

An Improved Method for Dynamic Opinion Maximization Based on Greedy Genetic Algorithms

Hossein Rayatparvar¹, Mohammad Hasani Ahangar^{*2}, Aboufazel Sarkardei³

¹ Master's degree, Imam Hossein University, Tehran, Iran (hosseinrayatparvar@ihu.ac.ir)

² Professor, Imam Hossein University, Tehran, Iran. (Correspondence: mrhasani@ihu.ac.ir)

³ PhD student, Imam Hossein University (AS), Tehran, Iran. (aboufazlsarkardei@gmail.com)

ARTICLE INFO

Article history:

Article Type: Research paper

Receive: 18 October 2025

Revise: 18 November 2025

Accept: 28 November 2025

Available online: 22 December 2025

Keywords:

Online social network analysis
dynamic opinion maximization
seed nodes
genetic algorithm
Q-learning

ABSTRACT

The analysis of online social network data represents a significant scientific challenge in contemporary research. Within the domain of user opinion analysis in these networks, dynamic opinion maximization has emerged as a nascent field of study. Prior investigations in this area have predominantly operated under the assumption of static, unchanging node opinions. Furthermore, the temporal evolution of user perspectives has received comparatively limited attention. This paper proposes a method for the dynamic opinion maximization problem, based on a greedy genetic algorithm, explicitly considering the dynamics of opinions and their evolution over time. The proposed method comprises two principal components: an activated opinion dynamics model and a seed node selection process. The activated opinion dynamics model is constructed by integrating the linear threshold model with stateless Q-learning, thereby explicitly accommodating the temporal fluctuations in opinions. A greedy genetic algorithm is employed for the selection of seed nodes. Following the identification of an initial seed node, the activated opinion dynamics model is initiated. During this phase, the seed node and its immediate neighbors are activated according to the linear threshold model. Subsequently, stateless Q-learning is utilized to update the opinions of the nodes. This iterative process continues until predefined termination criteria are satisfied. Experimental results on four signed social network datasets demonstrate that the proposed framework outperforms the state-of-the-art method by 14% in terms of the number of activated nodes and 27% in terms of average positive opinions.

Cite this article: Rayatparvar, H., Hasani Ahangar, M., Sarkardei, A. An Improved Method for Dynamic Opinion Maximization Based on Greedy Genetic Algorithms. *Electronic and Cyber Defense*, 2025; 13(4): 41- 62.

DOI: <https://doi.org/10.47176/ECDJ.2025.1617>



© The Author(s). retain the copyright and full publishing rights



Publisher: Imam Hossein University

ارائه روش بهبودیافته در حداکثر سازی پویایی نظرات مبتنی بر الگوریتم ژنتیک حریصانه**حسین رعیت پرور¹، محمدرضا حسنی آهنگر*²، ابوالفضل سرکرده‌ئی³**¹ کارشناسی ارشد، دانشگاه جامع امام حسین(ع)، تهران، ایران (hosseinrayatparvar@ihu.ac.ir)² استاد، دانشگاه جامع امام حسین(ع)، تهران، ایران (نویسنده مسئول: mrhasani@ihu.ac.ir)³ دانشجوی دکتری، دانشگاه جامع امام حسین(ع)، تهران، ایران (aboulfazlsarkardei@gmail.com)

چکیده	مشخصات مقاله
تحلیل داده‌های شبکه‌های اجتماعی برخط یکی از چالش‌های علمی موردتوجه در عصر حاضر است. در زمینه تحلیل نظرات کاربران در این شبکه‌ها، حداکثر سازی پویایی نظرات به‌عنوان یک حوزه پژوهشی جدید مطرح شده است. تحقیقات پیشین در این حوزه عمدتاً فرض کرده‌اند که نظرات گره‌ها ثابت و بدون تغییر هستند. همچنین، کمتر به تغییرات زمانی نظرات کاربران پرداخته شده است. در این مقاله، با در نظر گرفتن پویایی نظرات و تغییرات آن در طول زمان، روشی برای مسئله حداکثر سازی پویایی نظرات بر اساس الگوریتم ژنتیک حریصانه پیشنهاد شده است. این روش شامل دو بخش اصلی است. مدل پویایی نظرات فعال شده و فرایند انتخاب گره‌های دانه. مدل پویایی نظرات فعال شده با استفاده از ترکیب مدل انتشار آستانه خطی و یادگیری Q بدون حالت طراحی شده است که تغییرات زمانی نظرات را در نظر می‌گیرد. برای انتخاب گره‌های دانه، الگوریتم ژنتیک حریصانه به کار گرفته شده است. پس از تعیین گره اولیه یا دانه، مدل پویایی نظرات فعال شده آغاز می‌شود. در این مرحله، گره اولیه و همسایگان آن بر اساس مدل انتشار آستانه خطی فعال سازی می‌شوند. سپس با بهره‌گیری از یادگیری Q بدون حالت، نظرات گره‌ها به‌روزرسانی می‌گردند. این فرایند به‌صورت تکرارشونده ادامه می‌یابد تا زمانی که شرایط خاتمه موردنظر برآورده شوند. نتایج تجربی حاصل از آزمایش بر روی چهار مجموعه داده‌ی شبکه‌های اجتماعی امضا شده نشان می‌دهد که روش پیشنهادی در مقایسه با بهترین روش‌های موجود، در معیار تعداد گره‌های فعال 14 درصد و در معیار میانگین نظرات مثبت 27 درصد بهبود عملکرد داشته است.	تاریخچه مقاله: دریافت: 1404/07/26 بازنگری: 1404/08/27 پذیرش: 1404/09/07 ارائه آنلاین: 1404/10/01
	کلیدواژه‌ها: تحلیل شبکه‌های اجتماعی برخط حداکثر سازی پویایی نظرات گره دانه الگوریتم ژنتیک حریصانه یادگیری Q

