

基于复杂网络技术的电商平台用户情感影响力传播研究

曹丹妮

上海工程技术大学管理学院, 上海

收稿日期: 2025年5月5日; 录用日期: 2025年5月19日; 发布日期: 2025年6月23日

摘要

随着互联网技术的飞速发展, 电商平台外卖服务已成为人们日常生活中不可或缺的一部分, 用户对于电商平台外卖服务情感态度则能够体现出其认知和判断。本文基于复杂网络技术, 对电商平台用户情感影响力的传播进行了深入研究。即通过构建MIGM节点影响力评价模型并使用真实数据集和肯德尔(Kendall)相关系数进行评估, 爬取用户转发、评论、点赞、节点影响力MIGM值数据构建权重评价指标, 采用卷积神经网络-长短期记忆网络(Convolutional Neural Networks-Long Short Term Memory, CNN-LSTM)对节点情感状态进行划分, 从而用于构建复杂网络模型以分析用户情感在复杂网络中的传播路径和模式。研究发现: 高影响力用户的情感观点具有更广泛的传播性, 且节点密度更为集中, 呈现更为显著的情绪“簇团状”结构, 中影响力用户则处于复杂网络边缘, 情感节点的网络分布相对发散。此外, 通过分析不同圈层用户的情感状态, 发现所构建的复杂网络中用户对电商平台商家的做法态度持多元化, 用户多聚焦于支持商家减少资源浪费的举措, 以及秉持关注企业的积极应对措施和信息公开的态度。

关键词

复杂网络技术, 电商平台, 用户影响力, CNN-LSTM模型

Research on the Dissemination of User Emotional Influence on E-Commerce Platforms Based on Complex Network Technology

Danni Cao

School of Management, Shanghai University of Engineering Science, Shanghai

Received: May 5th, 2025; accepted: May 19th, 2025; published: Jun. 23rd, 2025

文章引用: 曹丹妮. 基于复杂网络技术的电商平台用户情感影响力传播研究[J]. 电子商务评论, 2025, 14(6): 2242-2254.
DOI: 10.12677/ecl.2025.1461984

Abstract

With the rapid development of Internet technology, the food delivery service on e-commerce platforms has become an indispensable part of People's Daily lives. Users' emotional attitudes towards the food delivery service on e-commerce platforms can reflect their cognition and judgment. Based on complex network technology, this paper conducts an in-depth study on the dissemination of emotional influence of users on e-commerce platforms. That is, by constructing the MIGM node influence evaluation model and using the real data set and the Kendall correlation coefficient for assessment, the weight evaluation indicators are constructed by crawling the data of user forwarding, comments, likes, and node influence MIGM values. The Convolutional Neural Networks-Long Short Term Memory (CNN-LSTM) is adopted to divide the emotional states of nodes. Thus, it is used to construct complex network models to analyze the propagation paths and patterns of user emotions in complex networks. The research finds that the emotional viewpoints of highly influential users have wider spreadability, and the node density is more concentrated, presenting a more significant emotional "cluster-like" structure. In contrast, moderately influential users are at the edge of complex networks, and the network distribution of emotional nodes is relatively divergent. Furthermore, by analyzing the emotional states of users in different circles, it is found that in the constructed complex network, users' attitudes towards the practices of e-commerce platform merchants are diversified. Users mostly focus on measures to support merchants in reducing resource waste, as well as positive response measures and an attitude of information disclosure that pay attention to enterprises.

Keywords

Complex Network Technology, E-Commerce Platform, User Influence, CNN-LSTM Model

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

作为数字经济时代的重要民生工程，电商外卖服务通过技术赋能实现了服务效率的指数级提升，现已稳固占据城市居民日常消费链的核心环节。它极大地便利了消费者的生活，同时也为餐饮行业带来了前所未有的发展机遇[1][2]。然而，伴随着外卖服务的普及，一些突发事件的信息传播也日益频繁，如近年来发生的外卖空包事件的信息传播，这类信息在各大社交媒体平台上迅速扩散，引发了广泛的关注和讨论。在这些信息的传播过程中，用户的情感影响力起到了至关重要的作用[3]。用户对于事件的看法、态度以及情感倾向，不仅影响着信息的传播速度和范围，还深刻影响着其他用户对于该事件的认知和判断[4][5]。

用户情感影响力的传播是一个复杂且动态的过程，涉及到信息在复杂网络中的扩散、用户之间的互动以及情感态度的演变等多个方面[6]。在研究用户情感影响力上，复杂网络技术作为一种计算机方法，提供了一种有效的工具，可以用于描述和分析自然界中存在的大量复杂系统[7]。在电商平台外卖服务事件信息传播上，用户可以被视为网络中的节点，用户之间的关系(如关注、转发、点赞等)则可以被视为节点之间的连边[8]。通过构建复杂网络模型，可以更加直观地揭示用户情感影响力的传播路径和模式，为制定有效的信息传播策略提供理论支持[9][10]。因此，将用户情感影响力与复杂网络技术相结合，是深

