

DOI:10.11918/j.issn.0367-6234.201708025

基于 PageRank 的用户影响力评价改进算法

王 顶, 徐 军, 段存玉, 吴玥瑶, 孙 静

(西北工业大学 电子信息学院, 西安 710100)

摘 要: 为了解决传统微博用户影响力评价算法全面性和客观性差的问题,通过对微博用户影响力的定义和影响因素进行分析,鉴于微博社区网络与 web 页面网络的拓扑结构有着天然相似性的特点,提出了一种基于 PageRank 的用户影响力评价改进算法(Self and Followers User Influence Rank)SF-UIR. 运用用户追随者数、用户是否认证、用户微博的传播能力三个指标对用户自身影响因素进行了量化,改善了 PageRank 值对用户影响力评价客观性差的问题. 采用权重因子将追随者对其所关注用户的影响力贡献值进行科学的量化分配,解决了追随者影响力等值传递的弊端. 与四类主流算法的对比实验结果表明:SF-UIR 算法同时考虑了基于用户行为的自身影响因素和基于拓扑结构的追随者影响因素,能够有效地解决追随者数量排名算法中的“僵尸粉”干扰问题,能比平均转发数算法更真实地反映用户的影响力高低,能有效规避 K-覆盖度算法中未考虑微博用户自身行为特征和将所有的追随者都一视同仁的严重缺陷,能极大地改进 PageRank 算法单纯依赖追随者数量和追随者质量的不足,从而能够更加全面、更加客观地反映微博用户的影响力.

关键词: 用户影响力评价; 微博; PageRank 算法; 自身质量; 权重因子

中图分类号: TP393.092 **文献标志码:** A **文章编号:** 0367-6234(2018)05-0060-08

Improved user influence evaluation algorithm based on PageRank

WANG Ding, XU Jun, DUAN Cunyu, WU Yueyao, SUN Jing

(School of Electronic and Information, Northwestern Polytechnical University, Xi'an 710100, China)

Abstract: To solve the less comprehensive and objective problem of the traditional microblog user influence evaluation algorithms, through the analysis of the definition and influencing factors of microblog user influence, this paper proposes an improved user influence ranking algorithm based on PageRank algorithm, named as Self and Followers User Influence Rank (SF-UIR). The user's own factors are quantified by using the three indicators, the number of followers, the situation of certification, and the microblog dissemination ability, and the poor objectivity situation of PageRank values for user influence ranking is improved. The disadvantage of influence equivalent transfer of the followers' influence is overcome by adopting weighting factor to distribute the influence contribution value of different followers scientifically and quantitatively. Compared with the four mainstream algorithms, the results show that the proposed algorithm is more comprehensive, more objective, and can reflect the influence of microblog users better because of considering the influencing factors based on the user's behavior and followers factors based on the topology, which can effectively solve the interference problem of "zombie fan" in a number of followers ranking algorithm. It can reflect the user's influence level more realistically than average forwarding number algorithm, and can availably avoid the serious defects of not taking the microblog user's behavior into account and giving equal treatment to all followers in K-coverage algorithm. The proposed algorithm can greatly improve the shortage of relying solely on the quantity and quality of followers in PageRank algorithm.

Keywords: user influence evaluation; microblog; PageRank algorithm; the quality of the user itself; weighting factor

微博因其用户数量巨大和消息传播快速及时的特点,已成为很多政府机构、企业单位和公众平台发布信息的重要媒介^[1],所以对微博的研究分析有助于社会舆论的预警和监控^[2]. 而作为消息传播的源头,发布消息的用户的重要性不言而喻,它在一定程

度上决定了该消息的传播路径和传播范围^[3]. 可用微博用户影响力来衡量不同微博用户在消息传播过程中所发挥的不同作用. 通常来讲,影响力越大的用户表明其追随者数量越多、质量越高^[4],那么他所发布的消息比影响力小的用户传播范围更大,对社会造成的影响也更大. 鉴于微博在社会信息传播和商业营销方面巨大的影响力,国内外许多学者都对微博用户影响力进行了研究,也提出了一些关于微博用户影响力的评价算法,如侧重用户追随者数

收稿日期: 2017-08-07
基金项目: 国家自然科学基金(61271279); 国家高技术研究发展计划(863 计划)项目 2015AA01A704 联合资助.
作者简介: 王 顶(1973—), 男, 副教授, 硕士生导师
通信作者: 徐 军, xuju_567@163.com.

量的 F-F 算法,侧重用户微博被转发数量的平均转发数算法,侧重用户之间级联关系的 K-覆盖度算法,侧重网络拓扑结构的 PageRank 算法以及一些改进算法. 上述这些算法虽然都有各自的研究重点,但整体来看,都存在着考虑问题不够全面,单纯地以某一个或某两个指标来衡量用户的影响力问题,使得最终的评估结果不够真实和准确. 因此,本文提出了一种基于 PageRank 的用户影响力评价改进算法(Self and Followers User Influence Rank)SF-UIR. 相比于其他算法而言,该算法考虑因素更多,计算公式更复杂,评价更真实客观.