استناد: رعیت پرور، حسین، حسنی آهنگر، محمدرضا، سرکرده‌ئی، ابوالفضل. ارائه روش بهبودیافته در حداکثر سازی پویایی نظرات مبتنی بر الگوریتم ژنتیکحریصانه. پدافند الکترونیکی و سایبری، ۱۴۰۴، ۱۳(۴)، ص ۳۹-۶۰. <https://doi.org/10.47176/ECDJ.2025.1617>

© نویسنده(گان) حق نشر و حقوق کامل انتشار را برای خود محفوظ می‌دارند.

ناشر: دانشگاه جامع امام حسین(ع).



OPEN ACCESS

1. مقدمه

در عصر فعلی که شبکه‌های اجتماعی به‌عنوان یکی از منابع حیاتی اطلاعات و نظرات کاربران در آن به یکی از ارکان اساسی تصمیم‌گیری‌ها تبدیل شده‌اند، تحلیل و بهینه‌سازی نظرات مختلف کاربران درباره یک موضوع خاص یا یک محصول، به یکی از مسائل بحرانی در حوزه تحلیل شبکه‌های اجتماعی تبدیل شده است. این تحلیل‌ها باهدف بررسی و مقایسه نظرات مثبت و منفی کاربران پیرامون یک موضوع یا محصول خاص انجام شده است [1]. بااین‌حال، این زمینه با چالش‌های فراوانی روبرو است، از جمله پویایی نظرات و پیچیدگی شبکه‌ها [2]. هدف اصلی این تحقیق، بررسی و بهبود نظرات مثبت کاربران درباره یک موضوع یا محصول است [3]. به‌نحوی که این تحلیل‌ها به‌طور مؤثر در فرآیندهای تصمیم‌گیری و ارتقاء کیفیت محتواها در شبکه‌های اجتماعی مورد استفاده قرار گیرد [4-3]. گسترش شبکه‌های اجتماعی برخط، منبع غنی از داده‌های اجتماعی درباره مسائل مختلف جامعه شده است. یکی از مفاهیمی که در حوزه تحلیل شبکه‌های اجتماعی مطرح شده، مسئله حداکثر سازی تأثیر است [5]. در این مفهوم، هدف اصلی این است که با شناسایی افراد یا گره‌های تأثیرگذار در یک شبکه اجتماعی، انتشار اطلاعات در آن شبکه به حداکثر برسد [6]. این مفهوم بر اساس مدل‌های انتشار تشکیل شده و به‌منظور بهبود فرآیند انتشار اطلاعات در شبکه مورد استفاده قرار می‌گیرد [8-7].

حداکثر سازی تأثیر در شبکه‌های اجتماعی به معنای شناسایی افراد کلیدی است که با کمترین هزینه، بیشترین تأثیر را در انتشار اطلاعات و شکل‌دهی افکار عمومی دارند. این افراد مانند جرقه‌ای عمل کرده و تغییرات گسترده‌ای را در شبکه ایجاد می‌کنند [10-9].

این مفهوم با گسترش دامنه‌ی خود، به مباحث پیچیده‌تری همچون حداکثر سازی نظرات و حداکثر سازی پویایی تأثیر نیز ورود کرده است [14]. در حداکثر سازی نظرات، تمرکز بر شناسایی افرادی است که می‌توانند بانفوذ خود، باعث پذیرش گسترده یک نظر خاص شوند [11]. از سوی دیگر، حداکثر سازی پویای تأثیر، با در نظر گرفتن تغییرات زمانی در شبکه‌های اجتماعی، به دنبال شناسایی افرادی است که در هر لحظه می‌توانند بیشترین تأثیر را بر شبکه بگذارند. به‌طور کلی، این مفاهیم به‌منظور درک عمیق‌تر از نحوه شکل‌گیری و انتشار افکار و عقاید در شبکه‌های اجتماعی و طراحی استراتژی‌های مؤثرتر برای تأثیرگذاری بر این شبکه‌ها مورد مطالعه قرار می‌گیرند [12]. مسئله حداکثر سازی پویایی نظرات به‌عنوان یک مفهوم نوظهور در حوزه تحلیل شبکه‌های اجتماعی، با تلفیق دو مسئله حداکثر سازی نظرات و حداکثر سازی پویایی تأثیر شکل گرفته است [11]. هدف اصلی این مسئله، بهینه‌سازی فرآیند انتشار نظرات در یک شبکه اجتماعی با در نظر گرفتن تغییرات نظرات افراد در طول

زمان است. به عبارت دیگر، این مسئله به دنبال شناسایی افرادی است که می‌توانند بانفوذ خود، باعث پذیرش گسترده یک نظر خاص در یک بازه زمانی مشخص شوند. با این رویکرد، می‌توان به درک عمیق‌تری از پویایی نظرات در شبکه‌های اجتماعی دست یافت و استراتژی‌های مؤثرتر و هدفمندتری را برای شکل‌دهی افکار عمومی طراحی نمود [12].