入研究电商平台外卖服务中信息传播机制的必要途径。

有鉴于此,本文基于复杂网络技术,对电商平台用户情感影响力的传播进行了深入研究。以一起外卖空包事件为例,采用卷积神经网络-长短期记忆网络(Convolutional Neural Networks-Long Short Term Memory, CNN-LSTM)进行情感划分,并基于复杂网络技术构建高、中影响力层级,分析在信息传播过程中用户情感在复杂网络中的分布状态。本文的贡献和创新点主要体现在以下几个方面:首先,本文通过定义节点影响力评价指标 MIGM 模型,并针对评价模型进行三种不同数据集和肯德尔(Kendall)相关系数的验证,以及根据针对转发量、评论量、点赞量和 MIGM 值的系数分别进行赋值,定义连边权重指标,从而构建电商平台外卖服务的复杂网络模型,为用户情感影响力的传播研究提供了新的视角和方法;其次,本文采用 CNN-LSTM 模型进行情感分类,有效的识别用户在信息传播过程中的情感态度;最后,通过对不同影响力层级的用户进行划分并分别进行分析,揭示了用户情感影响力在信息传播中的层级结构和传播特征。研究成果为相关利益决策者深入理解电商平台外卖服务中的信息传播机制提供有力支持,也为相关领域的进一步研究奠定理论及实践基础。

2. 复杂网络拓扑结构建模

2.1. 复杂网络节点相关重要性指标

(1) 度中心性

节点的度中心性 DC_i 反映了社交网络中节点与其周围节点的交互程度,度中心性越大,意味着节点对外连接关系越强,在社交网络中就越重要。若以 d_i 表示社交拓扑网络 $G = \{V, E, M\}$ 中节点 v_i 的度值,则

$$DC_i = \frac{d_i}{N-1} \quad (1)$$

(2) K-shell 算法

K-shell 算法是一种用于识别复杂网络中节点重要性的算法,其基本思想是通过节点的连接性来评估其在网络中的影响力。K-shell 算法的核心在于 K 值的定义, K 值表示一个节点在网络中所处的层级。具体来说,首先需要计算每个节点的度数,即与该节点相连的边的数量。将网络中的节点分配到不同的 K-shell 层级中。K 值越高的节点通常被认为在网络中越重要。

(3) 节点的特征向量中心性

特征向量中心性认为节点重要性取决于邻居节点数量和其重要性二者的综合指标。EC 算法是在 DC 算法的基础上,考虑近邻节点的重要度对其进行加权,记 b_i 为节点 v_i 的重要性度量值,则:

$$EC(i) = x_i = c \sum_{j=1}^n a_{ij} b_j \quad (2)$$

其中, c 是常数,对于含有 n 个节点的社交网络,记 $x = [x_1, x_2, x_3, \dots, x_n]^T$, 是节点 x_i 的重要性度量, a_{ij} 是邻接矩阵 A 中的元素,多次迭代达到稳态后可以改写为:

$$x = cAx \quad (3)$$

式(3)中 x 是矩阵 A 的特征值 c^{-1} 所对应的特征向量,在对社交网络中节点进行计算时将 x 除以矩阵 A 的特征值 λ , 即可以得到 $x = \lambda^{-1}Ax$, 于是 $c = \lambda^{-1}$ 。

2.2. 融入多元指标交叉的引力模型

就个体节点而言,度值、k-核心值和特征向量中心性值较大的节点影响力更大。此外,节点往往对于邻居节点的影响力更大。据此,将节点的度值、k-核值和特征向量中心性值之和作为节点的质量,将两个

节点之间的最短距离作为节点之间的距离，度值、k-核心值和特征向量中心性值较大的节点影响力分别记为 $k(i)$ 、 $k_s(i)$ 和 $x(i)$ 。则节点的影响力可以被估计为：

$$\text{MIGM}(i) = \sum_{d(i,j) \leq R, j \neq i} \frac{(k(i) + k_s(i) + x(i))(k(j) + k_s(j) + x(j))}{d^2(i, j)} \quad (4)$$

该模型基于引力模型[11]，考虑到复杂网络中节点多元特征，以及节点与节点之间情绪“交叉传染”效应，构建一个新的模型，因此称为多元交叉引力模型(MIGM)。由于这四个指标不是一个数量级，需要进行归一化，可改写为：

$$\text{MIGM}(i) = \sum_{d(i,j) \leq R, j \neq i} \frac{\left(\frac{k(i)}{k_{\max}} + \frac{k_s(i)}{k_{s\max}} + \frac{x(i)}{x_{\max}} \right) \left(\frac{k(j)}{k_{\max}} + \frac{k_s(j)}{k_{s\max}} + \frac{x(j)}{x_{\max}} \right)}{d^2(i, j)} \quad (5)$$

式(5)中 $k_{\max}$ 、 $k_{s\max}$ 、 $x_{\max}$ 分别表示度的最大值、k-核的最大值、特征向量中心性的最大值。

由于 k-核层指数的值空间最小，归一化 k-核层指数结果仍明显大于另外两个指数。因此，有必要降低 k-核指数的影响。给定一个指标，由于网络的无标度特性，大多数节点指标值都比较小。在本文的模型中，度中心性和特征向量中心性的值空间明显大于 k-核指数。鉴于此，可以通过降低 k-核指数的影响：

$$\alpha = \frac{\max \left(\frac{k_{\text{mid}}}{k_{\max}}, \frac{x_{\text{mid}}}{x_{\max}} \right)}{\frac{k_{s\text{mid}}}{k_{s\max}}} \quad (6)$$

式(6)中 k_{mid} 、 $k_{s\text{mid}}$ 、 x_{mid} 分别表示度值、k-核值、特征向量中心性的中位数。其中， $\left(\frac{k_{\text{mid}}}{k_{\max}}, \frac{x_{\text{mid}}}{x_{\max}} \right)$ 取的最大值是为了防止 k-核指数的作用被过度削弱。

