

基于双向融合图网络的谣言检测方法

王梦园¹ 罗卓卿² 杨广浩³

WANG Mengyuan LUO Zhuoqing YANG Guanghao

摘要

社交媒体的指数级增长使其成为公众获取信息的主要渠道，但用户生成内容的激增引发虚假信息泛滥，不仅误导公众认知，更威胁社会稳定，因此高准确率谣言识别至关重要。现有谣言检测方法多基于内容、传播模式、路径及多源信息融合等维度开展研究，但常将传播路径与用户信息独立建模，存在特征融合不充分的缺陷。针对此问题，文章通过挖掘谣言传播过程与人际关系构建传播图，提取语义互动特征与用户行为模式以增强识别机制，并提出双向融合图网络谣言检测方法，通过构建涵盖源发节点-传播节点信息扩散路径、传播者-接收者交互传播路径的双路径融合表征框架，以此对传播信息进行建模，实现传播路径与用户交互模式的双向特征融合；同时，构建双向传播图以捕获扩散关联与交互关联特征，并借助可学习注意力权重完成多层特征的适应性融合，从而提升模型对传播拓扑特性的表征能力。

关键词

谣言检测；社会背景信息；多任务学习

doi: 10.3969/j.issn.1672-9528.2026.02.032

0 引言

随着社交媒体种类的不断丰富，信息的发布也随之变得较为简单，可以随时发表观点、分享各类资讯，从而导致信息源头变得极为多元且难以追溯。例如，每年都会出现诸如“日本排放核污水会导致中国食盐短缺”之类的谣言^[1]。这样的言论在网络的各个角落迅速扩散，通过不同的账号和群组在短时间内形成了一个复杂的传播网络。而且谣言利用人们的好奇心以及一些普遍关注的热点话题，使其看上去极具可信度，许多人在不经意间看到这样的信息后，信以为真，进而二次传播，使得谣言传播范围越来越大。

因此，许多关于谣言检测的研究由此产生，通过利用社交媒体环境下的谣言传播过程建模^[2]，其中包括各类谣言传播树^[3-4]及谣言传播图^[5]，但这些方法在利用传播树或者传播图来对数据进行处理时，会因无法体现谣言的多角度特征或在谣言扩散程度的深浅、传播方向的广度上，从而导致在特征提取上有一定的差距。因此，针对现有的谣言检测方法所遇到的问题，本文提出了一种全面运用谣言的传播信息、文本信息、用户信息等来进行谣言检测的方法，对传播结构特征、上下文感知语义特征加以融合实现异构特征的深度交互，以增强模型整体性能。

1 基于双向融合图网络的谣言检测方法

1.1 基于双向融合图网络的谣言检测方法

本研究提出基于双向融合图的神经网络，通过融合信息传播拓扑与社交关系特征实现检测性能优化。如图1所示，主要包含两大核心组件：双向融合图神经网络模型和谣言分类决策器。




图1 双融合图架构

首先，基于推文的传播依赖关系构建自上向下的信息扩散子图，如图1(a)上图所示；其次，依据用户社交图谱构建自底向上的关系交互子图，如图1(a)下图所示。

随后，构建基于双向融合图神经网络模型，对谣言的信息扩散子图与关系交互子图进行特征提取并融合，如图1(b)所示。

最后，使用谣言分类决策器对融合后的特征进行分层解析，如图1(c)所示。

1.2 双向图的构建与原理

在社交媒体信息传播过程中，原始发布者通过初始发帖触发信息扩散，首批传播者通过转发或评论行为参与初级传

1. 武昌职业学院 湖北武汉 430202
2. 武汉金山云信息技术有限公司 湖北武汉 430200
3. 国家电网湖北省电力有限公司超高压公司 湖北武汉 430000

播, 次级传播者则通过再次交互形成多层次传播网络。这种针对源帖子展开评论或者转发的信息传递流程, 以及用户间利用帖子实施的信息交互流程形成了极为显著的树形架构。

这种层级传播机制呈现出两个显著特征: 信息内容沿传播路径的纵向扩散、用户社交关系在交互过程中的横向延伸。基于此传播特性, 本研究提出双向图结构建模方法:

(1) 首先构建自顶向下的信息扩散子图, 定义边方向由父节点指向子节点, 通过节点聚合父代信息表征信息传播路径;