1 微博用户影响力

1.1 定义

影响力通常指的是用一种潜移默化的方式,使周围人的思维和行为发生转变的能力^[5].

微博用户影响力主要反映不同账号的微博用户对微博群成员的影响程度,主要基于微博用户的基本数据^[6],结合行业市场规模、用户活跃程度、业内平均发展水平等因素,综合加权计算得出. 微博用户影响力是一个综合的衡量指标,相较于传统的追随者数量来说,能够更加客观的反映每日微博用户在微博社区中的动态.

1.2 影响因素

到达率和接收率. 到达率是指微博用户所发布的消息能够出现在多少追随者的页面中,通常用追随者的数量来衡量^[9];接收率是指用户所发消息可被多少追随者看到. 但要使微博用户发的每条消息都能被所有追随者看到是不可能的. 因为必定会有部分消息由于追随者没有及时查看而被其他用户所发的信息淹没,所以,接收率通常小于到达率.

一般认为,用户的追随者越多表明其影响力越大,但完全用追随者数量代替影响力既不全面也不客观的. 现实中,微博影响力的构成是很繁杂的,受多种因素的影响,比较重要的因素包括追随者数量、追随者的追随者数量、追随者的关注数量、追随者的活跃度、微博平台自身影响力、微博用户自身知名度等^[8-10].

2 PageRank 算法

PageRank 算法是由 Google 创始人 Sergey Brin 和 Lawrence Page 于 1998 年提出的一种网页排名算法,其核心思想是通过研究网络的拓扑结构和计算页面的入度(即页面被链接的次数),进而确定该页面的排名顺序. 页面的入度越大,那么它的重要性就越大,排名也越靠前. 一个页面之所以有指向另

一个页面的链接,是因为它认为该页面比较权威,内容真实可信,在相关领域有一定知名度. PageRank 算法中最重要也是最关键的一点是,它不光计算页面的入度数量,还将指向目标页面的其它页面自身的 PageRank 值考虑在内^[11]. 例如有两个页面 A 和 B,A 被一个非常重要的页面所认同,而 B 被很多普通的页面所认同,则页面 A 的 PageRank 值可能比页面 B 的 PageRank 值更大. 一个页面的 PageRank 值为

$$P(V_i) = (1 - d) + d \sum_{V_j \in F(V_i)} \frac{P(V_j)}{L(V_j)}. \quad (1)$$

式中: $P(V_i)$ 为页面 V_i 的 PageRank 值, $F(V_i)$ 为指向页面 V_i 的页面集, $P(V_j)$ 为页面集 $F(V_i)$ 中的任意一个页面 V_j 的 PageRank 值, $L(V_j)$ 为页面 V_j 中链接到其它页面的链接集, d 为阻尼系数,用来解决某些特殊情况导致的个别页面 PageRank 值因无法收敛而难以计算情况的发生,通常 $d = 0.85$.

为更加方便的理解和研究 PageRank 算法,将整个网络抽象成一个巨大的有方向的图,图中的节点代表现实网络中的 web 页面,图中的有向边代表 web 页面之间的链入链出关系. 现在假设有一个非常简单的网络,其中只有 4 个页面: A、B、C、D,其结构见图 1.




图 1 web 拓扑结构

Fig.1 Topology of websites

从图 1 中可看出, A 中有指向 B、C、D 的链接,假设用户从 A 跳转到其它页面的概率是相等的,即 A 到 B 的概率是 1/3,B 到 C 的概率是 1/2,而 D 没有指向 C 的链接,所以 D 到 C 的概率是 0. 假设网络中一共有 N 个页面,那么可以定义一个 N 维的转移矩阵(Transition Matrix): 其中第 x 行第 y 列的值为用户从页面 y 跳转到页面 x 的概率. 下面的 M 矩阵是图 1 所对应的转移矩阵.

$$M = \begin{bmatrix} 0 & 1 & 0 & 1/2 \\ 1/3 & 0 & 0 & 1/2 \\ 1/3 & 1/2 & 0 & 0 \\ 1/3 & 0 & 1 & 0 \end{bmatrix}.$$

然后,假设每个页面的初始 rank 值为 $1/N$, N 是网络中 web 页面的总数量,这里为 4. 将页面 A、B、C、D 的 rank 值组成的向量设为 $\vec{v}$

$$\vec{v} = [1/4 \quad 1/4 \quad 1/4 \quad 1/4]^T.$$

注意, 矩阵 M 第一行的数值对应的是 A 、 B 、 C 和 D 跳转到 A 的概率, 而向量 $\vec{v}$ 第一列的数值对应的是 A 、 B 、 C 和 D 当前的 rank 值, 所以根据矩阵的乘法原理, 用矩阵 M 的第一行乘以向量 $\vec{v}$ 的第一列, 所得结果就是 A 新 rank 值的合理估计, 同理, $M \cdot \vec{v}$ 的结果就分别代表 A 、 B 、 C 、 D 的新 rank 值.