在复杂网络中，相同情绪的节点往往会形成情感认同群体，不同节点与节点及不同的群体与群体情绪之间会形成“交叉传染”效应。

假设一个节点对另一个节点的影响能力与其位置有关，则位于网络中心的节点会高于位于外部的节点影响力。节点情绪传染能力越强，情绪传染概率就越大，节点影响力也就越强，群体内节点情绪传染概率与影响力成正比。鉴于此，可以对节点 i 对节点的吸引系数定义为 C_{ij} ：

$$C_{ij} = e^{\frac{k_s(i) - k_s(j)}{k_{s\max} - k_{s\min}}} \quad (7)$$

最后，MIGM(i)改写为：

$$\text{MIGM}(i) = e^{\frac{k_s(i) - k_s(j)}{k_{s\max} - k_{s\min}}} \sum_{d(i,j) \leq R, j \neq i} \frac{\left(\frac{k(i)}{k_{\max}} + \frac{k_s(i)}{k_{s\max}} + \frac{x(i)}{x_{\max}} \right) \left(\frac{k(j)}{k_{\max}} + \frac{k_s(j)}{k_{s\max}} + \frac{x(j)}{x_{\max}} \right)}{d^2(i, j)} \quad (8)$$

2.3. 复杂网络边权重指标

复杂网络的构建首先需要对加权图(Weighted Graph)进行建模。该模型以用户为节点集合 $V = \{u_1, u_2, \dots, u_n\}$ ，以社交关系交互为边集合 E ，其中定向边 e_{ij} 从节点 u_i 到 u_j ，表征 u_i 对 u_j 的影响力作用路径。权重集合 W 通过边权重 $w_{ij} \in W$ 量化交互强度，其数值越大表明节点间的信息传播能力越强。

权重的构建综合考量用户间的多维交互行为特征：当用户 u_i 对用户 u_j 产生社交平台行为(包括但不限于转发、评论、点赞)时，参考文献[12]对于边的权重进行定义，权重 w_{ij} 由标准化处理后的交互频率指标

共同决定。具体而言，定义如下：

$$w_{ij} = \alpha \frac{R_{ij}}{R_{max}} + \varepsilon \frac{MIGM_i}{MIGM_{max}} + \beta \frac{C_{ij}}{C_{max}} + \gamma \frac{L_{ij}}{L_{max}} \quad (9)$$

其中 R_{ij} 表示 u_i 对 u_j 内容的转发量, C_{ij} 为评论量, L_{ij} 为点赞量, $MIGM_i$ 为节点 i 影响力值, α 、 β 、 γ 、 ε 分别为各行为类型的权重系数(满足 $\alpha + \beta + \gamma + \varepsilon = 1$)。同时, 为了消除量纲差异, 采用 Min-Max 归一化, R_{max} , C_{max} , L_{max} 是数据集中转发、评论、点赞次数的全局最大值。该指标设计体现了不同互动行为的影响力差异: 转发(R_{ij})能够直接扩大信息传播范围, 且用户的转发行为往往会携带评论, 同时能够将情绪传播到自己的好友圈及粉丝圈, 相较于评论和点赞行为而言, 更具备主动性和传播性, 因此赋予高系数 α , 其中 $\alpha = 0.35$; $MIGM$ 为节点影响力值, 用于反应节点重要性, 对于评价节点影响力大小至关重要, 因此赋予次高系数 ε , 其中 $\varepsilon = 0.30$; 评论(C_{ij})反映深度互动, 赋予较高系数 β , 其中 $\beta = 0.21$; 点赞(L_{ij})作为轻度认可行为, 赋予基础系数 γ , 其中 $\gamma = 0.14$ 。通过这种多维度量方式, 所构建的权重集合 W 能更精准地表征复杂网络中非对称的交互强度与传播势能。

3. 用于构建复杂网络的 MIGM 模型评价分析

3.1. 实验数据集与统计特征

实验选取了 3 个不同领域的真实数据集用于评估所构建的 MIGM 模型的表现, 这 3 个数据集分别是 p2p_Gnutella、GrQc 和 Sex, 数据整理来源于文献中的开源数据[13]。其中 P2P_Gnutella 代表的是一种在 P2P(点对点)网络环境中形成的数据集, Gnutella 是一种文件共享网络, P2P_Gnutella 数据集在研究 P2P 网络的拓扑结构、性能分析等方面有重要的应用。GrQc 数据集(General Relativity and Quantum Cosmology)是一个由阿尔诺·阿尔维(Arxiv)提供的开放获取数据集, 其数据特征包含高维非线性关系, 这与社交网络中用户影响力的传播机制(如信息扩散的指数衰减、关键节点的级联效应)高度契合。Sex 数据集是在一个公开可见的公共在线论坛中评估异性恋男性(性买家)与女性(性卖家)的性接触关系网所获得的数据[14]。

