法实现不同用户传播风险等级的自动划分; 设计一种自适应加权策略实现对离散粒子群优化算法的改进, 进而提出一种基于离散粒子群优化的虚假信息传播关键节点选取方法, 用于从具有特定传播风险等级的用户节点集合中选取若干个具有影响力的控制驱动节点, 从而实现精准、高效的虚假信息传播控制; 基于现实在线社交网络平台上开展试验, 结果表明, 所提出的 DDC-UPRNI 方法与现有算法相比, 在控制效果和时间复杂度等重要指标上具有明显优势。该方法为社会网络空间中的虚假信息管控治理提供重要参考。

关键词: 在线社交网络; 虚假信息; 传播风险; 嵌入表示; 节点影响力; 自适应加权; 离散粒子群; 传播控制

中图分类号: TP309 **文献标志码:** A **文章编号:** 1673-4785(2024)02-0360-10

中文引用格式: 荆军昌, 张志勇, 宋斌, 等. 融合用户传播风险和节点影响力分析的虚假信息传播控制方法 [J]. 智能系统学报, 2024, 19(2): 360-369.

英文引用格式: JING Junchang, ZHANG Zhiyong, SONG Bin, et al. Disinformation diffusion control method integrating user propagation risk and node influence analysis[J]. CAAI transactions on intelligent systems, 2024, 19(2): 360-369.

Disinformation diffusion control method integrating user propagation risk and node influence analysis

JING Junchang^{1,2}, ZHANG Zhiyong^{1,2}, SONG Bin^{1,2}, BAN Aiyong^{1,2}, GAO Dongjun^{1,2}

(1. Information Engineering College, He'nan University of Science and Technology, Luoyang 471023, China; 2. He'nan International Joint Laboratory of Cyberspace Security Applications, He'nan University of Science and Technology, Luoyang 471023, China)

Abstract: The spread of disinformation on online social networks (OSNs) has become a critical challenge for cyberspace security governance. This paper presents DDC-UPRNI, a disinformation diffusion control method, by integrating user propagation risk with node influence analysis. First, comprehensively considering the diversity and complexity of the characteristic space of disinformation propagation, an embedded representation of the behavior, time and content dimensions of user propagation of disinformation is realized through the self-attention mechanism, and the automatic classification of different user propagation risk levels is achieved using the improved unsupervised clustering K-means++ algorithm. Second, an adaptive weighting strategy is designed to improve the discrete particle swarm optimization algorithm, and a method for selecting key nodes of disinformation propagation is proposed based on the discrete particle swarm optimization. This method determines several influential control driving nodes from the user node set with a specific propagation risk level to achieve accurate and highly efficient disinformation propagation control. Finally, experiments are performed on a real OSN platform, and the results demonstrate that the proposed DDC-UPRNI method has obvious advantages over other existing algorithms in some important indicators, including control effect and time complexity. This method provides a significant reference value for the current governance of disinformation in social cyberspace.

Keywords: online social networks; disinformation; propagation risk; embedded representation; node influence; adaptive weighting; discrete particle swarm; diffusion control

收稿日期: 2022-10-09. 网络出版日期: 2024-01-05.

基金项目: 国家自然科学基金项目 (61972133); 河南省中原科技创新领军人才项目 (204200510021); 中国博士后科学基金项目 (2021M700885).

通信作者: 张志勇. E-mail: xidianzzy@126.com.

在线社交网络 (online social networks, OSNs) 已经成为人们传递信息和表达情感的重要载体。然而, OSNs 在为用户带来便利的同时, 也滋生了

大量虚假信息和谣言^[1]。虚假信息由于具有突发性、隐蔽性和散布性等特点,所以给社会带来了巨大的负面影响力。相关研究表明,虚假信息在早期传播阶段与真实信息在传播方式上具有明显的区别^[2]。此外,虚假信息甚至比真实信息传播得更快、更远和更广^[3]。因此,虚假信息的控制和治理已经成为政府和社交平台管理者亟待解决的关键问题。

OSNs 虚假信息和谣言的传播控制指通过采用合适的智能理论和技术,选取并控制某些特殊的关键传播节点(驱动节点),从而达到控制信息在整个网络中大规模传播的目的^[4-5]。特别的,关键传播节点是指在虚假信息传播过程中起重要作用的节点。这些关键节点在传播广度、传播深度和传播速度上对社交平台造成严重影响。因此,准确有效识别关键传播节点成为 OSNs 虚假信息和谣言传播控制的重要手段之一^[6]。目前,关键传播节点的识别方法主要分为两类,1)贪心算法^[7-9]:该类算法在运行过程中能够获取很好的近似解,但由于涉及到蒙特卡罗仿真,故计算成本很高。此外,该类算法针对大规模社交网络时表现的性能并不理想。2)元启发式算法^[10-12]:该类算法的优势在于能够有效地避免在运行过程中使用蒙特卡罗仿真,从而降低了计算的时间开销。因此,元启发式算法更适用于大规模社交网络中关键节点的识别。

情境分析作为一种以人为中心的新型计算范式的基础,在软件工程领域得到了广泛关注^[13]。随着社会网络服务的多样化,人-人和人-机器在交互过程中产生了大量以人为中心的数据。在早期的研究中,Zhang 等^[14]通过将情境分析技术推广到社会网络领域,提出了一套社会情境理论,并将其用于社交用户行为模式的分析和发现。在此基础上,张志勇等^[15]进一步提出了适用于社交网络虚假信息传播场景的社会情境安全分析框架(socialsitu security)。由于本研究开展的虚假信息传播风险研究与用户传播行为模式之间具有潜在的关系,因此社会情境安全分析框架为本研究工作的开展奠定了重要的基础。

粒子群优化(particle swarm optimizer, PSO)算法作为一种经典的群智能优化算法,具有简单、高效和收敛速度快等显著优势,但该算法在迭代过程中容易陷入局部最优。近年来,一些研究人员开始通过设计一些加权策略对 PSO 算法进行改进,但这些算法只适用于连续的搜索空间,不能直接适用于求解离散空间的寻优问题^[16]。因

此,Gong 等^[17]开始对离散粒子群优化(discrete particle swarm optimizer, DPSO)算法进行深入研究,提出了一种标准的 DPSO 算法,用于解决社交网络离散空间的寻优问题。随后,Tang 和 Liu 等^[18-19]开始对标准的 DPSO 算法进行改进,并将其用于识别社交网络中具有影响力的关键节点。在谣言传播控制方面,Liu 等^[19]提出了一种基于进化搜索策略的 DPSO 算法,用于识别社交网络中具有影响力的谣言传播节点。