$$M \cdot \vec{v} = [1/4 \quad 5/24 \quad 5/24 \quad 1/3]^T.$$

将 $M \cdot \vec{v}$ 作为新的 rank 值向量赋值给向量 $\vec{v}$, 然后再用转移矩阵 M 乘以 $\vec{v}$, 如此往复, 不断执行迭代的过程. 当 $\vec{v}$ 约等于 $M \cdot \vec{v}$ 时, 迭代结束, 此时的向量 $\vec{v}$ 中的值就是各个页面最终的 PageRank 值. 在上面的例子中, 经过若干步迭代计算后

$$\vec{v} = [3/9 \quad 2/9 \quad 2/9 \quad 2/9]^T.$$

此时, $\vec{v}$ 就是 A 、 B 、 C 、 D 最终的 PageRank 值.

3 基于 PageRank 改进算法基本原理

由于微博的拓扑结构与网络的拓扑结构有着天然的相似性, 微博平台上的海量用户相当于网络世界里成千上万的页面, 而微博用户关注其他用户的行为相当于页面添加了一个指向其它页面的链接, 微博用户被其他用户关注的行为相当于页面增加了一个入度^[12]. 所以可借鉴 PageRank 的经典算法来计算微博用户的影响力. 但由于微博用户是活跃的、动态的, 他们会产生各种各样的用户行为, 例如发布或转发微博、关注好友等, 而页面却是静止的. 所以若直接利用 PageRank 算法来计算微博用户影响力, 仅仅是对其追随者的 PageRank 值进行叠加, 则会忽视用户本身行为所产生的影响因素, 使得最终得到的微博用户影响力不够准确和客观. 为此, 本文提出了一种基于 PageRank 经典算法的微博用户影响力评价改进算法——SF-UIR (Self and Followers User Influence Rank) 算法.

SF-UIR 算法的核心优势在于综合考虑了以下两方面因素:

1) 基于用户行为的自身影响因素

a) 用户的追随者数量. 这是最能直观体现一个微博用户影响力的指标, 通常来讲, 追随者数量越大, 意味着该节点有更多的链接边数, 那么该用户就有更大的接触面, 其影响力也会增大.

b) 用户是否认证. 一般普通的微博账号在搜索引擎中是搜不到的, 因为微博信息并不对搜索引擎开放. 但是, 当用户做了认证之后, 该账号就有很大的可能性被搜索引擎收录, 可见搜索引擎认为认证用户更值得信赖. 账号被搜索引擎收录, 这样无形中

就扩大了用户微博的影响力, 因为认证用户发的微博也很可能会被搜索引擎认可收录, 只要用户在搜索引擎上面搜索相似或者相关的字, 那么微博账号名就可能会被搜到, 这意味着认证用户比普通用户有更多“曝光”的手段, 从而有更多的机会让人们关注他的微博.

一旦你认证之后, 你所发布的微博信息也会让人觉得更可靠, 大家也更愿意去相信你表达的信息. 通过认证的用户, 也会被大家认为是具有一定影响力的名人, 发表的言论更加权威, 当然也会有更多的追随者. 因此用户通过认证对其影响力有很大提升.

c) 用户微博的传播能力. 一篇微博的传播能力主要是依靠其被其他用户评论或转发的次数来衡量. 通过知微工具来分析微博消息的传播过程, 以小米手机于 2015 年 1 月 7 日发布的一条微博为例^[13], 图 2 显示了这条微博的传播路径和传播范围.




图 2 微博传播路径

Fig.2 Propagation path of microblog

图中灰色节点代表根节点小米手机, 黄色的节点代表转发了这条微博的用户. 由图可见, 微博是以根节点为中心, 呈放射状并以级联的形式向外传播, 经大量研究表明, 绝大部分微博的传播深度值不会超过 6, 平均传播深度值约为 3.5.




图 3 微博传播的层级分析

Fig.3 Hierarchy analysis of microblog propagation

图 3 中, 在微博的传播过程中, 第 1 层转发占比为 43.7%, 第 2 层为 38.7%, 第 3 层为 15.3%, 第 4 层及第 4 层以后的为 2.3%. 由此可见, 一条微博的传播范围和能力大部分是由第 1 层和第 2 层用户的转发数决定的, 则微博用户的影响力范围主要覆盖它的第一级追随者 (直接的追随者) 和第二级追随者 (追随者的追随者).