数据的结构特征如表 1 所示。其中 N 表示复杂网络中所有节点数, M 表示节点的累计连边数, 也就是关系数。 $\langle k \rangle$ 是指平均度(Average Degree)用于描述复杂网络中节点的连接情况, 表示网络中所有节点度的平均值, 可以用来评估网络的连通性和信息传播的效率。平均度的计算公式为:

$$\text{平均度} = \frac{2M}{N} \quad (10)$$

较高的平均度意味着网络中的节点通常有较多的连接, 表明网络密集性较高, 人们之间的互动性频繁, 形成了紧密的社交圈。 $\langle d \rangle$ 表示复杂网络中的平均距离, 是指网络中任意两个节点之间的最短路径长度的平均值。平均距离可以反映网络的连通性。较短的平均距离意味着网络中节点之间的连接更为紧密, 信息能够更快地在网络中传播。 C 是指复杂网络中的平均集聚系数, 平均集聚系数(Average Clustering Coefficient)是一个用来衡量网络中节点聚集程度的指标, 反映了网络中相邻节点之间相互连接的可能性。设节点 i 的邻居节点数量为 k_i , 节点 i 的邻居之间实际存在的边数为 M_i , 则节点的局部集聚系数 C_i 可以用以下公式表示:

$$C_i = \frac{2E_i}{k_i(k_i - 1)} \quad (11)$$

其中 $k_i(k_i - 1)$ 是节点 i 的邻居之间可能存在的最大边数。取所有节点的局部集聚系数的平均值, 得到平均集聚系数:

$$C = \frac{1}{N} \sum_{i=1}^N C_i \quad (12)$$

r 表示关联系数(Assortativity Coefficient), 是用来衡量网络中节点属性之间相似性的一种指标, 它描述了网络中节点连接的倾向性, 反应了相似节点之间是否更可能相互连接, 关联系数通常用以下公式计算:

$$r = \frac{e_{yy} - e_{yx}}{e_{yy} + e_{yx} - 2e_{xx}} \quad (13)$$

其中, e_{yy} 表示连接两个同类节点之间的边的比例, e_{yx} 表示连接一个高连接度节点和一个低连接度节点之间的边的比例, e_{xx} 表示连接两个低连接度节点之间的边的比例。关联系数的取值范围在-1 到 1 之间, 正值表明网络倾向于将相似的节点连接在一起(同类连接), 0 表示没有明显的相似性趋势, 连接是随机的, 负值表明网络倾向于将不同类型的节点连接在一起。

H 表示度异质性指数它反映了网络中节点的连接度(即每个节点的邻居数量)之间的差异性, 可以通过度数的标准差与均值的比率来表示。传播阈值 β 用于描述信息或行为在网络中传播的临界条件, 达到某个临界值后, 信息或行为开始扩散。在所构建的 MIGM 网络模型中, 这一阈值取决于网络的结构特性, 即节点的平均度和度的分布。计算传播阈值首先要遍历网络中的所有节点, 求和其度数(即与该节点相连的边的数量), 然后除以节点的总数 N 。即:

$$k = \frac{1}{N} \sum_i G.degree(i) \quad (14)$$

然后计算度的平均值 k_2 , 同样遍历所有节点, 求每个节点度数的平方, 计算其平均值。

$$k_2 = \frac{1}{N} \sum_i G.degree(i)^2 \quad (15)$$

最后计算出传播阈值 β 为:

$$\beta_c = \frac{k}{k_2 - k} \quad (16)$$

最后, 通过编写并运行 Python 代码, 计算得到三个数据集的网络统计特征如表 1 所示:

Table 1. Statistical characteristics of the network

表 1. 网络的统计特征

Networks	N	M	$\langle k \rangle$	$\langle d \rangle$	C	r	H	β
p2p_Gnutella	6299	20776	6.5967	4.6430	0.0109	0.0355	0.5240	0.0600
GrQc	4158	13422	4.4560	6.0493	0.5568	0.6392	0.5430	0.0589
Sex	15810	38540	4.8754	5.7846	0.0000	-0.1145	5.8276	0.0365

3.2. MIGM 模型评价分析

为了评价引力模型 MIGM 对于复杂网络中不同关键节点重要性评估性能, 本文借助经典的传染病 SIR 模型[15]对节点的传播扩散进行仿真实验, 对于实验取 100 次的平均结果作为节点的真实影响力。并使用肯德尔(Kendall)相关系数测试 MIGM 模型评估得出的排序结果与 SIR 模型排序结果的相关性。计算 Kendall 相关系数 t 。其中, t 值越大, MIGM 模型评估节点影响力准确率越高。

通过与 GC [16]、DC、KS、EC、MCGM [13]、KSGC [17]进行比对的排序结果, 得到在不同传播率下与真实影响力排序结果之间的 Kendall 相关系数, 实验的结果如图 1 所示。

其中, MCGM 模型计算公式如下:

$$\text{MCGM}(i) = \sum_{d(i,j) \leq R, j \neq i} \frac{\left(\frac{k(i)}{k_{\max}} + \frac{\alpha k_s(i)}{k_{s\max}} + \frac{x(i)}{x_{\max}} \right) \left(\frac{k(j)}{k_{\max}} + \frac{\alpha k_s(j)}{k_{s\max}} + \frac{x(j)}{x_{\max}} \right)}{d^2(i,j)} \quad (17)$$

KSGC 模型的计算公式如下:

$$\text{KSGC}(i) = \sum_{d_{ij} \leq 0.5} c_{ij} \frac{k_i \cdot k_j}{d_{ij}^2} \quad (18)$$

图 1 中横坐标取值为传播阈值。当传播阈值越大, MIGM 模型的 Kendall 系数要高于其他方法, 当传播阈值越小, MIGM 模型的表现则低于其他方法。其原因是, 传播率较小时, 信息传播空间往往较为局限, 节点影响力主要由度值决定, 传播率提高, 信息传播空间较大时, MIGM 的优越性则体现出来。在真实的复杂网络中, 由于信息技术的高速发展, 舆情信息传播速度和传播广度相较于之前呈现出几何式的增长, 传播率高度增长更为符合真实的复杂网络情况。