پویایی نظرات و تعاملات کاربران در شبکه‌های اجتماعی، موضوعی کلیدی در مطالعات علوم اجتماعی و رایانه است [15]. علیرغم پژوهش‌های متعدد در حوزه شبکه‌های اجتماعی، مطالعات جامع در زمینه مدیریت و هدایت پویایی نظرات کاربران همچنان محدود است [13]. در این پژوهش، به بررسی مسئله حداکثر سازی پویایی نظرات در شبکه‌های اجتماعی پرداخته‌ایم. هدف اصلی، یافتن روش‌هایی برای افزایش نظرات مثبت و تأثیرگذاری بر افکار عمومی در محیط‌های برخط است [16]. با مطالعه ادبیات موجود و تحلیل شبکه مقالات علمی، به این نتیجه رسیدیم که یکی از چالش‌های اصلی در این حوزه، مدل‌سازی دقیق فرآیند انتشار نظرات و یافتن استراتژی‌های مناسب برای انتخاب افراد تأثیرگذار است.

برای رفع این چالش، یک مدل ریاضی جامع برای مسئله حداکثر سازی پویایی نظرات ارائه دادیم. سپس، با استفاده از الگوریتم ژنتیک حریصانه و تلفیق آن با مدل یادگیری تقویتی Q -learning، یک روش برای حل این مسئله پیشنهاد کردیم. این روش به ما امکان می‌دهد تا با شناسایی افراد تأثیرگذار (دانه‌ها) و طراحی استراتژی‌های مناسب، نظرات مثبت را در شبکه گسترش دهیم.

نتایج آزمایش‌ها بر روی مجموعه داده‌های واقعی نشان داد که روش پیشنهادی عملکرد بسیار خوبی دارد و می‌تواند به‌طور مؤثری نظرات مثبت را در شبکه اجتماعی افزایش دهد. این یافته‌ها نشان می‌دهد که روش پیشنهادی می‌تواند در حوزه‌های مختلفی مانند بازاریابی، سیاست و اطلاع‌رسانی مورد استفاده قرار گیرد.

2. روش تحقیق


در این بخش، پس از بررسی جامع ادبیات پژوهش و شناسایی شکاف‌های موجود در دانش، روش‌شناسی تحقیق حاضر ارائه می‌شود.

2-1. کارهای مرتبط


در این پژوهش، منابع مورد استفاده در سند تحقیقی بر اساس اصول منبع‌شناسی ارائه شده است. این اصول بر فهرستی از کتب، مقالات، وب‌سایت‌ها و دیگر منابع مرتبط با تحقیق، که در انتهای سند آمده است، استوار است. فهرست مذکور به خوانندگان امکان می‌دهد تا به‌طور مستقل جزئیات مربوط به منابع استفاده‌شده در تحقیق را بیابند و بدین ترتیب، اعتبار و اصالت کار تحقیقی تأیید

ترسیم و تحلیل شد. این روش تحقیقی، تصویری دقیق از منابع مورد استفاده در تحقیق ارائه می‌دهد و از اهمیت اصالت و اعتبار کار تحقیقی در این پژوهش تأکید می‌کند. تأکید بر مشخص کردن مقالات پر کاربرد و داغ در حوزه تحقیق، نقشی مهم در تدوین مسیر و تحلیل دامنه تحقیقات فعلی ایفا می‌کند.

گردد. جهت تعیین حدود و دامنه تحقیق، از مخازن مقالات موجود در اینترنت استفاده شد و تقریباً صد مقاله انتخاب و جمع‌آوری گردید. سپس، کلمات کلیدی هر مقاله استخراج و جدول یال میان مقالات ایجاد شد. نهایتاً، با بهره‌گیری از نرم‌افزار گفی، با توجه شکل (1- الف و ب)، گراف استناد مقالات به یکدیگر و گراف مقالات بر اساس ارجاعت




(الف) گرافی از ارتباط مقالات بر اساس کلمات کلیدی



(ب) گراف ارجاعات مقالات به یکدیگر
 شکل (۱). گراف‌های رسم شده برای مقالات این حوزه

موضوعات یا زمینه‌های تحقیقاتی موجود در مجموعه داده ارائه می‌دهد.