虚假信息和谣言传播风险评估和感知研究近年来受到了学者们的广泛关注^[20-22]。研究人员主要采用传播动力学模型和风险感知因素分析的方式展开深入研究。例如,Zhang 等^[20]基于改进的谣言传播动力学模型 ICSAR(无知者 I、信息载体 C、信息传播者 S、倡导者 A、移除者 R)和动态的个人活动轨迹数据,建立了谣言传播动态时空综合风险评估模型,得到社交网络中谣言传播风险分布图。洪巍等^[21]选取社交网络中关于食品安全主题的谣言作为研究对象,重点针对谣言关注度的风险感知影响因素进行深入研究,提出了“谣言-风险感知-关注度”的理论研究框架。

本研究的创新点主要包括:

1)构建了一种用户传播风险划分模型,该模型能够根据用户传播虚假信息的行为维度特征、时间维度特征和内容维度特征,实现对具有不同传播风险程度的用户自动划分。

2)提出了一种基于改进 DPSO 的虚假信息传播关键节点选取方法,用于从具有特定传播风险的用户集合中选取出具有影响力的关键传播节点,使得传播控制效果达到最大化。

1 相关工作

近年来,国内外研究学者主要通过采用贪心算法和元启发式算法选取社交网络中合适的关键用户节点,并对这些关键的用户节点进行阻塞,从而实现虚假信息和谣言的大规模传播和控制。

1.1 贪心算法

贪心算法作为一种传统的关键节点选取方法,受到研究人员的广泛关注。例如,Kempe 等^[23]提出了一种爬山(hill-climb, HC)算法,该算法能够用于识别社交网络中具有影响力的前 K 个关键节点。Leskovec 等^[8]通过利用子模块特性开发了一个有效的贪心算法 CELF(cost-effective lazy forward)。Goyal 等^[9]通过对 CELF 算法进行优化,提出了 CELF++ 算法用于识别具有影响力的关键节点。Taherinial 等^[24]根据网络中的核心节

点组成最小跨越节点集合,使用蒙特卡罗仿真估计最小跨越节点集合的传播影响力。

1.2 元启发式算法

近年来,相关学者开始针对一些元启发式算法展开研究。例如,Tang等^[18]设计了一种基于网络拓扑结构的局部搜索策略,并对DPSO算法进行改进,从而识别前 k 个具有影响力的关键节点。Chen等^[4]设计了一种具有自适应维数选择机制的蚁群优化算法,提出了一种多目标优化模型,用于识别社交网络中关键传播者。图1给出OSNs虚假信息传播控制示意图。

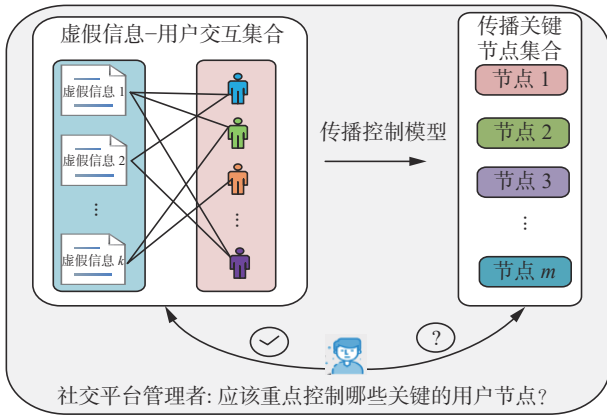


图1 OSNs虚假信息传播控制示意图

Fig. 1 Schematic diagram of OSNs disinformation diffusion control

2 相关定义与解决方案

2.1 相关定义

定义1^[15] 社会情境 $Socialsitu(t) = \{obj, ID, d, A, E, T\}_t$, 其中, obj 指社交客体, ID 指用户所属的群组和角色, d 指用户的意愿, A 指用户的行为集合, E 指用户所处的环境, T 指受众实体的类型。

定义2 用户历史传播虚假信息对应的集合 $G_F^u = \{(F, u_i) | F = \{f_1, f_2, \dots, f_n\}, u_i \in U\}$ 。这里 G_F^u 指用户 u_i 传播虚假信息组成的序列 F , U 指社交网络中用户的集合, 虚假信息 $f_n = \{w_1, w_2, \dots, w_{n_m}\}$, w_{n_m} 表示虚假信息 f_n 中的第 n_m 个单词。

定义3 虚假信息传播路径序列集合 $P = \{p(f_1), p(f_2), \dots, p(f_n)\}$, 这里 $p(f_n) = \langle (u_0, Socialsitu(t_0)), (u_1, Socialsitu(t_1)), \dots, (u_k, Socialsitu(t_k)) \rangle$ 。

定义4 用户传播虚假信息的历史行为集合 $B = \{(a_i, b_i, c_i, u_i, \Delta t) | u_i \in U, \Delta t \in \varphi\}$ 。其中 a_i 、 b_i 和 c_i 分别指在 Δt 时间段内用户 u_i 分享、点赞和评论虚假信息的数量。

定义5 虚假信息传播控制效果 $L(S)$ 。选取局

部影响估计子 (local influence estimation, LIE)^[17] 作为评估虚假信息传播关键节点集合 S 在独立级联 (independent cascade, IC) 模型 2-hop 区域内的传播控制效果。LIE 函数的表达式如下

$$L(S) = \sigma_0(S) + \sigma_1^*(S) + \tilde{\sigma}_2(S) = |S| + \left(1 + \frac{1}{|N_s^{(1)} \setminus S|} \sum_{u \in N_s^{(2)} \setminus S} p_u^* d_u^* \right) \sum_{i \in N_s^{(1)} \setminus S} \left(1 - \prod_{(i,j) \in E, j \in S} (1 - p_{ij})\right) \quad (1)$$

式中: $\sigma_0(S)$ 表示 S 中节点数量; $\sigma_1^*(S)$ 和 $\tilde{\sigma}_2(S)$ 分别表示 1-hop 和 2-hop 区域期望影响传播值; $N_s^{(1)}$ 和 $N_s^{(2)}$ 表示 S 中节点在 1-hop 和 2-hop 区域的邻居集合; p_u^* 表示 $N_s^{(2)} \setminus S$ 中节点 u 在传播模型中恒定的激活概率; d_u^* 表示 $N_s^{(2)} \setminus S$ 中节点 u 在 $N_s^{(1)}$ 和 $N_s^{(2)}$ 中边数; E 表示节点之间的边集合; p_{ij} 表示虚假信息传播概率。