Figure 1. Results of Kendall coefficient of MIGM model on three data sets

图 1. MIGM 模型的 Kendall 系数在三种数据集上的结果

4. 基于复杂网络技术的用户影响力分析

4.1. 数据爬取

信息传播的过程中往往会夹杂着大量的情感内容，而突发事件的信息传播在情感视角上由于广受用户的讨论和关注，往往更能够具备代表性。根据新浪新闻和南方日报官方微博账号的权威报道以及微博智搜的结果显示，外卖空包事件的相关信息一经发布，引发多家官媒争相报道，一度位居微博、抖音等各大平台榜首，相关话题的电商直播量也随之飙升。因此，本文通过关键词搜索相关事件的博文信息作为数据来源，基于复杂网络技术探究电商平台上信息传播过程中用户情感影响力表现。

在数据爬取上，首先，采用八爪鱼采集器中的高级筛选项，选取一起外卖空包事件作为关键词，通过八爪鱼采集器进行时间定位以确认该事件第一发布时间，然后将八爪鱼采集器高级检索中的时间范围调整为第一发布时间的当日凌晨 0 点至往后递延一个月的凌晨 1 点作为时间周期，以便获得初始博文的 URL。然后将筛选后生成的初始 URL 导入 Python 中，通过编写代码，生成以每小时为周期的 2500 条 URL，采用八爪鱼采集器循环爬取，累计爬取到所发布的原创微博数量 2549 条，爬取数据内容包括转发量、转发行为中的文本内容、评论量和点赞量。然后通过筛选出转发量大于 0 的博文，整理出对应的 URL 和转发者 URL。通过对于转发者 URL 进行爬取，爬取内容包含发布者 id、转发者 id、微博转发量、微博评论量和微博点赞量在内的数据累计 3567 条。

4.2. CNN-LSTM 模型情感分类

传统模型在情感分类上存在一定的局限性，尤其是在处理复杂情感和反讽等情况下准确率不高。其中，朴素贝叶斯(Naive Bayes model)基于概率统计，假设特征独立，计算简单但效果有限，尤其在处理复杂文本时误差较大[18]。循环神经网络(RNN)能够处理序列数据，但存在梯度消失问题，难以捕捉长距离依赖的缺点，比如长句子中的情感变化可能无法有效传递[19]。LSTM (Long Short Term Memory)作为 RNN 的改进，通过门控机制解决梯度问题，虽能捕捉序列依赖，但对局部语义模式(如短语、情感词组合)敏感度较低，可能丢失局部关键特征(如否定词 + 形容词的组合) [20]。而 CNN-LSTM (Convolutional Neural Networks-Long Short Term Memory)模型与前三者相比，CNN 通过多尺寸卷积核提取局部语义模式，弥补 LSTM 对细粒度特征的忽视，其中，CNN 提取的局部特征经池化后输入 LSTM，形成从局部到全局的层级特征表示，能够显著提升复杂语义理解能力[21]。四类模型中的核心原理、特征提取方式、长文本处理、复杂语义建模、计算效率、典型应用场景对比分析如表 2 所示。

有鉴于此，本文选取 CNN-LSTM 模型作为情感分类的方法，使用 Python3.11 版本作为代码编写工具。在数据预处理上，实验采用爬取的转发文本内容作为数据集，通过 Unicode 编码规范化处理过滤非汉字字符，运用 jieba 分词工具进行文本切分，并结合自定义停用词表消除语气助词干扰。文本数据经 Tokenizer 工具转化为词索引序列后，通过截断填充操作统一为长度 100 的规范化输入矩阵，标签信息则通过字典映射与 one-hot 编码完成向量化表征。

模型架构设计方面，构建了嵌入层 - 卷积神经网络 - 循环神经网络的多级处理模块，其中嵌入层将离散词索引映射为 128 维连续向量空间，双层一维卷积层通过最大池化操作提取局部文本特征，128 单元 LSTM 层进一步建模长距离语义依赖关系，最终经全连接层和 Softmax 函数输出类别概率分布。

在模型训练阶段，采用 Adam 优化器配合交叉熵损失函数进行参数更新，批量训练规模设置为 128，通过早停机制动态监控验证集损失以控制训练周期。评估环节通过测试集计算准确率、和 F1 值(宏观平均)指标以验证模型的可行性。最终得到的准确率为 90%，F1 值为 0.88，验证结果表明模型表现优秀，可以将其情感分类结果用作电商平台用户情感影响力分析。

Table 2. Comparison framework table of four groups of models
表 2. 四组模型对比框架表

模型	Naive Bayes model [22]	RNN [23]	LSTM [24]	CNN-LSTM [25]
核心原理	基于概率统计，假设特征独立，通过贝叶斯定理计算类别概率	基于循环结构传递隐藏状态，捕捉序列依赖	引入门控机制(遗忘/输入/输出门)和细胞状态，缓解梯度消失问题	CNN 提取局部特征 + LSTM 建模时序关系，形成多层次特征表示
特征提取方式	词袋模型(Bag-of-Words)，忽略词序和上下文	仅依赖隐藏状态传递全局信息	通过门控机制选择性保留关键历史信息	CNN 卷积核提取 n-gram 局部特征 + LSTM 整合时序依赖
长文本处理	无法处理长文本(特征稀疏性严重)	易丢失长距离依赖(梯度消失)	显著缓解梯度问题，但长文本计算效率较低	CNN 压缩冗余信息 + LSTM 专注关键依赖，平衡效率与精度
复杂语义建模	无法捕捉否定词、转折词等复杂语义组合	对复杂句式(如双重否定)处理能力弱	通过门控机制部分解决复杂语义问题	CNN 捕获局部语义模式 + LSTM 整合全局情感逻辑
计算效率	最高(线性复杂度)	中等(时间步线性复杂度)	较低(门控机制增加计算量)	较高(CNN 卷积与 LSTM 并行计算)
典型应用场景	短文本快速分类(如垃圾邮件检测)	短序列任务(如字符级生成)	中长文本情感分析(如影评)	复杂语义长文本(如用户评论)