در مرحله بعد، با توجه به شکل (۲) توزیع مقالات به خوشه‌ها موردبررسی قرار می‌گیرد تا مشخص شود چند انجمن یا خوشه مجزا از مقالات به‌هم‌پیوسته وجود دارد. این تحلیل، ایده‌ای از




شکل (۲). توزیع مقالات در جوامع شناسایی شده

به‌صورت قابل‌توجهی حضور دارند. این موضوع نشان‌دهنده آن است که حوزه حداکثر سازی تأثیر، که شامل حداکثر سازی

در بررسی داده‌های مرتبط با مقالات، نکته برجسته این است که مقالات مربوط به جامعه هشت در حوزه حداکثر سازی تأثیر

تفاوت‌های بین آن‌ها کمک می‌کند. بررسی نمودار پراکنش، امکان تحلیل تفاوت‌ها و الگوهای مختلف بین مقادیر پیج رنک بر اساس ماژولاریتی کلاس را فراهم می‌سازد. این تحلیل می‌تواند در شناسایی مناطقی از داده‌ها که تفاوت‌های چشمگیری نسبت به بقیه دارند، مؤثر باشد. همچنین این تحلیل کمک می‌کند تا مشخص شود آیا مقادیر پیج رنک بر اساس ماژولاریتی کلاس‌ها متفاوت هستند یا خیر.

پویایی نظرات و حداکثر سازی نظرات می‌شود، درون یک جامعه قرار گرفته‌اند و نشان‌دهنده این است که این مسائل توسعه‌ای از حداکثر سازی تأثیر محسوب می‌شود. با توجه به شکل (3)، رابطه بین پیج رنک مقالات و ماژولاریتی کلاس آن‌ها مورد بررسی قرار می‌گیرد تا جوامع مرتبط با یکدیگر شناسایی شوند. با تحلیل نمودار پراکنش بین ماژولاریتی کلاس و پیج رنک، می‌توان الگوهایی را کشف کرد که نمایانگر روابط میان گروه‌های مختلف داده‌ها هستند. این تحلیل به شناسایی گروه‌های مرتبط و درک



شکل (3). نمودار پراکنش پیج رنک و ماژولاریتی کلاس مقالات

تولید نظرات بهینه گره است. هدف دیگر این چارچوب پیشنهادی این است که فرایند شبکه را در طول زمان پویا در نظر می‌گیرد و بر روی روابط اجتماعی بین کاربران هم متمرکز است. این چارچوب، از دو بخش کار تشکیل شده است که در بخش اول مدل نظر پویای فعال‌شده مبتنی بر یادگیری تقویتی و در بخش دوم فرایند پیدا کردن گره‌های دانه مبتنی بر یادگیری تقویتی است. در مدل نظر پویای فعال‌شده فرایند فعال‌سازی با نظرات پویا ترکیب شده است. نتایج ارزیابی این چارچوب نشان می‌دهد که این چارچوب نسبت به نظرات مثبت و گره‌های فعال‌شده بهتر عمل می‌کند.

در مقاله [17] یک چارچوب حداکثر سازی نظرات در شبکه اجتماعی علامت‌دار ارائه دادند. این چارچوب شامل 2 بخش است. بخش اول برای فعال‌سازی نظر به‌صورت پویا که مبتنی بر یادگیری تقویتی است و بخش دوم یک فرایند پیدا کردن گره برای مجموعه دانه مبتنی بر یادگیری تقویتی بر اساس استراتژی حریف ناشناخته است. هدف از این چارچوب این است که یک

با توجه به شکل (3) در جامعه هشت، مقالات علمی و پژوهشی از اهمیت بسیاری برخوردارند. این مقالات، به‌عنوان نمایندگان اصلی دانش و تحقیقات در این حوزه، نقش مهمی در توسعه دانش و فهم مسائل جامعه ایفا می‌کنند. برخی از این مقالات، به‌عنوان مقالات پایه معرفی می‌شوند که نقش دانه در تکامل مفاهیم و نظریه‌ها دارند. مقالات پایه به دلیل موضوعات عمیق و کارآمدی که بررسی می‌کنند، برتری در مقایسه با سایر مقالات دارند و اغلب موضوعاتی را که اساس و اصول یک حوزه علمی را شکل می‌دهند، مورد بررسی قرار می‌دهند. این مقالات پایه، تأثیر طولانی‌مدتی در تکامل و پیشرفت حوزه‌های علمی دارند و از اهمیت ویژه‌ای برخوردارند.

با اتکا بر تحلیل‌های آماری جامع و شناسایی مقالات برجسته در سه حوزه کلیدی حداکثر سازی تأثیر، حداکثر سازی نظرات و حداکثر سازی پویایی نظرات، منابع شناسایی و به کارهای مرتبط پرداخته می‌شود.

در مقاله [11] یک چارچوب حداکثر سازی نظرات پویا باهدف انتخاب برخی از گره‌ها در شبکه و حذف نظرات گره‌های شبکه و

از لحاظ حداقل رساندن نظرات در توزیع نظرات حالت پایدار بهتر عمل می‌کند.