2.2 用户传播风险划分模型

本节首先对用户传播特征进行提取,并通过自注意力机制实现特征的嵌入表示;其次,使用改进的无监督聚类算法 K-Means++, 对上述用户传播特征嵌入向量进行聚类划分。最后,假定传播虚假信息影响力越大的簇,其对应的用户传播风险等级越高。根据每一个簇中包含的传播特征向量,得到其对应的用户节点集合,进而计算这些用户节点对应的 LIE 值。若上述得到的簇对应的 LIE 值越大,则其对应的用户集合传播风险等级越高。图2给出具体的用户传播风险划分流程图。

2.2.1 基于自注意力机制的用户传播特征嵌入表示

用户行为维度特征包括用户传播虚假信息的活动关注度、活跃度、交互度和转移概率。该维度的特征具体描述如下。

1) 用户活动关注度: 用户活动关注度能够从整体上度量用户对虚假信息的关注程度,具体定义如下

$$A(u_i) = \frac{M_{u_i}^{(RT)} + M_{u_i}^{(like)} + M_{u_i}^{(RV)}}{\Delta T \times \frac{1}{N} \sum_{i=1}^N (M_{u_i}^{(RT)} + M_{u_i}^{(like)} + M_{u_i}^{(RV)})} \quad (2)$$

式中: $M_{u_i}^{(RT)}$ 、 $M_{u_i}^{(like)}$ 和 $M_{u_i}^{(RV)}$ 分别表示用户在 ΔT 时间区间内对虚假信息的分享数量、点赞数量和评论数量, N 表示传播虚假信息用户总数。

2) 用户传播虚假信息的活跃度: 用户在特定时间内转发虚假信息数量,能够准确地反映用户的活跃程度,具体定义为^[25]

$$R(u_i) = \frac{n_2^{u_i}}{n_1^{u_i}} \quad (3)$$

式中: $n_2^{u_i}$ 表示用户 u_i 在 ΔT 时间段内转发虚假信息帖子的总数量; $n_1^{u_i}$ 表示用户 u_i 在 ΔT 时间区间内转发所有帖子的总数量。

3) 用户传播虚假信息的交互度: 用户的交互度是以在一定时间段内用户传播虚假信息数量为基数, 以用户的好友数作为覆盖指数, 具体定义如下

$$I(u_i) = (f_{rr})^{\lg(|N^{\text{out}}(u_i)|+1)} \quad (4)$$

式中: $f_{rr} = \frac{n_2^{u_i}}{\Delta T}$, $n_2^{u_i}$ 表示用户 u_i 在 ΔT 时间区间内转发虚假信息帖子的总数量; $N^{\text{out}}(u_i)$ 表示用户 u_i 的好友数量。

4) 用户传播虚假信息的转移概率: 根据随机过程中状态转移概率的定义, 结合虚假信息传播的行为模式, 给出用户传播虚假信息的转移概率, 具体表示为

$$P(u_i) = \frac{\sum_t \{X(t+1) = j, X(t) = i\}}{\sum_t X(t) = i}, \quad t \in T \quad (5)$$

式中: $\sum_t X(t) = i$ 表示用户处于状态 i 的总数; $\sum_t \{X(t+1) = j, X(t) = i\}$ 表示在 t 时刻用户处于状态 i , 在 $t+1$ 时刻处于状态 j 的总数。

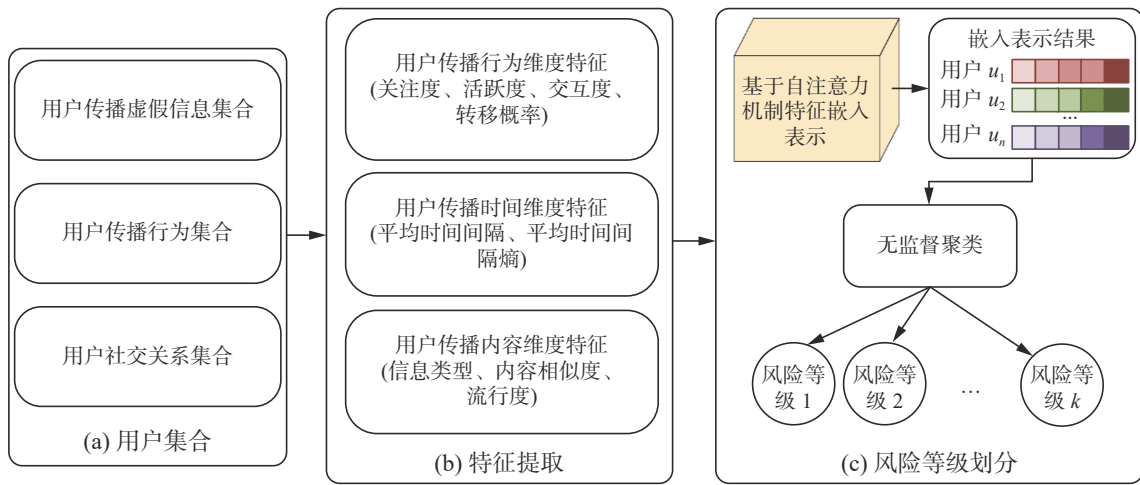


图2 用户传播风险划分流程

Fig. 2 Flow chart of user dissemination risk division

用户时间维度特征包括用户传播虚假信息的平均时间间隔和时间间隔熵。该维度的特征具体描述如下。

1) 用户传播虚假信息的平均时间间隔。用户传播虚假信息的平均时间间隔由发布者发布时间和传播者传播信息时间决定, 具体定义如下:

$$T(u_i) = \frac{1}{n_2^{u_i}} \sum_{k=1}^K (t_1^{(k)} - t_0^{(k)}) \quad (6)$$

式中 $t_1^{(k)}$ 和 $t_0^{(k)}$ 分别表示用户 u_i 传播第 k 条信息的时间及该信息对应的发布时间。

2) 用户传播虚假信息的时间间隔熵。时间间隔熵能够准确反应社交网络中用户行为在时间上的分布规律, 具体表示为^[26]

$$H(u_i) = - \sum_{i=1}^{n_r} p(\Delta t_i) \lg(p(\Delta t_i)) \quad (7)$$

式中: $p(\Delta t_i) = \frac{n_{\Delta t_i}}{\sum_{k=1}^{n_r} n_{\Delta t_k}}$, $n_{\Delta t_i}$ 表示用户在第 i 个时间间隔 Δt_i 内传播虚假信息数量。