(2) 其次构建自底向上的关系交互子图, 定义边方向由子节点指向父节点, 通过节点聚合子代信息表征用户交互网络。详细的构建流程如图 2 所示, 图 2 (a) 是一个完整的传播事件图, 里面包含了谣言的源帖子, 转发评论, 以及用户信息等。源帖 1 和帖子 2~4 存在着转发关系, 帖子 5~7 对帖子 2 进行了转发, 帖子 8 也对帖子 3 进行转发, 由此构建了谣言的信息扩散子图, 如图 2 (b) 所示; 而其中用户 1 作为源帖 1 发布者, 用户 2 作为帖子 2 的创建者, 用户 3 作为帖子 3~4 的创建者与用户 1 之间的一次交互形成一级分支, 用户 4~6 分别作为帖子 5~7 的创建者与用户 2 之间的二次交互建立二级分支, 用户 7 作为帖子 8 的创建者与用户 2 的二次交互建立二级分支, 最终根据这些交互信息形成用户交互子图, 如图 2 (c) 所示。




图 2 双向融合图的构建流程图

1.3 基于双向融合图网络的特征提取与分类

本研究通过将整个社交网络结构转化为一个有向的图形结构, 先利用每个节点的信息扩散轨迹上的特性变化, 即用户信息的发布、更改及接收过程中的各个具体阶段; 后利用每一个参与者与其周围的参与者间的行为交互行为, 最后结合两种类型的关联方式来捕捉更为丰富的信息表征。

首先, 设传播事件图为 $\mathcal{G} = (\mathcal{V}, \mathcal{E}_D, \mathcal{E}_S)$, 其中 $\mathcal{E}_D$ 为谣言信息扩散边; $\mathcal{E}_S$ 为用户社交交互边。定义传播扩散邻接矩阵为 A_D , 其中 $A_D \in \{0, 1\}^{|\mathcal{V}_D| \times |\mathcal{V}_D|}$ 定义用户交互邻接矩阵为 A_S , D_D 、 D_S 分别为对应的度矩阵, 提取信息扩散子图特征的卷积层被定义为:

$$H_D^{(l)} = \sigma(\widehat{D}_D^{-1/2} A_D \widehat{D}_D^{-1/2} H_D^{(l-1)} W_D^{(l)}) \quad (1)$$

具体的计算步骤为:

$$\bar{A}_D = \widehat{D}_D^{-1/2} A_D \widehat{D}_D^{-1/2} \quad (2)$$

$$Z_D = \bar{A}_D H_D^{(l-1)} W_D^{(l)} \quad (3)$$

$$H_D^{(l)} = \sigma(Z_D) \quad (4)$$

式中: $H_D^{(l)}$ 为上一层传播图所有节点的特征矩阵; $\widehat{D}_D = D_D + I$ 为添加自环后的度矩阵; $W_D^{(l)} \in \mathbb{R}^{d \times d}$ 为可训练权重矩阵; σ 为 ReLU 激活函数。

用于提取用户的社交交互子图特征的卷积层被定义为:

$$H_S^{(l)} = \sigma(\widehat{D}_S^{-1/2} A_S \widehat{D}_S^{-1/2} H_S^{(l-1)} W_S^{(l)}) \quad (5)$$

具体的计算步骤为:

$$\bar{A}_S = \widehat{D}_S^{-1/2} A_S \widehat{D}_S^{-1/2} \quad (6)$$

$$Z_S = \bar{A}_S H_S^{(l-1)} W_S^{(l)} \quad (7)$$

$$H_S^{(l)} = \sigma(Z_S) \quad (8)$$

式中: $H_S^{(l)}$ 为上一层传播图所有节点的特征矩阵; $\widehat{D}_S = D_S + I$ 为添加自环后的度矩阵; $W_S^{(l)} \in \mathbb{R}^{d \times d}$ 为可训练权重矩阵。

将构建的信息扩散子图和用户的社交交互子图分别放入式 (1) 和 (5) 的卷积层中进行计算, 得到了两种子图的特征, 随后放入式 (9) 中进行级联融合:

$$H^{(l)} = \text{ReLU}([H_D^{(l)} \parallel H_S^{(l)}] W_F^{(l)}) \quad (9)$$

式中: $H_D^{(l)}$ 为信息扩散子图最终节点表征; $H_S^{(l)}$ 为用户的社交交互子图最终节点表征; $[\cdot \parallel \cdot]$ 为按拼接操作; ReLU 为非线性激活函数; $W_F^{(l)} \in \mathbb{R}^{2d \times d}$ 为融合权重矩阵, 经过如式 (9) 的计算得到了基于双向融合图特征表示 H , 其中 $H = \{H_0, H_1, \dots, H_i\}$, 然后将 H 放入谣言分类决策器中进行计算, 用公式表示为:

$$\hat{y} = \text{softmax}(\text{MLP}(H)) \quad (10)$$

2 相关实验及分析

2.1 数据集和实验参数设置

本实验所采用的数据集为 PHEME 数据集, 包含了诸多与事件相关的信息和标注。至于实验环境, 是在 Linux 操作系统下进行的, 硬件上使用了 NVIDIA 4080 显卡, 为模型训练提供强大的计算能力支撑, 而算法框架则是按照高效、灵活的 Pytorch 框架来进行模型的构建与训练。