در مقاله [21] یک رویکرد حداکثر سازی نظر را برای شبکه‌های اجتماعی علامت‌دار، وزن‌دار و جهت‌دار با مدل انتشار آستانه خطی چندمرحله‌ای برای انتشار اطلاعات ارائه کرده‌اند. گره‌های دانه وظیفه انتشار نظرات موردنظر در شبکه بر عهده‌دارند. سه رویکرد پیشنهاد می‌دهند که در رویکرد اول یک فرایند اکتشافی برای انتخاب گره‌های دانه کاندید با استفاده از معیارهای مرکزیت و در رویکرد دوم شبکه را به جوامع تقسیم می‌کند و یک فرایند اکتشافی برای محاسبه تأثیر گره‌ها در جوامع برای انتخاب گره‌های دانه کاندید توسعه داده شده است و در رویکرد سوم تشخیص جامعه را با استفاده از معیار مرکزیت ترکیب می‌کند.

در مقاله [22] با توجه به اینکه مسائل حداکثر سازی نظرات کارایی بالا و دقت پایدار آن به‌سختی محاسبه می‌شود، رویکردی مبتنی بر جوامع شبکه‌های اجتماعی ارائه داده‌اند. مدل نظر را مبتنی بر وزن موجود در شبکه و ارتباطات گره‌ها برای تخمین تغییرات پویای نظرات است و برای دستیابی به گره‌های تأثیرگذار مبتنی بر جامعه عمل می‌کند. در این مقاله برای هر یک از جوامع تأثیر را بر اساس همسایگان آن به دست می‌آورد. با اندازه‌گیری 2-پرش و حذف تأثیر همپوشانی برای تعیین گره‌های دانه توسعه داده شده است.

در مقاله [23] با توجه به ساختار شبکه‌های اجتماعی که نامنظم، پیچیده و پویا است، حداکثر سازی تأثیر کلاسیک را با پویایی در نظر گرفته‌اند. از الگوریتم ژنتیک تعمیم‌یافته پویا تحت مدل انتشار آبخاری مستقل برای به دست آوردن مجموعه دانه پویا استفاده شده است. نتایج این مقاله مقیاس‌پذیری و دقت بالاتری برای شناسایی گره‌های تأثیرگذار نمایش داده است.

در مقاله [24] یک رویکرد تکراری برای حداکثر سازی تأثیر برای یافتن مجموعه دانه در شبکه‌های پیچیده ارائه کردند. در این مقاله گره‌های دانه اولیه را با در نظر گرفتن اهمیت آن در شبکه محلی و ارتباطات سراسری آن در شبکه انتخاب می‌شود. گره‌های دیگر بر اساس شاخص تشابه جوامع خاص اختصاص داده شده است. همچنین یک استراتژی جستجوی تطبیقی برای یافتن راه‌حل بهینه استفاده می‌کند.

در مقاله [25] یک الگوریتم تکاملی محدود مبتنی بر شاخص تأثیر محلی سراسری برای حداکثر سازی تأثیر هزینه ارائه کردند و در این مقاله یک شاخص تأثیر جدید مبتنی بر اطلاعات همسایگان محلی و اطلاعات جامعه برای اندازه‌گیری تأثیر گره‌ها ارائه شده است. در چارچوب تکاملی محدود را با طراحی چندین استراتژی جدید مانند استراتژی جهش، استراتژی متقاطع و استراتژی تعمیر برای ارتقای تکامل جمعیت است.

در مقاله [26] رویکردی برای حداکثر سازی نظر دلخواه در مورد یک محصول یا ایده (حداکثر سازی نظر رقابتی) در شبکه‌های

مدل انتشار انعطاف‌پذیرتر و هوشمندتر و یک طرح یافتن گره‌های شاخص به‌صورت پویا را تنظیم کند، است.

در مقاله [18] یک چارچوب ترکیبی مؤثر برای حداکثر سازی نظرات پویا طراحی کرده‌اند. این چارچوب بر اساس وضعیت فعال‌سازی با مدل آستانه خطی و یک فرایند نظرات پویا با مدل وزن‌دار هگس‌لن-کراز و یک مدل نظر فعال می‌کند. یک چارچوب برای انتخاب گره‌های دانه که شامل تشخیص جامعه، تعیین گره‌های دانه کاندید و الگوریتم یافتن گره‌های دانه با الگوریتم *PSO* بر اساس استراتژی جایگزینی طراحی شده است. ارزیابی این چارچوب بر پایه میانگین نظرات و تعداد گره‌های فعال نسبت به الگوریتم‌های *Atom*، *RIS* و *CELF* است.

در مقاله [19] یک چارچوب باهدف ترکیب گره‌های فعال شده و فرایند شکل‌گیری نظر پویا است و در نظر گرفتن روابط منفی بین گره‌ها است. چارچوب حداکثر سازی نظرات فعال شده در شبکه اجتماعی علامت‌دار از سه بخش تشکیل شده است. در بخش اول گره‌های دانه کاندید انتخاب شده است. در بخش دوم فرایند تشکیل نظرات فعال شده، مدل‌سازی می‌شود. در بخش سوم گره‌های کاندید را تعیین می‌کند. یک قانون اکتشافی مؤثر برای انتخاب گره‌های دانه کاندید استفاده می‌شود و برای مدل‌سازی فرایند فعال‌سازی و شکل‌دهی پویای نظرات است. یک مدل نظرات فعال شده بر اساس مدل آستانه خطی چند مرحله و مدل *Degroot* طراحی شده است. روش پیشنهادی نظرات بالقوه رقابتی و پیچیدگی محاسباتی کمتری را در مقایسه با الگوریتم‌های حریصانه به دست می‌آورد.