2) 基于拓扑结构的追随者影响因素

借鉴 PageRank 的思想,将微博用户视为网页节点,用户之间的关注关系视为网页的链入链出,着重分析微博用户的追随者群、每个追随者的自身的影响力以及他们如何将自身的影响力合理地分配给他们所关注的用户. 由 PageRank 的计算公式可知,网页将自身 PageRank 值均匀地分给它所链出的网页,例如,假设网页 A 的 PageRank 值是 1,它一共包含 5 个指向其它网页的链接,那么它对每一个网页贡献的 PageRank 值为 $1/5$. 对比于微博用户,则表现为每个用户将自身的影响力值均分给他关注的所有用户,这样的分配显然是不合理的,因为尽管关注了很多用户,但是不可能做到对所有的用户都一视同仁,总是对其中的一部分更加感兴趣,更愿意去转发和评论他们所发的微博. 因此,如果直接套用 PageRank 公式来计算追随者的影响力贡献值是不准确的.

鉴于 PageRank 算法中追随者影响力等值传递的这种弊端^[14],在式(1)的基础上增加一个权重因子来反映追随者与其所关注用户的密切程度,追随者根据权重因子的大小来分配他的贡献值. 权重因子越大,表明二者的关系越密切,互动性越强,相应的追随者会将更大比例的贡献值分配给该用户. 这样既很好地解决了 PageRank 算法的弊端,又保留了其原有的优势,使得最终结果更加符合实际情况,使得评估模型更客观、更合理.

4 SF-UIR 算法的具体实现

4.1 算法推导

考虑基于用户行为的自身影响因素和基于拓扑结构的追随者影响因素,将 SF-UIR 算法定义为

$$P_{\text{SF-UIR}}(U_i) = P_{\text{SF-UIR_self}}(U_i) + P_{\text{SF-UIR_fans}}(U_i). \quad (2)$$

式中: $P_{\text{SF-UIR}}(U_i)$ 为用户 i 的影响力, $P_{\text{SF-UIR_self}}(U_i)$ 为用户 i 的自身影响因素, $P_{\text{SF-UIR_fans}}(U_i)$ 为用户 i 的追随者影响因素.

SF-UIR 算法的物理意义在于对用户追随者数量、用户是否认证、用户微博的传播能力等三方面的用户自身影响因素进行了量化,同时还根据权重因子量化计算了追随者对其所关注用户的影响力贡献值,从而克服了单纯以某一个或某两个指标来衡量用户影响力的问题,考虑因素更多,计算公式更复杂,评价更真实,更能反映微博用户的影响力.

$$P_{\text{SF-UIR_self}}(U_i) = \frac{F_{U_i}}{N} + B_{\text{verified}}(U_i) + A_{U_i} * T_{U_i}$$

式中: F_{U_i} 为用户 i 的追随者数, N 为所有用户中追随者数最多的用户所拥有的追随者数, $B_{\text{verified}}(U_i) =$

$(e, 0)$ 为用户 i 是否经过认证,是一个布尔类型,若用户 i 经过认证则 $B_{\text{verified}}(U_i) = e$,反之, $B_{\text{verified}}(U_i) = 0$. A_{U_i} 为用户 i 在统计周期内发布微博的频率,即其在统计周期内的微博传播能力.

$$A_{U_i} = \frac{M_{U_i}}{T}.$$

式中: M_{U_i} 为用户 i 在 T 内所发微博的集合, T 为统计周期,将统计周期设定为 15 天,即 $T = 15$.

$$T_{U_i} = \sum_{m_j \in M_{U_i}} (aR_{m_j} + bC_{m_j} + cL_{m_j}). \quad (3)$$

式中: m_j 为用户 i 在统计周期内所发微博集合中的任意一条微博, R_{m_j} 为 m_j 这条微博的转发率,它等于 m_j 被转发的总数与用户 i 的追随者数的比值, C_{m_j} 为评论率, L_{m_j} 为点赞率. a 、 b 、 c 分别为各自的权重.

$$P_{\text{SF-UIR_fans}}(U_i) = (1 - d) + d \sum_{U_j \in F_{U_i}} S(i, j) P_{\text{SF-UIR}}(U_j). \quad (4)$$

式中: F_{U_i} 为用户 i 的追随者集合,用户 j 为用户 i 追随者集合中的任意一个用户, $S(i, j)$ 为用户 j 分配给用户 i 的 SF-UIR 值的比例,由用户 i 的微博传播能力占用户 j 所有好友的微博传播能力之和的大小所决定.

$$S(i, j) = \frac{R(i, j)}{\sum_{U_p \in I_{U_j}} R(p, j)}.$$

式中: I_{U_j} 为用户 j 所关注好友的集合, $R(i, j)$ 为用户 i 在统计时间内传递给用户 j 的信息量, $\sum_{U_p \in I_{U_j}} R(p, j)$ 为用户 j 在统计时间内一共接收到的来自所有好友的信息量.

$$R(i, j) = \frac{Rt(i, j)}{S(i) + 1}.$$

式中: $Rt(i, j)$ 为用户 j 在统计周期内转发、评论和点赞用户 i 的微博次数, $S(i)$ 为用户 i 在统计周期内发布和转发的微博数量, $S(i) + 1$ 是为避免分母为零的情况出现,因为有些用户可能在统计周期内没有发布或转发过微博.