2.2 对比方法

在本次对比实验中总计选取了 10 个对比试验, 其涵盖了 3 个极具代表性的经典模型以及 6 个近期测试的实验, 且相关参数的设定与原论文中模型的设定完全相同, 以此来切实保障实验的精确性与可信度。

DTC^[6]: 结合人工设计的特征, 利用信息可靠性作为检

测标准的决策树分类器方法。

RvNN^[7]: 通过递归神经网络对谣言事件文本内容以及网状传播结构予以建模, 而提取出高层表征的方式。

SVM-TS^[8]: 利用支持向量机 (SVM) 进行分类的方法, 通过监测和分析时间序列数据来自动识别网络环境中的谣言。

Bi-GCN^[4]: 基于 GNN 双向传播结构谣言检测模型。

RFC-AVG^[9]: 通过对图中所有节点的特征向量进行平均来输出传播向量, 且利用随机森林模型对该向量来分类。

RFC-PR^[10]: 该模型会学习一种嵌入向量, 依据网页排名来体现传播结构。然后, 训练一个随机森林分类器对这些向量进行分类。

GCAN^[8]: 一种基于 GNN 的模型, 其能够对谣言传播模式予以描述, 且运用双协同注意力机制来捕捉源文本、用户特征以及传播路径之间的关联。

UDGCN^[11]: 利用根源特征增强策略提升模型的性能。

STS-NN^[12]: 通过联合建模信息传播的空间与时间结构, 实现更细粒度的谣言检测模型。

2.3 实验分析

本研究在 PHEME (多平台社交媒体谣言数据集) 上进行验证, 对比实验选取 9 个代表性模型, 涵盖传统机器学习 (DTC、SVM-TS)、集成学习 (RFC-PR、RFC-AVG) 与图神经网络 (UDGCN、RvNN、STS-NN 等) 方法, 评估指标除常规 Accuracy 外, 重点考察 F_1 -score 以平衡类别不平衡问题。

表 1 PHEME 数据集实验结果

Method	ACC	PRE	REC	F_1
DTC	0.581	0.659	0.652	0.656
SVM-TS	0.640	0.639	0.621	0.640
RFC-AVG	0.793	0.698	0.770	0.637
UDGCN	0.805	0.752	0.673	0.708
RFC-PR	0.817	0.741	0.789	0.699
STS-NN	0.819	0.816	0.791	0.800
RvNN	0.825	0.765	0.772	0.760
GCAN	0.834	0.769	0.758	0.761
Bi-GCN	0.847	0.840	0.834	0.835
Ours	0.854	0.872	0.875	0.873

如表 1 在 PHEME 数据集上的实验结果所示, 本方法在关键指标上实现全面领先, 且本方法的准确性 Accuracy 达 85.4%, 较最优基线 Bi-GCN 提升了 0.7%, 证明了双向图结构能更完整捕捉传播特征, 而且 Precision 与 Recall 差值仅 0.3%, 显示本文的模型在减少误报与漏报间取得更好平衡,

而且相比单图模型方法 UDGCN, 本文的 F_1 -score 提升了 16.5%, 验证了信息扩散图与关系交互图互补的有效性; 并且与传统模型 RFC-AVG 相比较, 使其模型在 Accuracy 上达到了 79.3%, 但其 F_1 分数仅仅只有 63.7%, 暴露了单一传播特征建模的局限性, 而本方法通过分层特征解析, 能够在复杂传播场景中保持稳健性能。

3 结语

本文提出的双向融合图网络谣言检测方法, 从信息传播多视角挖掘交互关系, 借注意力机制调整特征权重, 增强模型对不同特征的适应性。其优势在于: 整合单侧扩散与人际交互, 提升信息感知分析维度; 改善算法局限, 捕捉关键信息以优化识别性能; 为深度学习改进谣言侦测模型提供启发, 助力相关应用发展及现实假信息处理。

参考文献:

[1] 商云嫻, 蔡国永, 刘庆华, 等. 基于主动学习的多模态谣言检测模型 [J]. 计算机科学, 2025, 52(12): 391-399.

[2] MA J, GAO W, MITRA P, et al. Detecting rumors from microblogs with recurrent neural networks [C]//proceedings of the 25th International Joint Conference on Artificial Intelligence. New York: ACM, 2016: 3818 - 3824.