4.3. 不同影响力层级分析

微博平台的用户在对于某一博主的观点表达出强烈认同或者反对的情绪时，通常会表现出更为积极主动的行为，发布频率和号召力显著提升，在社交网络中表现为更强的影响力，从而成为平台中的“意见领袖”。因此，根据发布者和转发者之间的网络关系，对于其中的用户情感影响力 MIGM 值进行等级划分，划分成高和中不同的影响力层级，得到的高、中影响力层级分布部分数据结果以及对应的用户 ID、转发量、评论量、点赞量、MIGM 节点评价价值、加权重计算结果和对应的层级大小如表 3 所示。高、中影响力用户累计 103 条，由于数据量过多，因此仅截取部分数据展示。低影响力层由于没有转发量，多数为普通用户，且其转发、发布行为主要受到高、中影响力层用户的情感传染影响，所以不进行展示。

Table 3. User influence level classification and feature analysis
表 3. 用户影响力层级大小划分及特征分析

用户名称	转发量	评论量	点赞量	MIGM 节点评价价值	加权重计算结果	层级大小
蹦蹦跳跳的阿龙	1613	1194	40,279	0.016518	8.57	高
梨视频	610	1385	53,742	0.014952	7.12	高
唯一纯白的茉莉花儿	469	1554	30,446	0.013841	6.11	高
手残小编	323	25	1208	0.012124	1.82	高
章佳明	287	385	787	0.011332	2.29	高
新浪新闻	263	632	5739	0.009937	2.75	高
江卓尔_大号	245	389	4119	0.009764	2.20	高
佳欣财经	221	1	517	0.009567	1.31	高
搜狐千里眼	191	1710	15,762	0.008529	4.75	中
以史为鉴 V	179	32	1550	0.007952	1.18	中

续表

八酱日常	171	365	6533	0.007623	1.91	中
观察者网	165	646	13,772	0.007164	2.64	中
封面新闻	164	527	6517	0.007089	2.14	中
南风窗	164	433	6360	0.007086	1.96	中
小满	161	224	885	0.006966	1.37	中
红星新闻	150	847	7468	0.006873	2.69	中
兔玩游戏	49	240	2089	0.004312	0.97	中
晓川杂谈	49	77	926	0.004141	0.63	中
游戏圈资讯君	48	139	1612	0.004098	0.76	中
绝色少年神妙汉	46	18	562	0.004077	0.50	中
风闻社区	44	356	3057	0.004064	1.18	中
连锋医生	44	190	990	0.004032	0.81	中
财经网	43	105	630	0.003977	0.64	中
北京婚姻家事律师张丽珍	42	149	1033	0.003897	0.72	中

通过对于爬取的全部转发者影响力值进行分类,得到的统计结果如表 2 所示。当 MIGM 值大于 0.009 时,该用户为高影响力节点,占高、中影响力层的比重 10%,当 MIGM 值介于 0~0.009 之间时,该用户为中影响力层,占高、中影响力层的比重 90%,当 MIGM 值为 0 时,该用户为低影响力层,其发布的信息不具备传播性。通过粉丝量、V 指数以及博文阅读数及转发量进行分析,发现高、中影响力用户多数为各个领域的大 V,以其拥有较高粉丝量、互动量和 V 指数,所发布的情感观点往往能够产生更大范围的转发量,从而使得该类事件的爆发在复杂网络中得以更广泛维度的传播。

由于高影响力用户往往能够以其较高的粉丝量、互动量以及所在领域的 V 指数对于其他用户产生较高的辐射,因此,本文进一步分析高影响力在复杂网络中的情感传播分布。在情感划分上,采用 CNN-LTSM 模型对于每条发布博文文本、转发者转发文本的包含的情感态度进行分类,划分为支持者和反对者,用于评价不同层级影响力节点的情感传播状态。其中的支持者节点的情感设置成蓝色和黄色,反对者的情感标记为红色,将高影响力层级包含转发者 id、发布者 id 以及情感标记色彩的结果导入 Gephi 软件中,绘制出高、中影响力层级包含发布者及转发者情感态度及情绪传染分布的网络特征图分别如图 2 和图 3 所示。




Figure 2. Distribution of emotional tendency of “supporters” and “opponents” of high influence level
图 2. 高影响力层级“支持者”和“反对者”情感倾向分布图

根据图 2 可以得出,对于不同颜色节点的分布以及群状结构中不同节点的情感传播趋势,以及根据对于不同情感态度的博文内容进行分析,发现蓝色节点的这类人群占比 36.71%,他们痛斥该类事件的发生,觉得这样做浪费了公共资源,给社会治安也造成了严重的困扰和巨大的压力,电商平台商家送空包外卖恰好可以避免资源浪费的问题,并在一定程度上缓解了垃圾清除的压力,因此支持电商平台商家送空包的行为;而黄色群体占比 30.65%,这类群体更多的关注此次事件发生后,商家能够积极解决相关人员,并做到了信息公开透明,奖惩有力,他们能够理性看待此次事件,同时呼吁政府及公众能够将关注更多给到事件调查本身;红色节点的这类群体持消极反对态度,这类群体认为外卖空包反应了不良商家从中谋取私利,商家的做法“令人寒心”。