将式(4)进一步分解

$$P_{\text{SF-UIR_fans}}(U_i) = (1 - d) + d \sum_{U_j \in F_{U_i}} S(i, j) \cdot$$

$$[P_{\text{SF-UIR_self}}(U_j) + P_{\text{SF-UIR_fans}}(U_j)]$$

代入到公式(2)中得

$$P_{\text{SF-UIR}}(U_i) = P_{\text{SF-UIR_self}}(U_i) +$$

$$d \sum_{U_j \in F_{U_i}} S(i, j) P_{\text{SF-UIR_self}}(U_j) +$$

$$d \sum_{U_j \in F_{U_i}} S(i, j) P_{\text{SF-UIR_fans}}(U_j) + 1 - d.$$

式中: $P_{\text{SF-UIR_self}}(U_i) + d \sum_{U_j \in F_{U_i}} S(i, j) P_{\text{SF-UIR_self}}(U_j)$ 为常数. 由于 PageRank 的计算公式是收敛的, 而 $d \sum_{U_j \in F_{U_i}} S(i, j) P_{\text{SF-UIR_fans}}(U_j) + 1 - d$ 从结构上与式(1)相同, 所以本文的 SF-UIR 计算公式也是收敛的.

4.2 参数确定

式(2)中 N 为所有用户中追随者数最多的用户所拥有的追随者数, 在 mysql 数据库中可使用以下命令进行查询:

```
select * from user_info order by fn desc limit 10
```

式(3)中 a 、 b 、 c 为不同变量的权重值. 通过这些权重值能直观地反映出评价人对不同变量的不同重视程度, 实现了重要程度的量化, 使人们可很轻松地分辨出各变量之间的差异程度. 但每个变量的权重其实是很难直接确定的, 尤其是评价指标较多时, 评价人通常只能粗略的估计每个变量的重要程度, 但要给出具体的、精确的数值是不现实的, 所以需要运用合理有效的方法去解决这个问题.

首先将各个变量的重要程度做成对比较, 然后将比较的结果按一定的方式聚合起来, 经过计算, 最终得到各个变量的权重值.

1) 设有 m 个变量, 对这 m 个变量按照重要程度两两作比较, 一共要比较的次数为

$$C_m^2 = \frac{1}{2}m(m - 1).$$

把第 i 个变量对第 j 个变量的相对重要性记为 b_{ij} , 并认为这就是变量 i 的权重 w_i 和变量 j 的权重 w_j 的比值, 即 $b_{ij} = \frac{w_i}{w_j}$.

2) 由转发率、评论率、点赞率 3 个变量成对比较的结果构成矩阵 B

$$B = \begin{bmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \\ b_{31} & b_{32} & b_{33} \end{bmatrix} = \begin{bmatrix} a/a & a/b & a/c \\ b/a & b/b & b/c \\ c/a & c/b & c/c \end{bmatrix}. \quad (5)$$

显然有:

$$b_{ij} = \frac{1}{b_{ji}}, \quad b_{ij} = b_{ik} \cdot b_{kj}, \quad b_{ii} = 1.$$

3) 表 1 为 Saaty 参考普通人对事物重要程度的认知方式和判断习惯总结出的变量间相对重要性等级表. 参照该表来确定第 i 个变量对第 j 个变量的相对重要性, 即求取 b_{ij} 的值. 转发率与评论率相比, 介于略微重要和相当重要之间, 取 $b_{12} = 4$; 转发率与点赞率相比, 介于明显重要和绝对重要之间, 取 $b_{13} = 8$; 评论率和点赞率相比, 介于同等重要和略显重要之间, 取 $b_{23} = 2$. 代入式(5)中, 可得

$$B = \begin{bmatrix} 1 & 4 & 8 \\ 1/4 & 1 & 2 \\ 1/8 & 1/2 & 1 \end{bmatrix}.$$

最终, 求得 $a = 0.727, b = 0.182, c = 0.091$.

表 1 变量间相对重要性等级

Tab.1 Relative importance level between variables

相对重要程度	定义	说明
1	同等重要	两个变量同样重要
3	略微重要	由经验判断, 一个变量比另一个变量稍微重要
5	相当重要	由经验判断, 一个变量比另一个变量更为重要
7	明显重要	一个变量比另一个重要更为重要, 且已有实践证明
9	绝对重要	重要程度可以断言为最高
2, 4, 6, 8	两个相邻判断的中间值 需要折中时采用	

5 算法结果对比分析

5.1 数据采集、预处理及相关说明

为更加客观地反映本文所提 SF-UIR 算法的优越性, 搭建了基于 Spark 平台的实验环境. 以目前最流行、最受广大网民欢迎的新浪微博作为数据源, 运用中国爬萌网站提供的“新浪微博微博信息采集器”采集所需微博用户的基本信息, 采集到的用户基本信息字段见表 2. 运用八爪鱼数据采集系统从新浪微博上获取所需微博用户在一定周期内的行为信息, 主要采集 5 个字段, 分别为: 用户名、发布时间、转发数量、评论数量、点赞数量.