در مقاله [12] یک چارچوب حداکثر سازی نظرات را طراحی کرده‌اند که هدف آن در نظر گرفتن پویا بودن شکل‌گیری نظرات و حل چالش برآورده نکردن دو ویژگی یکنواختی و زیرمدولار بودن مسئله حداکثر سازی تأثیر است. این رویکرد از دو بخش تشکیل شده است که در بخش اول شکل‌گیری نظرات با در نظر گرفتن پویای آن که به‌صورت همکاری است. در بخش دوم فرایند یافتن گره‌های دانه را با حداکثر کردن مسئله حداکثر سازی نظرات به‌صورت تطبیقی است. نتایج نشان داده است که رویکرد پیشنهادی نظر منطقی که منتشر می‌شود را نسبت به روش‌های موجود بهبود می‌بخشد.

در مقاله [20] یک الگوریتم طراحی کردند باهدف در نظر گرفتن دانش افراد برای انتشار اطلاعات و پویایی نظرات هر فرد است. این الگوریتم پیشنهادی در مرحله ابتدایی یک مدل انتشار رقابتی به‌صورت پویا است و در مرحله بعدی یک‌روند خودکار و ارتباطی برای تجزیه و تحلیل فرایند انتقال نظر کاربران بر اساس زنجیره مارکوف زمان گسسته است و برای حداقل کردن نظرات منفی یک الگوریتم حریصانه برای انتخاب گره‌های دانه است. نتایج نشان می‌دهد که این رویکرد نسبت به الگوریتم‌های سنتی،

گره‌های درون به صورت بهینه و حداکثر باشد. در نهایت هدف به شرح زیر است:

$$F(S,t) = \operatorname{argmax} \sum_{v_i \in V} X_i(t) \quad (1)$$

$$S = \cup \{ \gamma_i v_i \} \quad (2)$$

$$\gamma_i = \begin{cases} 1 & \text{if } v_i \text{ seed node} \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

$$\sum \gamma_i = m \quad (4)$$

در رابطه‌های (1) تا (4)، هدف انتخاب مجموعه‌ای از گره دانه^۱ به نحوی است که مجموع نظرات مثبت در شبکه به حداکثر برسد. تابع $F(S,t)$ بیانگر بیشینه سازی مجموع نظرات $X_i(t)$ برای تمام گره‌ها v_i در مجموعه V در زمان t است. متغیر γ_i مشخص می‌کند که آیا گره v_i به عنوان یک گره اولیه انتخاب شده است یا خیر (۱ اگر گره اولیه باشد و ۰ در غیر این صورت). شرط $\sum \gamma_i = m$ نیز محدودیت تعداد گره‌های اولیه را تعیین می‌کند.

2-3. روش کار

مشابه مسئله حداکثر سازی نفوذ سنتی، مسئله حداکثر سازی پویایی نظرات نیز از پی - سخت است. بنابراین، چارچوب حداکثر سازی پویایی نظرات مبتنی بر الگوریتم ژنتیک حریصانه را پیشنهاد می‌کنیم که شامل یک مدل پویایی نظر فعال و یک الگوریتم انتخاب گره دانه مبتنی بر الگوریتم ژنتیک حریصانه است (شکل 4). به طور خاص، مدل پویایی نظر فعال از نظریه یادگیری تقویتی بدون حالت Q-learning استفاده می‌کند، درحالی که ما یک الگوریتم Seeding مبتنی بر الگوریتم ژنتیک حریصانه را برای انتخاب گره‌های بذر به صورت تطبیقی پیشنهاد می‌کنیم. در ادامه، مدل پویایی نظر فعال و الگوریتم Seeding مبتنی بر الگوریتم ژنتیک حریصانه را به تفصیل معرفی خواهیم کرد.

در این پژوهش، برای آغاز فرایند شبیه سازی و ارزیابی عملکرد روش پیشنهادی، به هر گره در شبکه یک نظر اولیه به صورت تصادفی نسبت داده شده است. این مقداردهی اولیه، به عنوان یک شرط آغازین برای سنجش توانایی مدل در تغییر و تکامل نظرات گره‌ها در طول زمان تلقی می‌شود.

اجتماعی می‌پردازند. یک چارچوب جدیدی (QOMF) پیشنهاد می‌کند که رقابت و کاربرانی را که ممکن است نظرشان را تغییر دهند، در نظر می‌گیرد. QOMF دارای دو بخش است، مدلی که نحوه انتشار نظرات را نشان می‌دهد و روشی برای انتخاب بهترین افراد برای شروع انتشار نظر (گره‌های دانه). مدل به گونه‌ای طراحی شده است که واقع بینانه باشد و این روش استراتژی‌های رقیب شناخته شده و ناشناخته را در نظر می‌گیرد. در آزمایش‌ها، QOMF از روش‌های دیگر برای دستیابی به نظر مطلوب بهتر عمل کرد.