用户传播内容维度特征包括用户传播虚假信息类型、流行度和内容相似度。该维度的特征具体描述如下。

1) 虚假信息类型。虚假信息通常以文本或文本和图片相结合的形式存在于社交网络中, 社交用户通常更倾向于传播带有图片或 URL 的虚假信息^[27], 具体表达式如下

$$C(u_i) = \frac{|n_{u_i}p| + |n_{u_i}r|}{|n_{u_i}|} \quad (8)$$

式中: $|n_{u_i}p|$ 和 $|n_{u_i}r|$ 分别表示用户 u_i 传播虚假信息中包含图片的虚假信息数量和包含 URL 的虚假信息数量; $|n_{u_i}|$ 表示用户 u_i 传播包含所有虚假信息类型的总数量。

2) 虚假信息的流行度。社交网络中谣言和虚假信息的传播过程类似于物理学领域放射性元素半衰期过程^[28]。因此, 根据放射性元素半衰期的定义和 2.1 节的定义 2, 将虚假信息流行度定义为

$$K(u_i) = \sum_{i=1}^n \left(D(f_i, t) \times (1/2)^{\frac{t-t_0}{\gamma}} \right) \quad (9)$$

式中: $D(f_i, t)$ 表示虚假信息 f_i 从发布时刻 t_0 到当前时刻 t 的传播总数量; $(1/2)^{\frac{t-t_0}{\gamma}}$ 表示虚假信息流行度的半衰期函数; γ 表示正则化参数。

3) 虚假信息的内容相似度。为了准确衡量用户之间传播虚假信息内容的相似度, 给出相似度具体定义:

$$S(u_i, v) = \sum_{v \in N(u_i)} J(u_i, v) \quad (10)$$

式中: $J(u_i, v) = \frac{V_i \cdot V_j}{\|V_i\| \|V_j\|}$; 这里 $N(u_i)$ 表示用户 u_i 的邻居用户集合; V_i 和 V_j 分别表示运用 Doc2vec 算法^[29]得到用户 u_i 和邻居用户 v 对应的 d 维向量。

综上, 首先分别对用户行为维度、时间维度和内容维度特征进行建模, 具体表示如下

$$f_{\text{behavior}}(u_i) = A(u_i) \times R(u_i) \times I(u_i) \times P(u_i) \quad (11)$$

$$f_{\text{time}}(u_i) = T(u_i) \times H(u_i) \quad (12)$$

$$f_{\text{content}}(u_i) = C(u_i) \times K(u_i) \times S(u_i, v) \quad (13)$$

然后通过嵌入层将每个用户对应的上述维度特征进行嵌入表示, 并输入到全连接层。根据加性注意力机制^[30], 将每个用户对应特征的权重系数表示为

$$\alpha_p^{(u_i)} = \text{Softmax}(\mathbf{w}^T \tanh(\mathbf{W} \tilde{\mathbf{H}}))^T \quad (14)$$

式中: $\mathbf{w} \in \mathbf{R}^{e_2 \times 1}$, $\mathbf{W} \in \mathbf{R}^{e_2 \times e_1}$, $\text{Softmax}(\cdot)$ 和 $\tanh(\cdot)$ 指激活函数。进而通过自注意力机制学习每个用户对应的特征, 得到其特征嵌入表示 $\mathbf{r}_p^{(u_i)}$ 。最后, 构建全连接层并将每个用户所有特征的嵌入向量进行拼接, 在输出层得到用户 u_i 所有特征的嵌入表示向量 $\mathbf{r}^{(u_i)}$ 。

2.2.2 基于改进 K-Means++ 的用户传播风险等级划分

标准的 K-Means 算法通常采用随机的方式选取初始的簇中心, 因此如果初始簇中心的选取不合适, 则容易导致算法陷入局部最优。为了有效地克服上述聚类算法存在的不足之处, 根据 2.2.1 节中用户嵌入表示向量 $\mathbf{r}^{(u_i)}$, 构建用户集合 U 的传播特征矩阵 $\mathbf{R}^{(U)} = \{\mathbf{r}^{(u_i)} | u_i \in U\}_{i=1}^n$, 并将其作为改进 K-Means++ 聚类算法的输入。该聚类算法首先从传播特征矩阵 $\mathbf{R}^{(U)}$ 中随机选取一个用户特征向量作为初始的簇中心, 计算剩余用户对应的特征向量与簇中心之间的最短距离 $D(\mathbf{r}^{(u_i)})$ 。然后, 从传播特征矩阵 $\mathbf{R}^{(U)}$ 中选取某一个用户特征向量作为下一个簇中心, 并通过以下方式计算其对应的概率值 $p(\mathbf{r}^{(u_i)})$, 直至得到第 k 个初始的簇中心。最后, 通过标准的 K-Means 算法对用户特征嵌入向量进行聚类, 从而得到 k 个不同的簇。根据每

一个簇中包含的传播特征向量, 得到其对应的用户节点集合, 进而计算这些用户节点对应的 LIE 值。若上述得到的簇对应的 LIE 值越大, 则其对应的传播风险等级越高。

2.3 基于改进离散粒子群优化的控制驱动节点集选取

本节将虚假信息传播控制驱动节点集选取作为一种带约束的优化问题, 即在 2.2 节风险节点等级划分的基础上, 通过设计一种改进的 DPSO 算法, 用于从高风险节点集合中筛选出具有重要影响力的关键传播节点, 并将其作为控制驱动节点。