表 2 用户信息字段

Tab.2 Fields of user information

字段名	完整名称	描述
_id	用户原始 id	用户名称
un	username	用户名
sn	screen_name	用户屏幕名
sx	sex	统一使用“男”“女”
ad	address	地址
de	description	用户自我描述信息
iu	profile_image_url	头像 URL 最短标识字符串
an	attention_num	关注数量默认值 0
fn	fans_num	追随者数量默认值 0
mn	message_num	消息数量默认值 0
iv	is_verified	0 普通用户, 1 vip 用户
vi	verify_info	认证信息
tg	tag	用户标签, 用“,”号分隔
ei	education_info	教育信息
ci	career_info	职业信息
fui	follower_userid	用户关注的人的 id 列表

采集到的实验数据通常存在格式不规范、内容冗余、部分信息缺失等问题,为保证实验的顺利进行以及实验结果的真实可靠,需经过格式转换、冗余字段删除、实验数据入库、僵尸粉和沉默用户的删除、关系提取等一系列数据预处理过程后再将其上传到分布式文件系统 HDFS 中,最终综合 Spark GraphX、Spark SQL、MLlib 等技术实现了追随者数量排名算法、平均转发数算法、K-覆盖度算法、PageRank 算法和 SF-UIR 算法。

由于本文的实验数据是通过爬虫工具从新浪微博上爬取的,因此会造成部分微博用户信息的缺失,如某些用户的关注列表不完整、固定周期内用户所发的微博没有全部采集到等,这会导致实验结果与真实的结果之间存在一定的偏差。但是本文的所有实验都是基于相同的实验数据进行的,因此通过分析实验结果所得出的实验结论仍具有一定的说服力和可信力。

为更加形象地反映微博用户在网络中的影响力程度,将借助“用户排名”的概念,依据不同的算法规则对其进行量化排名,同时进行比较分析。需要指出的是文中追随者数量排名算法、平均转发数算法、K-覆盖度算法和 PageRank 算法均是依据各算法的原始方法实现的。SF-UIR 算法亦是与它们的原始方法进行对比,但这并不影响比较因素的全面性和结果的正确性。这是因为,一方面当前主流算法的原始方法能充分反映该算法的本质特征;另一方面一些基于主流算法的改进算法本身依然具有一些不够全面的问题,如文献[8]考虑了微博用户的粉丝数、微博发布频率、用户的活跃度等因素只解决了僵尸粉对用户影响力的干扰问题,文献[14]构建了用户活跃度和历史关注度两个指标,只从微博传播能力方面改进了 PageRank 算法,等等,而本文算法已经将这些不全面的方面进行了考虑和完善。

5.2 SF-UIR 算法同追随者数量排名算法对比

表 3 给出本文 SF-UIR 算法排名前十的用户,以及这 10 名用户按照追随者数量排名的次序。图 4 用对数刻度(纵坐标呈对数分布,当纵坐标数值差较大时更便于观察)直观展示了两两种排名算法与追随者数量间的对应变化情况。

实验结果表明,追随者数量虽然是支撑影响力排名的重要因素,但并非绝对因素。因此,按照追随者数量来判断一个用户的影响力的方法太过于片面,极易容易受到“僵尸粉”的误导。而考虑了追随者质量的 SF-UIR 算法对用户影响力评价则更全面,且可以用来杜绝微博上的某些陋习,例如,由于虚荣心或商业目的,有些用户会花钱去购买追随者,

甚至通过发布一些哗众取宠的内容来吸引人们的注意,以此来增加自己的追随者数量。

表 3 SF-UIR 算法同追随者数量排名算法对比
Tab.3 SF-UIR compared with the number of followers ranking

SF-UIR 排名	用户名	追随者数量/人	按追随者数量排名
1	心 * 小谈	19 186	3
2	路- * 不遥远	15 764	8
3	* 尾音	12 088	11
4	西 * _VISION	11 270	14
5	B * sco--波	6 084	32
6	木 * 藤藤	16 984	5
7	De * rperi	21 975	2
8	张昕 * _小昕	8 659	27
9	等 * 一个你爱的人	9 683	16
10	Blue * 文 Margie	17 890	4




图 4 SF-UIR 算法同追随者数量排名算法对比折线
Fig.4 The line chart of comparing SF-UIR with the number of followers ranking algorithm

5.3 SF-UIR 算法同平均转发数算法对比

表 4 给出本文 SF-UIR 算法排名前十的用户,以及这 10 名用户按照平均转发数排名的次序。图 5 用对数刻度直观展示了两两种排名算法与平均转发数间的对应变化情况。

表 4 SF-UIR 算法同平均转发数排名算法对比
Tab.4 SF-UIR compared with average forward

SF-UIR 排名	用户名	平均转发数/次	按平均转发数排名
1	心 * 小谈	1 230	2
2	路- * 不遥远	953	4
3	* 尾音	745	11
4	西 * _VISION	426	18
5	B * sco--波	594	14
6	木 * 藤藤	862	7
7	De * rperi	392	32
8	张昕 * _小昕	685	12
9	等 * 一个你爱的人	451	16
10	Blue * 文 Margie	627	13