Figure 3. Distribution of emotional tendency of “supporters” and “opponents” of medium influence level
图 3. 中影响力层级“支持者”和“反对者”情感倾向分布图

根据图 3 可知,相较于高影响力节点,中影响力层的节点大多处于复杂网络中的边缘分布状态,网络“群簇状”结构相较于高影响力层的节点分布较为发散。就情感状态而言,大部分中层影响力的博主大多以新闻风格为主。其中一部分博主题材更多的倾向于报道顾客的该行为带来的公共资源浪费等不良影响,另一部分博主倾向于报道该事件发生后,各个电商平台名牌企业采取的积极的补救措施,只有少部分博主出现较为强烈的情感色彩指责该商家的该类行为。中影响力层的用户情感态度对于其转发者用户而言 40.96%的中影响力圈层中的转发者用户谴责电商平台商家送空包外卖的服务行为。此外,32.87%的用户认为该事件的发生应该是店家的错,以及认为企业的危机处理措施较为及时且奖惩有力,同时还给到企业品牌的形象带来一定的正面宣传效果,剩下的用户则认为该事件商家的反应确实能够减少粮食的浪费和对于城市街道的污染,认为商家面对这类事件就应该抵制资源浪费行为。

对于外卖空包事件的发生,公众对于电商平台商家的做法并没有呈现出一边倒的情况,相反,大部分公众对于商家的做法是包容且理性的。原因有两点,首先是很多公众认为外卖空包可以减少资源的浪费,将资源给到真正需要的人,且外卖的腐烂和堆放反而对于公共卫生带来巨大的挑战。其次,当事企业均采取积极响应和奖惩措施,并发布官方声明,做到了及时性、奖惩有力和信息公开透明。这一举措不仅很好的化解了由于电商平台外卖服务事件负面信息的进一步传播,还产生了正面的广告效应,有利于公司品牌形象和企业口碑的树立。此外,也有较少一部分公众持负面态度,认为在此次事件中,商家存在欺骗消费者的行为,认为这些商家可以拒绝接单从而避免资源浪费问题。

5. 本文小结

本研究基于复杂网络技术,通过关键词搜索博文作为实证数据来源,首先通过选取评价复杂网络的相关重要性指标进行归一化处理,引入吸引系数 C_{ij} ,构建多元交叉引力模型 MIGM,并借助经典的传染病 SIR 模型对节点的传播扩散进行仿真实验,验证所构建模型的可行性。考虑到用户转发、评论、点赞等交互行为,融入包含转发量、评论量、点赞量和用户影响力值在内的指标并分别赋予权重系数,构建复杂网络的权重评价指标。然后通过对比四种用于文本内容情感分类的模型,选取 CNN-LSTM 模型用于复杂网络中节点情感状态的分类。最后,将节点影响力值、连边权重指标计算结果和情感分类结果用于构建复杂网络,并根据所计算的 MIGM 值对不同影响力层级进行划分。

研究发现:首先,在针对电商外卖平台的信息传播上,高影响力用户由于在社交网络中拥有较高的粉丝量、阅读量和权威身份认证,其观点往往会引发大量其他用户的交互行为,扮演着平台中“意见领袖”的作用。通过分析复杂网络中高影响力节点的节点影响力值和权重大小,以及其在所构建网络中的分布状态,发现高影响力用户往往在所属的圈层中拥有较高的度值和更大的权重,其引发的情感传播在所构建的复杂网络中也易吸引其他用户的聚拢,从而在网络分布中呈现密集的“簇团状”结构,这些因素能够更进一步主导高影响力用户在电商外卖平台上其他用户的舆论走向。其次,高影响力用户对于其他用户表现出较高的情感影响力,其情感传播力度能够引发更为广泛的“情感共鸣”,从而引发新一轮的情感分化和用户更深度情感探讨,构成新一轮的情感子圈层,如此形成广泛的复杂网络圈层。此外,中低影响力用户由于粉丝量和阅读量较小,情感传播力度在电商平台中往往较弱。在本文所构建的复杂网络中,中影响力用户度值和权重大小较低,且在空间上也分布于网络边缘,情感节点位置较为分散,难以聚拢其他用户去进一步的形成新的情感圈层。但由于中影响力用户数量占比更多,因此其传播力也不可忽略,且通过情感分类,发现中影响力用户的情感倾向较于高影响力用户更具备情感极化特征,即中影响力用户的情感倾向中支持者占比更多。

综上所述,建议电商外卖服务平台可借助复杂网络识别关键传播节点,优化正向情感传播路径,建立基于网络拓扑结构的情感预警机制,通过影响力用户放大企业社会责任传播效果。但当前研究受限于单一事件数据源和静态网络模型,未来可结合多平台动态传播数据,引入图神经网络捕捉情感演变的时空特征,拓展到虚假信息识别、危机公关策略优化等应用场景。

基金项目

国家哲学社会科学基金资助项目“大数据背景下辟谣信息生成传播机理与辟谣效果研究”,项目编号:19BGL234;上海哲学社会科学青年项目“突发事件中复杂网络信息传播特征及干预策略研究”,项目编号:2021EGL004。