2.3.1 粒子位置和速度向量离散化表示和初始化

在 DPSO 中, 粒子 i 的位置由 s 维整数向量 \mathbf{X}_i 进行编码, 即 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{is})$, ($i = 1, 2, \dots, n_1$), 其中 x_{ij} 指高风险节点。粒子 i 的速度表示为 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{is})$, 其中, $v_{ij} \in \{0, 1\}$ 。当 $v_{ij} = 1$ 时, 该处对应的用户节点需要使用其他用户节点进行替换。当 $v_{ij} = 0$ 时, 该处对应的用户节点保持不变。粒子 i 的初始速度向量 $\mathbf{V}_i = \mathbf{0}$, 初始位置向量 \mathbf{X}_i 由基于度和 K-壳的启发式算法 (算法 1) 生成。算法 1 中 $\hat{D}(x_{ij})$ 指节点 x_{ij} 的度 $k(x_{ij})$ 和改进标准 K-壳 $k_s^*(x_{ij})$ 的组合, 具体表示为

$$\hat{D}(x_{ij}) = k(x_{ij}) + k_s^*(x_{ij}) \quad (15)$$

式中: $k(x_{ij})$ 指节点 x_{ij} 的度; $k_s^*(x_{ij})$ 指改进的标准 K-壳, 即 $k_s^*(x_{ij}) = k_s(x_{ij}) + \frac{p(x_{ij})}{\max q(x_{ik}) + 1}$; $k_s(x_{ij})$ 表示节点 x_{ij} 的标准 K-壳值; $q(x_{ik})$ 表示节点 x_{ik} 在 K-壳分解过程的阶段总数; $p(x_{ij})$ 表示节点 x_{ij} 在移除阶段的次序。受万有引力定律的启发, 将节点 \hat{D} 值作为它们的质量, 将网络中 2 个节点之间的最短距离作为它们的距离, 则虚假信息传播的高风险用户节点 x_{ij} 的度和 K-壳通过引力模型可进一步表示为^[31]

$$\hat{M}(x_{ij}) = \sum_{j \neq k, d(x_{ij}, x_{ik}) \leq R} \frac{\hat{D}(x_{ij}) \hat{D}(x_{ik})}{d^2(x_{ij}, x_{ik})} \quad (16)$$

式中: $d(x_{ij}, x_{ik})$ 表示节点 x_{ij} 和 x_{ik} 之间的最短距离; R 表示截断半径。

算法 1 基于度和 K-壳的粒子位置向量初始化

输入 种群个数 n_1 , 种子节点个数 d , 传播虚假信息的高风险节点集合 M , 截断半径 R

输出 粒子的初始位置向量 \mathbf{X}

1) Begin

2) for $i=1:n_1$ do

3) 根据式 (17) 计算 \mathbf{X}_i 中节点 $\hat{D}(\mathbf{X}_i)$

4)根据式(18)计算 X_i 中节点 $\hat{M}(X_i)$

5) $X_i \leftarrow (X_i)$

6)for all $x_{ij} \in X_i$ do

7) if $r(x_{ij}) > 1/2$ then // $r(x_{ij})$ 表示 X_i 中 x_{ij} 位置对应的 $[0,1]$ 之间随机数

8) $x_{ij} \leftarrow l(x_{ij}, M)$ // 1表示将 x_{ij} 用高风险节点集合 M 中其他节点进行代替

9)endif

10)endfor

11)endfor

12)End

2.3.2 粒子位置和速度向量更新规则的改进

粒子的速度向量使得粒子位置朝着更优的方向前进,标准的粒子速度向量更新规则表示如下^[17]

$$V_i(l+1) \leftarrow H(w \times V_i(l) + c_1 \times r_1 \times (E_i(l) \cap_{(1)} X_i(l)) + c_2 \times r_2 \times (B(l) \cap_{(1)} X_i(l))) \quad (17)$$

式中: l 表示迭代次数; w 表示惯性权重; c_1 和 c_2 分别表示认知加速系数和社会加速系数; r_1 和 r_2 为 $[0,1]$ 的随机数;决策函数 $H(\cdot)$ 用于确定 V_i 中的元素 $v_{ij} \in \{0,1\}$; $\cap_{(1)}$ 表示逻辑相似交叉运算符。

算法2 虚假信息传播控制算法

输入 用户集合 $U = \{u_1, u_2, \dots, u_{|U|}\}$, 虚假信息集合 F 。

用户历史传播虚假信息集合 $G_F^u = \{(F, u_i) | F = \{f_1, f_2, \dots, f_n\}, u_i \in U\}$, 用户历史行为集合 $B = \{a_i, b_i, c_i, u_i, \Delta t | u_i \in U, \Delta t \in \emptyset\}$ 。

虚假信息传播路径序列集合 $P = \{p(f_1), p(f_2), \dots, p(f_n)\}$, 聚类个数 k , 传播概率 p

输出 控制驱动节点集合 S

1)Begin

2)控制驱动节点集合 S 初始化 $S = \emptyset$

3)for each $u_i \in U$ 且 $i \leftarrow 1$ to $|U|$ do

4)根据式(11)计算用户 u_i 传播行为维度特征 $f_{\text{behavior}}(u_i)$

5)根据式(12)计算用户 u_i 传播时间维度特征 $f_{\text{time}}(u_i)$

6)根据式(13)计算用户 u_i 传播内容维度特征 $f_{\text{content}}(u_i)$

7)计算用户 u_i 对应的特征嵌入表示向量 $\mathbf{r}^{(u_i)}$

8)endifor

9)生成用户集合 U 的传播特征 $\mathbf{R}^{(U)}$

10)生成初始的簇中心集合 C

11)通过标准的K-means算法生成高风险用户节点集合 M

12)根据集合 M 和改进的自适应加权DPSO算法生成控制驱动节点

13)对控制驱动节点进行筛选,生成控制驱动节点集合 S

14)End

由于上述标准粒子速度向量更新规则中认知加速系数 c_1 和社会加速系数 c_2 为常数,在算法迭代过程中不能根据粒子个体当前的位置与其局部最优位置(Pbest)和群体全局最优位置(Gbest)的距离进行自适应地调整。本研究基于Sigmoid函数设计了一种自适应加权更新策略,具体表示如下

$$V_i(l+1) \leftarrow H(w \times V_i(l) + c_{g_{pi}}(l) \times r_1 \times (E_i(l) \cap_{(1)} X_i(l)) + c_{g_{gi}}(l) \times r_2 \times (B(l) \cap_{(1)} X_i(l))) \quad (18)$$

式中,认知加速系数 $c_{g_{pi}}(l)$ 和社会加速系数 $c_{g_{gi}}(l)$ 分别表示为

$$c_{g_{pi}}(l) = F(g_{pi}(l)) = \frac{b}{1 + e^{-a \times g_{pi}(l)}} + c \quad (19)$$

$$c_{g_{gi}}(l) = F(g_{gi}(l)) = \frac{b}{1 + e^{-a \times g_{gi}(l)}} + c \quad (20)$$