图 5 SF-UIR 算法同平均转发数算法对比折线

Fig.5 The line chart of comparing SF-UIR with average forward

从实验结果来看,在 SF-UIR 算法中排名前 10 的用户,除了“心 * 小谈”、“路- * 不遥远”和“木 * 藤藤”之外,在按平均转发数算法的排名中都没能排进前 10,排名第 7 的“De * rperi”用户甚至排到了第 32 名. 这说明用户的影响力与用户微博的平均转发数量并非呈现一定的正相关性,影响力高的用户,其微博的平均转发数并不一定高.

5.4 SF-UIR 算法同 K-覆盖度算法对比

表 5 给出了 SF-UIR 算法与 K-覆盖度算法的排名结果对比情况. 图 6 从 SF-UIR 算法排名前 10 位用户的角度直观展示了两排名算法对应变化情况.

表 5 SF-UIR 算法同 K-覆盖度算法对比

Tab.5 SF-UIR compared with K-coverage algorithm

SF-UIR 排名	用户名	K-覆盖度排名	用户名
1	心 * 小谈	1	Blue * 文 Margie
2	路- * 不遥远	2	De * rperi
3	* 尾音	3	周 * 摄影
4	西 * _VISION	4	心 * 小谈
5	B * sco--波	5	小 * 领域-
6	木 * 藤藤	6	滕 * 老彭
7	De * rperi	7	木 * 藤藤
8	张昕 * _小昕	8	飞 * 我心
9	等 * 一个你爱的人	9	西 * Lily
10	Blue * 文 Margie	10	高 * 企鹅




图 6 SF-UIR 算法同 K-覆盖度算法对比折线

Fig.6 The line chart of comparing SF-UIR with K-coverage

无论从表 5 的连续排名比较,还是从图 6 的统一用户排名比较来看,两种算法得到的排名结果很接近,但仍有不小的差别. 经过分析可知,虽然 K-覆盖度算法将多级用户的影响力都考虑了进去,但也存在两点不足:1) 没有将微博用户自身行为特征所产生的影响力考虑在内;2) 将微博消息被转发的概率统一设为 m , 这种一视同仁的做法忽略了不同用户消息的差异性. 从而导致了与 SF-UIR 算法相比,不具有很强的说服力.

5.5 SF-UIR 算法同 PageRank 算法对比

表 6 给出了 SF-UIR 算法与 PageRank 算法的排名结果对比情况. 图 7 从 SF-UIR 算法排名前 10 位用户的角度直观展示了两排名算法对应变化情况.

表 6 SF-UIR 算法同 PageRank 算法对比

Tab.6 SF-UIR compared with PageRank

SF-UIR 排名	用户名	PageRank 排名	用户名
1	心 * 小谈	1	心 * 小谈
2	路- * 不遥远	2	De * rperi
3	* 尾音	3	路- * 不遥远
4	西 * _VISION	4	西 * _VISION
5	B * sco--波	5	* 尾音
6	木 * 藤藤	6	B * sco--波
7	De * rperi	7	男 * _Eric
8	张昕 * _小昕	8	美 * 道理
9	等 * 一个你爱的人	9	西 * Lily
10	Blue * 文 Margie	10	木 * 藤藤




图 7 SF-UIR 算法同 PageRank 算法对比折线

Fig.7 The line chart of comparing SF-UIR with PageRank

从表 6 的连续排名结果和图 7 的统一用户排名结果可以看出,SF-UIR 的排名与 PageRank 的排名差别不是特别大,尤其是第 1 名和第 4 名的排名结果是一致的,这就证明 SF-UIR 是基于 PageRank 算法改进而来的,因此两种排名在总体上接近,在某些情况下甚至是一致的. 但是,由于 PageRank 算法只考虑了用户之间的链入链出关系,是基于静态的网络拓扑结构生成的排名,影响力的大小主要由追随者的数量和追随者的质量决定的. 例如,用户“De * rperi”在 PageRank 排第二名,但在 SF-UIR 中排名

掉落到第 7 名,通过分析发现,在研究的周期内,用户“De * rperi”相比于榜单上的其他用户而言,活跃度较低,微博平均转发量、评论量、点赞量都相对较低,因此 SF-UIR_Self 的值比较低,那么在 SF-UIR 算法中排名降低也是合情合理的。由于 SF-UIR 算法在考虑用户追随者贡献值的同时,还兼顾用户自身的行为特征和活跃程度,因此,它比 PageRank 更加合理,更加全面,更加贴近实际情况。

综上所述,通过比较分析不难发现 SF-UIR 算法在考虑用户追随者贡献值的同时,还兼顾用户自身的行为特征和活跃程度,因此,它比其他算法更加合理、全面、贴近实际情况。

6 结 论

本文基于微博用户影响力评价与网页排名 PageRank 算法天然相似的客观实际,在 PageRank 算法的基础上结合微博用户自身的行为特征提出了 SF-UIR 算法,综合考虑了基于用户行为的自身影响因素和基于拓扑结构的追随者影响因素。通过与代表性算法相比较,表明该算法考虑的信息更全面、给出的评价更真实、更能客观地反映出用户的实际影响力。

参考文献

[1] 张俊豪, 顾益军, 张士豪. 基于 PageRank 和用户行为的微博用户影响力评估[J]. 信息网络安全, 2015(6): 73-78. DOI: 10.3969/j.issn.1671-1122.2015.06.012.