参考文献

- [1] 雷明琦, 吴红. O2O 移动餐饮服务平台的现状分析及优化对策[J]. 电子商务, 2015(7): 21-22.
- [2] 温希波, 邢志良, 薛梅. 生鲜电子商务发展中的瓶颈及其突破策略研究[J]. 中国管理信息化, 2021, 24(17): 128-130.
- [3] 王胜源, 里清泉. 基于主题挖掘与情感分析的生鲜电商平台用户购后评论研究[J]. 辽宁工程技术大学学报(社会科学版), 2025, 27(2): 130-137.
- [4] 黄本涛, 李璨, 吴红, 等. 公众对 ChatGPT 的认知——基于跨平台用户生成内容的主题与情感研究[J]. 数字图书馆论坛, 2025, 21(2): 35-46.
- [5] 陈茁, 高博研, 张晓扬, 等. 电商平台用户评论数据的情感分析: 以家庭陪伴机器人为例[J]. 电脑知识与技术, 2025, 21(6): 79-82.

- [6] 杨瑞仙, 刘佳涵, 孙倬. 社交网络用户隐私泄露情感损失计算研究[J]. 现代情报, 2025, 46(2): 1-19.
- [7] 李春华, 李婷, 马金龙. 基于复杂网络的人脸图像分类算法[J]. 复杂系统与复杂性科学, 2025, 22(2): 1-8.
- [8] 马玉磊, 郭莎莎. 基于深度学习的多样化复杂网络影响力节点识别[J]. 电信科学, 2025, 70(4): 1-12.
- [9] 杨昆, 鲍勤, 程兵, 等. 复杂社会经济条件下基于网络模型的传染病防控政策研究[J]. 系统工程理论与实践, 2024, 44(8): 2509-2526.
- [10] 马晋超, 林雯欣, 章蓓蓓, 等. BIM 外包模式中信息沟通效率的对比分析——基于社会网络分析和 SIR 模型的仿真模拟[J]. 广西科技大学学报, 2025, 36(2): 1-17.
- [11] Zhao, N., Liu, Q., Wang, H., Yang, S., Li, P. and Wang, J. (2023) Estimating the Relative Importance of Nodes in Complex Networks Based on Network Embedding and Gravity Model. *Journal of King Saud University—Computer and Information Sciences*, 35, Article ID: 101758. <https://doi.org/10.1016/j.jksuci.2023.101758>
- [12] 陈如达, 杨凡, 谢剑, 等. 基于重力模型和图注意力网络的重要节点排序方法[J]. 广西科技大学学报, 2025, 36(2): 1-12.
- [13] Li, Z., Ren, T., Ma, X., Liu, S., Zhang, Y. and Zhou, T. (2019) Identifying Influential Spreaders by Gravity Model. *Scientific Reports*, 9, Article No. 8387. <https://doi.org/10.1038/s41598-019-44930-9>
- [14] Rocha, L.E.C., Liljeros, F. and Holme, P. (2011) Simulated Epidemics in an Empirical Spatiotemporal Network of 50,185 Sexual Contacts. *PLOS Computational Biology*, 7, e1001109. <https://doi.org/10.1371/journal.pcbi.1001109>
- [15] 熊才权, 古小惠, 吴歆韵. 基于邻居层级分布引力模型的节点重要性评估方法[J]. 数学物理学报, 2023, 43(6): 1869-1879.
- [16] Ma, J., Li, D. and Tian, Z. (2016) Rumor Spreading in Online Social Networks by Considering the Bipolar Social Reinforcement. *Physica A: Statistical Mechanics and its Applications*, 447, 108-115. <https://doi.org/10.1016/j.physa.2015.12.005>
- [17] Yang, X. and Xiao, F. (2021) An Improved Gravity Model to Identify Influential Nodes in Complex Networks Based on K-Shell Method. *Knowledge-Based Systems*, 227, Article ID: 107198. <https://doi.org/10.1016/j.knosys.2021.107198>
- [18] Fersini, E., Messina, E. and Pozzi, F.A. (2014) Sentiment Analysis: Bayesian Ensemble Learning. *Decision Support Systems*, 68, 26-38. <https://doi.org/10.1016/j.dss.2014.10.004>
- [19] 马玉冰, 邢磊. 基于 RNN 的计算机网络主机异常行为预测研究——以流量数据为视角[J]. 黑龙江科学, 2025, 16(8): 22-25.
- [20] 张圆圆, 张跃军. 基于分析师评论文本情感挖掘的原油收益率预测研究[J]. 系统工程理论与实践, 2025, 45(5): 1-21.
- [21] 简明宇, 任苏灵, 王静. 基于注意力机制的 CNN-LSTM 模型的碳市场价格预测[J]. 哈尔滨商业大学学报(自然科学版), 2025, 41(2): 226-232.
- [22] 高秀艳, 颜笑. 基于 Python 语言和朴素贝叶斯算法的中文文本情感分类器设计与实现[J]. 科技传播, 2024, 16(12): 14-17.
- [23] 张艳倪, 汤敏, 王坤赤. 基于深度学习的情感识别研究综述[J]. 计算机时代, 2025(3): 1-5.
- [24] Tan, X., Wang, Y., Sun, G., Wu, L., Yu, Q. and Yu, Y. (2025) Heat Load Prediction of Building Rooms Using Only the Whole Building Data via Heat Allocation Approach. *Journal of Thermal Science*, 34, 953-969. <https://doi.org/10.1007/s11630-025-2109-2>
- [25] 黄少年, 杨正杰, 易星宇. 群体性突发公共事件数据集构建及识别方法研究[J]. 情报探索, 2025(4): 38-44.