式中: $F(\cdot)$ 指自适应加权更新函数;参数 a 指该函数曲线的陡度;参数 b 指该曲线的峰值;参数 c 为常数。此外,在标准的Jaccard系数定义基础上,给出DPSO中粒子 i 的位置 X_i 分别与其 E_i 和群体 B 距离的定义,具体表示如下

$$g_{pi}(l) = 1 - \frac{|E_i(l) \cap_{(2)} X_i(l)|}{|E_i(l) \cup X_i(l)|} \quad (21)$$

$$g_{gi}(l) = 1 - \frac{|B(l) \cap_{(2)} X_i(l)|}{|B(l) \cup X_i(l)|} \quad (22)$$

式中: $|E_i(l) \cap_{(2)} X_i(l)|$ 表示 $E_i(l)$ 与 $X_i(l)$ 中相同元素的个数; $|B(l) \cup X_i(l)|$ 表示 $B(l)$ 与 $X_i(l)$ 中所有不同元素的个数。

粒子对应位置的更新规则可表示为

$$X_i(l+1) \leftarrow X_i(l) \oplus V_i(l) \quad (23)$$

式中, $X_i(l) \oplus V_i(l) = \tilde{X}_i(l) = (\tilde{x}_{i1}, \tilde{x}_{i2}, \dots, \tilde{x}_{id})$,特别的,

$$\tilde{x}_{ij} = \begin{cases} x_{ij}, & v_{ij} = 0 \\ R(x_{ij}, M), & v_{ij} = 1 \end{cases} \quad (24)$$

这里, $R(x_{ij}, M)$ 表示从集合 M 中随机选取节点代替 x_{ij} ,并且确保替换之后 X_i 中没有重复的节点。

2.3.3 适应度函数的选择

在虚假信息传播控制过程中,需要选择合适的适应度函数来评估粒子群优化迭代过程中全局最优位置。本研究选取LIE函数作为适应度函数,并从传播风险节点中选取具有若干个具有影响力的关键节点,使得LIE函数值最大化。图3给出具体改进的自适应加权DPSO流程。

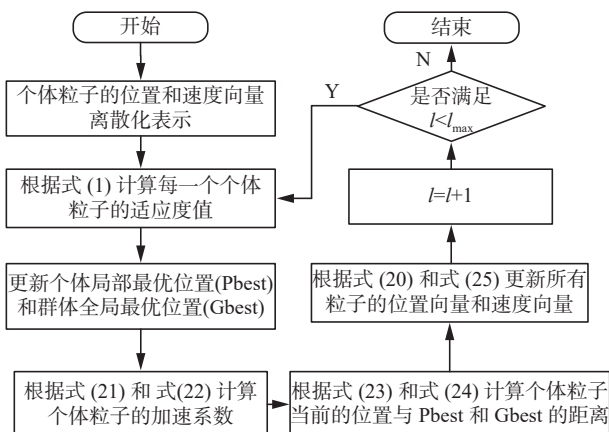


图 3 改进的自适应加权 DPSO 流程

Fig. 3 Improved adaptive weighted DPSO flowchart

2.4 虚假信息传播控制算法描述

虚假信息传播控制算法包括 2 个方面: 1) 通过用户传播虚假信息的行为维度、时间维度和内容维度特征, 实现不同用户节点风险的划分; 2) 通过改进的 DPSO 算法, 获取高风险节点集合中具有影响力的关键传播节点。虚假信息传播控制算法的具体描述如算法 2 所示。

3 试验设计与结果分析

3.1 试验数据

本研究选取在线社交网络晒科网(又名晒我的)(<http://www.shareteches.com>)作为试验研究平台^[32], 该平台包括网站平台和移动应用程序(Android 和 iOS)。用户通过晒科网 App 可以随时随地交流和分享前沿的科技话题和附近的科技信息。在晒科网服务器端, 通过数据埋点动态实时收集用户访问该平台时产生的社会情境 Socialsitu 元数据^[33]。目前关于社交网络虚假信息和谣言传播控制的相关领域研究, 研究人员主要是通过社交平台提供的 API (application programming interface) 接口或者通过采用数据埋点技术获取社交网络平台中相应的元数据。社会情境 Socialsitu 元数据已经在虚假信息传播分析^[34]、社交用户行为模式分析^[14]和恶意用户检测^[35]等方面得到广泛应用。表 1 给出该数据集的详细统计信息。

3.2 试验结果与分析

3.2.1 传播风险用户聚类个数对虚假信息控制效果的影响

为了探究不同聚类个数对应的虚假信息控制效果, 分别计算传播风险用户聚类个数 k 为 3、4、5、6、7 时对应的控制效果 LIE 值。

试验结果如图 4 所示, 随着聚类个数 k 的增加, 虚假信息在传播概率 $p=0.01$ 和 $p=0.05$ 时对应

传播控制效果 LIE 值不断减小。这是由于随着聚类个数 k 的增加, 用户节点被更加细粒度的划分为不同的风险等级, 并且同一个簇中用户节点在虚假信息传播模式上表现出更强的相似性。本研究选取 k 取值为 3 且 LIE 取得最优值时对应的用户节点集合作为高风险用户节点集合。

表 1 试验数据集的统计信息

Table 1 Statistics of the experimental dataset

统计名称	数量
Socialsitu 元数据	1 460 656
Socialsitu 六元组元数据	649 987
真实信息	36 610
虚假信息	10 449
用户数量	28 857
转发数量	31 940
点赞数量	24 196
评论数量	7 019




图 4 传播风险节点聚类个数对控制效果的影响

Fig. 4 Influence of the number of propagation risk node clusters on the control effect

3.2.2 不同离散粒子群优化算法的性能分析

为了证明本研究所提出的融合自适应加权策略 DPSO 算法的有效性, 选取标准的 DPSO 算法^[17]、增强的离散粒子群优化 (enhanced local discrete particle swarm optimization, ELDPPO) 算法^[18]、增强的局部搜索离散粒子群优化 (enhanced local search discrete particle swarm optimization, ELS-DPSO) 算法^[19]作为基线方法进行比较。由图 5(a) 和 (b) 分析得出, 随着控制驱动节点个数的增加, 传播控制效果 LIE 值也在不断增加。图 5(a) 表明本研究的算法相对于 DPSO、ELDPPO 和 ELS-DPSO 算法分别平均提高 10.76%、7.83% 和 4.05%。图 5(b) 表明本研究的算法相对于上述 3 种算法分别平均提高 8.91%、5.01% 和 2.45%。