ZHANG Junhao, GU Yijun, ZHANG Shihao. Microblog user influence evaluation based on pagerank and user behavior [J]. Netinfo Security, 2015(6): 73-78. DOI: 10.3969/j.issn.1671-1122.2015.06.012.

[2] 简小军. 浅析微博的舆论功能及其发展[J]. 新闻世界, 2014(8): 110-111.

JIAN Xiaojun. Brief analysis of microblog public opinion function and development[J]. News World, 2014(8): 110-111.

[3] 易续平. 微博影响力的量化研究[D]. 昆明: 云南财经大学, 2014.

YI Xuping. Quantitative research of microblog influence[D]. Kunming: Yunnan University of Finance and Economics, 2014.

[4] 程志强. 基于新浪微博主题的用户影响力研究[D]. 沈阳: 东北大学, 2013.

CHENG Zhiqiang. User influence research based on the theme of sina microblog[D]. Shenyang: Northeastern University, 2013.

[5] 李军, 陈震, 黄霁崑. 微博影响力评价研究[J]. 信息网络安全, 2012(3): 10-13. DOI: 10.3969/j.issn.1671-1122.2012.03.003.

LI Jun, CHEN Zhen, HUANG Jiwei. Microblog influence evaluation research [J]. Netinfo Security, 2012(3): 10-13. DOI: 10.3969/j.issn.1671-1122.2012.03.003.

[6] 尹杰. 基于用户分析的微博信息过滤研究[D]. 大连: 大连理工大学, 2013.

YIN Jie. The microblog information filtering based on user analysis [D]. Dalian: Dalian University of Technology, 2013.

[7] 梁宏. 微博复杂网络适应度模型的研究[D]. 北京: 北京化工大学, 2013.

LIANG Hong. The research of fitness network model on weibo complex network[D]. Beijing: Beijing University of Chemical Technology, 2013.

[8] 杨科. 基于改进 PageRank 算法的微博用户影响力研究[D]. 西安: 西安建筑科技大学, 2014.

YANG Ke. Microblog user influence research based on the improved pagerank[D]. Xi'an: Xi'an University of Architecture & Technology, 2014.

[9] 张昊, 刘功申, 苏波. 一种微博用户影响力的计算方法[J]. 计算机应用与软件, 2015(3): 41-44. DOI: 10.3969/j.issn.1000-386x.2015.03.012.

ZHANG Hao, LIU Gongshen, SU Bo. A method of calculating the influence of weibo users[J]. Computer Applications and Software, 2015(3): 41-44. DOI: 10.3969/j.issn.1000-386x.2015.03.012.

[10] 姚茜, 卜彦芳. 基于影响力研究的微博营销模式探析[J]. 经济问题探索, 2011(12): 117-121.

YAO Xi, BO Yanfang. The analysis of microblog marketing model based on influence research[J]. Inquiry into Economic Issues, 2011(12): 117-121.

[11] 张亚楠. 基于用户行为的信任感知推荐方法研究[D]. 哈尔滨: 哈尔滨工程大学, 2014.

ZHANG Ya'nan. Research on recommendation methods based on trust perception of user behavior[D]. Harbin: Harbin Engineering University, 2014.

[12] 陆毅. 微博社会网络构造与分析技术研究[D]. 上海: 复旦大学, 2011.

LU Yi. The study of microblog social network structure and analysis techniques[D]. Shanghai: Fudan University, 2011.

[13] 马晓娟, 李玉贞, 胡勇. 微博用户影响力的评估[J]. 信息安全与通信保密, 2013(6): 53-55.

MA Xiaojuan, LI Yuzhen, HU Yong. The evaluation on microblog user influence[J]. Information Security and Communications Privacy, 2013(6): 53-55.

[14] 王琛, 陈庶樵. 一种改进的微博用户影响力评价算法[J]. 信息工程大学学报, 2013, 4(3): 380-384. DOI: 10.3969/j.issn.1671-0673.2013.03.021.

WANG Chen, CHEN Shuqiao. Improved user influence evaluation algorithm of microblog[J]. Journal of Information Engineering University, 2013, 14(3): 380-384. DOI: 10.3969/j.issn.1671-0673.2013.03.021.

(编辑 苗秀芝)