[3] NASIR J A, KHAN O S, VARLAMIS I. Fake news detection: a hybrid CNN-RNN based deep learning approach [J]. International journal of information management data insights, 2021, 1(1): 100007.

[4] BIAN T, XIAO X, XU T Y, et al. Rumor detection on social media with bi-directional graph convolutional networks [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2020: 549-556.

[5] LU Y J, LI C T. GCAN: graph-aware co-attention networks for explainable fake news detection on social media [C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Brussels: ACL, 2020: 505-514.

[6] CASTILLO C, MENDOZA M, POBLETE B. Information credibility on Twitter [C]//Proceedings of the 20th International Conference on World Wide Web. New York: ACM, 2011: 675-684.

[7] MA J, GAO W, WONG K-F. Rumor detection on Twitter with tree-structured recursive neural networks [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. Brussels: ACL, 2018: 1980-1989.

基于多维岭化马氏距离算法的无人机通信安全

王一帆¹ 陈玲玲^{1*} 陈一凡¹

WANG Yifan CHEN Lingling CHEN Yifan

摘要

随着无人机互联网 (internet of drones, IoD) 在智慧城市等场景中的深度应用, 多源感知数据的准确性正面临严峻挑战。为此, 文章提出一种以最小化真实感知地面各部分占比结果与所得感知地面各部分占比结果之间均方误差的优化目标。为实现这一目标, 设计了一种多维岭化马氏距离 (multi-dimensional ridge mahalanobis distance, MDRMD) 算法, 该算法采用逐维建模策略, 分别计算各个无人机在不同特征维度上的马氏距离, 并通过聚合生成综合异常指标, 同时引入岭化方差, 以增强模型在高维、小样本条件下的稳定性。仿真结果表明, 该算法在无人机准确率控制方面显著优于传统马氏距离与 K-means 等常用方法, 具备良好的可扩展性与高效的部署效率。

关键词

无人机互联网; 异常数据识别; 岭化马氏距离; 多维特征融合

doi: 10.3969/j.issn.1672-9528.2026.02.033

0 引言

传统地面通信系统由于网络容量和覆盖范围的限制, 难以全面满足用户日益多样化的无线接入需求^[1]。在此背景下, 无人机通信技术凭借其高机动性、低延迟数据传输、灵活部署等优势迅速发展, 成为重要的补充解决方案^[2-4]。IoD 通过

无人机与地面控制站 (ground control station, GCS) 的协同工作, 为移动用户 (mobile user, MU) 提供包括交通监控以及灾害救援在内的多种服务。该系统利用无人机群采集图像、视频等感知数据并传输至 GCS 进行整合分析, 这种空对地通信模式在复杂环境中展现出更强的适应性和更广的覆盖范围, 显著提升了通信系统的整体性能。

然而, 该技术在实际应用中仍面临数据安全挑战: 一方

1. 吉林化工大学信息与控制工程学院 吉林吉林 132022

[8]MA J, GAO W, WEI Z Y, et al. Detect rumors using time series of social context information on microblogging websites [C]//CIKM'15: Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. New York: ACM, 2015: 1751-1754.

[9]VU D T, JUNG J J. Rumor detection by propagation embedding based on graph convolutional network[J]. International journal of computational intelligence systems, 2021, 14(1): 1053-1065.

[10]VU D-T, JUNG J J. Detecting emerging rumors by embedding propagation graphs [C]//Information Retrieval Technology: 15th Asia Information Retrieval Societies Conference, AIRS 2019, Hong Kong, China. New York: ACM, 2020: 173-184.

[11]CHEN J, LIU W Q, HUANG Z Z, et al. Universal deep GNNs: rethinking residual connection in GNNs from a path

decomposition perspective for preventing the over-smoothing [EB/OL]. (2022-05-30)[2025-12-30]. <https://doi.org/10.48550/arXiv.2205.15127>.

[12]HUANG Q, ZHOU C, WU J, et al. Deep spatial-temporal structure learning for rumor detection on Twitter [J]. Neural computing and applications, 2023, 35(18): 12995-13005.

【作者简介】

王梦园 (1999—), 女, 湖北随州人, 硕士研究生, 研究方向: 自然语言处理。

罗卓卿 (1999—), 男, 湖南娄底人, 硕士研究生, 工程师, 研究方向: 自然语言处理。

杨广浩 (1998—), 男, 湖北襄阳人, 硕士研究生, 工程师, 研究方向: 自然语言处理。

(收稿日期: 2025-07-13 修回日期: 2026-01-26)