3.2.3 不同控制驱动节点选取算法的试验结果对比分析

本研究选取改进的具有成本效益惰性前向选择 (CELF++) 算法^[9]、中介中心度 (betweenness

centrality, BC)算法^[36]、紧密中心度(closeness centrality, CC)算法^[37]、PageRank(PR)算法^[38]和模拟退火期望传播值(simulated annealing expected diffusion value, SAEDV)算法^[7]作为基线方法。





图5 当传播概率为 $p=0.01$ 和 $p=0.05$ 时, 4 种不同的 DPSO 算法的性能比较

Fig. 5 Performance comparison of three different DPSO algorithms when the propagation probability $p=0.01$ and $p=0.05$

由图6可以发现, 在传播概率 $p=0.01$ 和 $p=0.05$ 下, 本研究所提出算法优于基于中心度的启发式算法和贪心算法 CELF++。贪心算法 CELF++ 对应的试验结果仅次于本研究的算法, 基于中心度的启发式算法 BC 和 CC 对应的试验结果最不理想, 这是因为该类算法通常是根据网络拓扑结构特征, 选取前 s 个 BC 值或 CC 值最大的节点作为控制驱动节点。





图6 当传播概率为 $p=0.01$ 和 $p=0.05$ 时, 不同控制驱动节点选取算法的性能比较

Fig. 6 Performance comparison of different control driven node selection algorithms when the propagation probability $p=0.01$ and $p=0.05$

由图7可以发现, 在时间复杂度指标上, 本研究所提出的算法对应的运行时间优于贪心算法 CELF++ 和启发式算法 SAEDV, 但是与基于中心性的启发式算法相比, 本研究所提出的算法需要消耗更长的运行时间。因此, 本研究所提出的算法在计算虚假信息传播控制效果和运行时间上得到了很好的权衡。




图7 当传播概率 $p=0.05$ 时, 不同控制驱动节点选取算法的时间复杂度比较

Fig. 7 Time complexity comparison of different control driver node selection algorithms when the propagation probability $p=0.05$

4 结束语

本研究提出了一种融合用户传播风险和节点影响力分析的虚假信息传播控制方法 DDC-UP-RNI。该方法能够准确有效地识别社交网络中虚假信息传播的关键用户节点。社交平台管理者针对这些关键用户节点及时实施“禁言”“封号”等措施, 能够大大降低平台的控制成本, 从而达到有效控制虚假信息大规模传播的目的。未来, 将继续从复杂社会网络 and 智能控制理论的视角, 进一步探究跨平台虚假信息的传播控制方法。

参考文献:

- [1] CHOI D, OH H, CHUN Selin, et al. Preventing rumor spread with deep learning[J]. *Expert systems with applications*, 2022, 197: 116688.
- [2] ZHAO Zilong, ZHAO Jichang, SANO Y, et al. Fake news propagates differently from real news even at early stages of spreading[J]. *EPJ data science*, 2020, 9(1): 7.
- [3] VOSOUGHI S, ROY D, ARAL S. The spread of true and false news online[J]. *Science*, 2018, 359(6380): 1146–1151.
- [4] CHEN Weineng, TAN Dazhao, YANG Qiang, et al. Ant colony optimization for the control of pollutant spreading on social networks[J]. *IEEE transactions on cybernetics*, 2020, 50(9): 4053–4065.
- [5] 黄宏程, 赖礼城, 胡敏, 等. 基于严格可控理论的社交网络信息传播控制方法 [J]. *电子与信息学报*, 2018, 40(7): 1707–1714.
HUANG Hongcheng, LAI Licheng, HU Min, et al. Information propagation control method in social networks based on exact controllability theory[J]. *Journal of electronics & information technology*, 2018, 40(7): 1707–1714.
- [6] JIA Jianfeng, LIU Xuewei, ZHANG Yixin, et al. Rumor propagation controlling based on finding important nodes in complex network[J]. *Journal of industrial & management optimization*, 2020, 16(5): 2521–2529.
- [7] JIANG Qingye, SONG Guojie, CONG Gao, et al. Simulated annealing based influence maximization in social networks[C]//Proceedings of the Twenty-Fifth AAAI Conference on Artificial Intelligence. San Francisco: ACM, 2011: 127–132.
- [8] LESKOVEC J, KRAUSE A, GUESTRIN C, et al. Cost-effective outbreak detection in networks[C]//Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Jose: ACM, 2007: 420–429.
- [9] GOYAL A, LU Wei, LAKSHMANAN L V S. CELF++: optimizing the greedy algorithm for influence maximization in social networks[C]//Proceedings of the 20th International Conference Companion on World Wide Web. Hyderabad: ACM, 2011: 47–48.
- [10] LIU Huanli, MA Chuang, XIANG Bingbing, et al. Identifying multiple influential spreaders based on generalized closeness centrality[J]. *Physica A: statistical mechanics and its applications*, 2018, 492: 2237–2248.
- [11] LEV T, BEN-GAL I, SHMUELI E. Influence maximization through scheduled seeding in a real-world setting[J]. *IEEE transactions on computational social systems*, 2022, 9(2): 494–507.
- [12] SRINIVASAN S, DHINESH BABU L D. A bio-inspired defensive rumor confinement strategy in online social networks[J]. *Journal of organizational and end user computing*, 2021, 33(1): 47–70.
- [13] CHANG C K. Situation analytics—at the dawn of a new software engineering paradigm[J]. *Science China information sciences*, 2018, 61(5): 050101.
- [14] ZHANG Zhiyong, SUN Ranran, WANG Xiaoxue, et al. A situational analytic method for user behavior pattern in multimedia social networks[J]. *IEEE transactions on big data*, 2019, 5(4): 520–528.
- [15] 张志勇, 荆军昌, 李斐, 等. 人工智能视角下的在线社交网络虚假信息检测、传播与控制研究综述 [J]. *计算机学报*, 2021, 44(11): 2261–2282.
ZHANG Zhiyong, JING Junchang, LI Fei, et al. Survey on fake information detection, propagation and control in online social networks from the perspective of artificial intelligence[J]. *Chinese journal of computers*, 2021, 44(11): 2261–2282.
- [16] LIU Weibo, WANG Zidong, YUAN Yuan, et al. A novel sigmoid-function-based adaptive weighted particle swarm optimizer[J]. *IEEE transactions on cybernetics*, 2021, 51(2): 1085–1093.
- [17] GONG Maoguo, YAN Jianan, SHEN Bo, et al. Influence maximization in social networks based on discrete particle swarm optimization[J]. *Information sciences*, 2016, 367/368: 600–614.
- [18] TANG Jianxin, ZHANG Ruisheng, YAO Yabing, et al. Identification of top-k influential nodes based on enhanced discrete particle swarm optimization for influence maximization[J]. *Physica A: statistical mechanics and its applications*, 2019, 513: 477–496.
- [19] LIU Zhaoli, QIN Tao, SUN Qindong, et al. SIRQU: dynamic quarantine defense model for online rumor propagation control[J]. *IEEE transactions on computational social systems*, 2022, 9(6): 1703–1714.
- [20] ZHANG N, HUANG H, DUARTE M, et al. Risk analysis for rumor propagation in metropolises based on improved 8-state ICSAR model and dynamic personal activity trajectories[J]. *Physica A: statistical mechanics and its applications*, 2016, 451: 403–419.
- [21] 洪巍, 王晨雪, 吴林海, 等. 基于保护动机理论的安全网络谣言关注度影响因素研究 [J]. *系统工程理论与实践*, 2022, 42(11): 3121–3138.
HONG Wei, WANG Chenxue, WU Linhai, et al. Research on influencing factors of food safety Internet rumor attention based on protection motivation theory[J]. *Systems engineering-theory & practice*, 2022, 42(11): 3121–3138.

- [22] 杨洋洋, 谢雪梅. 网络谣言风险测度与治理路径研究[J]. 情报科学, 2021, 39(9): 170–177.
YANG Yangyang, XIE Xuemei. Research on risk measurement and governance path of Internet rumors[J]. Information science, 2021, 39(9): 170–177.
- [23] KEMPE D, KLEINBERG J, TARDOS É. Influential nodes in a diffusion model for social networks[M]// CAIRES L, ITALIANO G F, MONTEIRO L, et al. Automata, Languages and Programming. Berlin: Springer Berlin Heidelberg, 2005: 1127–1138.
- [24] TAHERINIA M, ESMAEILI M, MINAEI-BIDGOLI B. Optimizing CELF algorithm for influence maximization problem in social networks[J]. Journal of artificial intelligence and data mining, 2022, 10(1): 25–41.
- [25] XIAO Yunpeng, LI Jinghua, ZHU Yangfu, et al. User behavior prediction of social hotspots based on multimesage interaction and neural network[J]. IEEE transactions on computational social systems, 2020, 7(2): 536–545.
- [26] GHOSH R, SURACHAWALA T, LERMAN K. Entropy-based classification of ‘retweeting’ activity on twitter[EB/OL]. [2011–06–02][2020–01–01]. <http://arxiv.org/abs/1106.0346.pdf>.
- [27] FU Boyang, SUI Jie. Multi-modal affine fusion network for social media rumor detection[J]. PeerJ computer science, 2022, 8: e928.
- [28] XIAO Yunpeng, HUANG Zhen, LI Qian, et al. Diffusion pixelation: a game diffusion model of rumor & anti-rumor inspired by image restoration[J]. IEEE transactions on knowledge and data engineering, 2023, 35(5): 4682–4694.
- [29] KIM D, SEO D, CHO S, et al. Multi-co-training for document classification using various document representations: TF-IDF, LDA, and Doc2Vec[J]. Information sciences, 2019, 477: 15–29.
- [30] LIN Zhouhan, FENG Minwei, SANTOS C, et al. A structured self-attentive sentence Embedding[C]//ICLR’2017: Proceedings of the 5th International Conference on Learning Representations. Toulon: OpenReview, 2017.
- [31] LI Zhe, HUANG Xinyu. Identifying influential spreaders in complex networks by an improved gravity model[J]. Scientific reports, 2021, 11(1): 22194.
- [32] ZHANG Zhiyong, SUN Ranran, ZHAO Changwei, et al. CyVOD: a novel trinity multimedia social network scheme[J]. Multimedia tools and applications, 2017, 76(18): 18513–18529.
- [33] JING Junchang, ZHANG Zhiyong, CHOO K K R, et al. Inference of user desires to spread disinformation based on social situation analytics and group effect[J]. IEEE transactions on dependable and secure computing, 2023, 20(3): 1833–1848.
- [34] JING Junchang, LI Fei, SONG Bin, et al. Disinformation propagation trend analysis and identification based on social situation analytics and multilevel attention network[J]. IEEE transactions on computational social systems, 2023, 10(2): 507–522.
- [35] 卫新乐, 张志勇, 宋斌, 等. 基于纵向联邦学习的社交网络跨平台恶意用户检测方法[J]. 小型微型计算机系统, 2022, 43(7): 1541–1546.
WEI Xinle, ZHANG Zhiyong, SONG Bin, et al. Social networks cross-platform malicious user detection method based on vertical federated learning[J]. Journal of Chinese computer systems, 2022, 43(7): 1541–1546.
- [36] BRANDES U. On variants of shortest-path betweenness centrality and their generic computation[J]. Social networks, 2008, 30(2): 136–145.
- [37] FREEMAN L C. Centrality in social networks conceptual clarification[J]. Social networks, 1978, 1(3): 215–239.
- [38] BOLDI P, SANTINI M, VIGNA S. PageRank: functional dependencies[J]. ACM transactions on information systems, 2009, 27(4): 19.

作者简介:



荆军昌, 博士研究生, 中国计算机学会会员, 主要研究方向为多媒体内容安全、社会计算与社会智能、大数据分析。E-mail: jingjunchang2012@126.com。



张志勇, 教授, 博士生导师, 博士, CCF/CAAI/IEEE/ACM 高级会员, 主要研究方向为网络空间安全、复杂社会网络分析、人工智能。主持和参与国家自然科学基金项目 4 项、教育部重点项目 20 余项。出版学术专著 4 部、编著 2 部和译著 1 部, 发表学术论文 120 余篇。E-mail: xidianzzy@126.com。



宋斌, 讲师, 博士, 中国计算机学会会员, CAAI 高级会员, 主要研究方向为人工智能、图像处理、社交网络安全。主持和参与河南省科技攻关等省级课题 3 项, 出版学术专著 3 部, 发表学术论文 20 余篇。E-mail: songbin@haust.edu.cn。