2-2. بیان مسئله

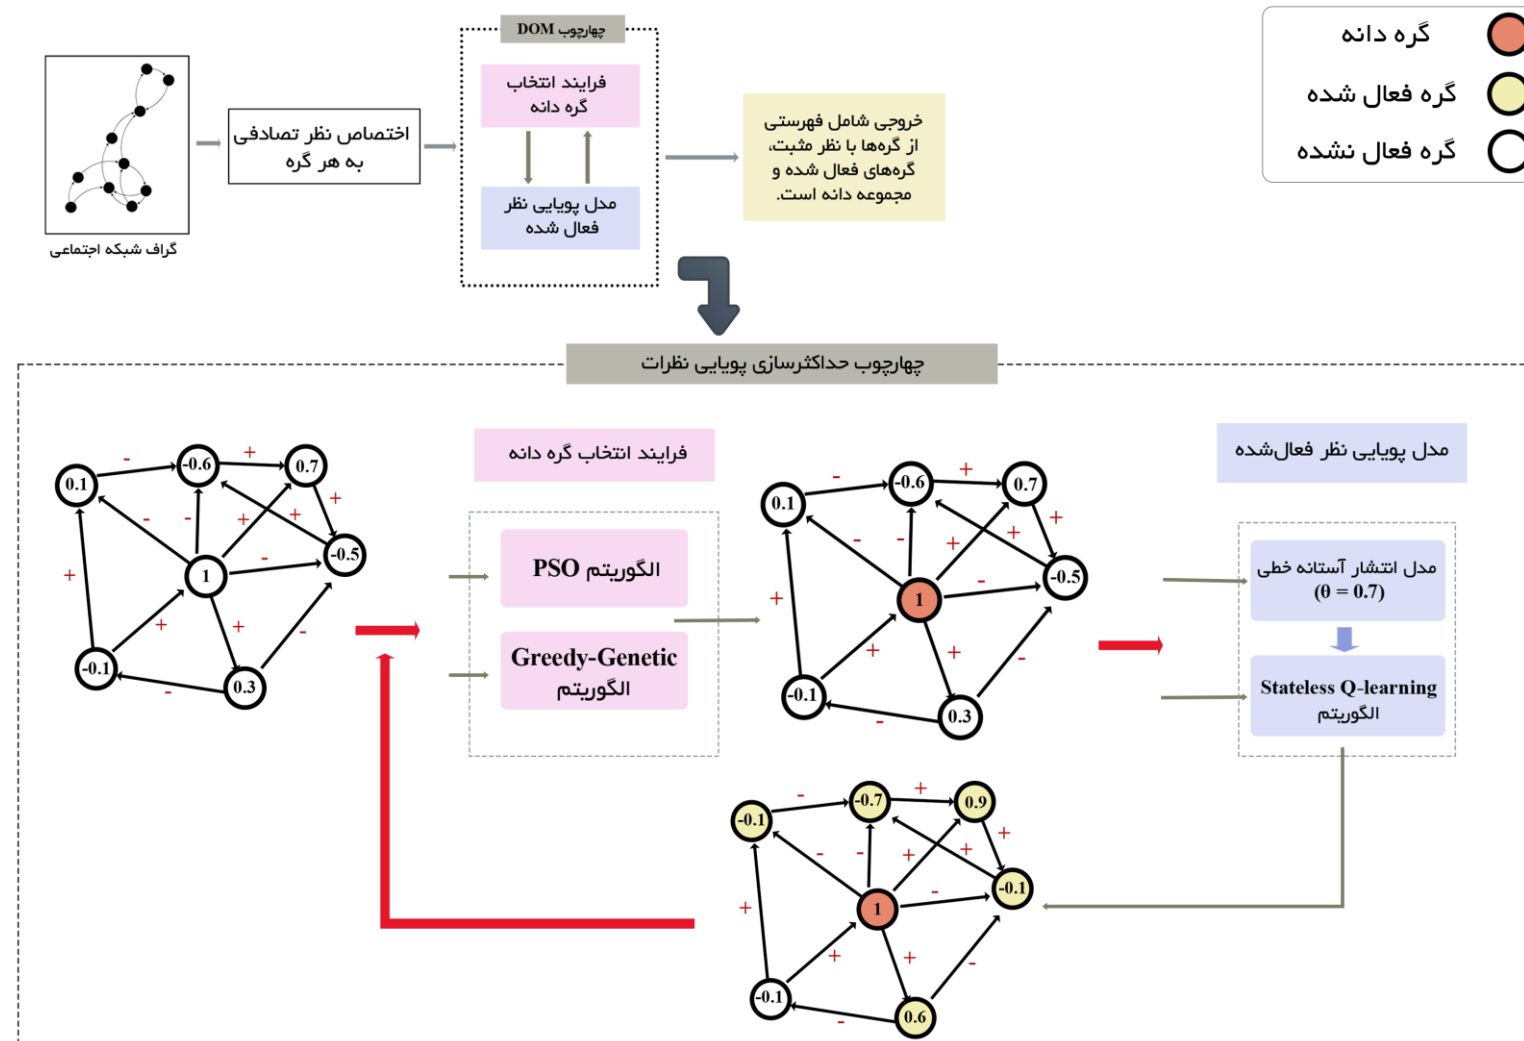
با توجه به پویایی نظرات کاربران در شبکه اجتماعی، دو مدل برای رویکرد پیشنهادی طراحی شده است که عبارت‌اند از:

- مدل برای انتخاب گره‌های دانه مبتنی بر الگوریتم

ژنتیک حریصانه

- مدل برای نظرات پویای فعال شده

حال با توجه به هدف این پژوهش، ارائه دو مدل فوق و ترکیب آن‌ها می‌تواند مسئله حداکثر سازی نظرات را حل کند. در این مسئله مجموعه داده نگاشت به $G=(V,E)$ است که $V=\{v_1, v_2, v_3, \dots, v_N\}$ مجموعه کاربران شبکه اجتماعی و $E=\{e_1, e_2, e_3, \dots, e_M\}$ مجموعه روابط بین کاربران که با توجه به شرایط شبکه متفاوت است. N نشان دهنده تعداد گره‌ها و M نشان دهنده تعداد یال‌ها است. X_i نشان دهنده نظر گره i است که $-1 \leq X_i \leq +1$ است. در ابتدای کار برای هر گره به صورت تصادفی نظری تعیین می‌شود. پس از آن می‌بایست مجموعه اولیه خود را ساخته تا بتوان آن را بهینه کرد. مجموعه اولیه با S نمایش داده می‌شود. حال با توجه به گره‌های دانه انتخاب شده به وسیله الگوریتم ژنتیک، گره‌های دانه به دست آورده می‌شوند. هدف از الگوریتم‌های ژنتیک پیشنهاد شده انتخاب گره‌های دانه است. پس از اینکه گره دانه مشخص شد نیازمند این است که با پویا در نظر گرفتن نظر، فعال شود و مقدار جدید نظر آن محاسبه شود. شرط خاتمه، زمانی که مجموعه اولیه به دست آمده نظرات



شکل (4). معماری رویکرد پیشنهادی

3-2-1. الگوریتم Seeding

این بخش مدلی را برای انتخاب مجموعه‌ای از گره‌های تأثیرگذار، که به‌عنوان «مجموعه اولیه یا دانه» نامیده می‌شود، در یک شبکه اجتماعی توصیف می‌کند. این گره‌های دانه نقش مهمی در تأثیرگذاری بر پویایی نظرات کلی و هر کاربر شبکه دارند. در این پژوهش، به‌منظور انتخاب بهینه گره‌های دانه در آغاز فرایند انتشار نظر، از الگوریتم ژنتیک حریصانه استفاده شده است. در این الگوریتم، هر کروموزوم نشان‌دهنده مجموعه‌ای از گره‌های دانه است. با اعمال عملگرهای ژنتیکی مانند انتخاب، ترکیب و جهش بر روی این کروموزوم‌ها و ارزیابی تناسب هر کروموزوم (بر اساس میزان تأثیرگذاری گره‌های دانه بر گسترش نظر)، به‌تدریج مجموعه‌های مختلفی از گره‌های دانه را تولید و ارزیابی می‌کند تا در نهایت به مجموعه‌ای بهینه دست یابد که بتواند با بیشترین کارایی، نظر موردنظر را در شبکه منتشر نماید. دلیل استفاده از حریصانه بودن در این الگوریتم ژنتیک دلایل زیر است:

- کاهش پیچیدگی محاسباتی: الگوریتم حریصانه، به‌عنوان یک الگوریتم ساده و مستقیم، کمترین تعداد محاسبات را برای رسیدن به راه‌حل بهینه انجام می‌دهد. این باعث می‌شود که زمان اجرای الگوریتم کاهش یابد، که به‌خصوص در مسائل با ابعاد بزرگ مهم است. همچنین، الگوریتم ژنتیک می‌تواند پیچیده باشند و پیاده‌سازی و اجرا آن‌ها دشوار باشد. ترکیب این ژنتیک و حریصانه می‌تواند این ضعف را از بین ببرد.
- کارایی: الگوریتم حریصانه معمولاً به‌سرعت به راه‌حل‌های خوب می‌رسد، به‌ویژه اگر محدودیت‌های زمانی و محاسباتی وجود داشته باشد. در بسیاری از موارد، راه‌حلی که توسط الگوریتم حریصانه ارائه می‌شود، به‌طور قابل قبولی بهینه است.

با توجه به شکل (5)، در الگوریتم ژنتیک طراحی شده برای مسئله یافتن گره‌های دانه تأثیرگذار در گراف، ساختار کروموزوم به‌صورت بهینه‌ای طراحی شده است. هر کروموزوم به شکل یک آرایه از اعداد صحیح نمایش داده می‌شود، که در آن هر عدد منحصرأ نشان‌دهنده شماره یک گره خاص و دانه در گراف است. این ساختار فشرده و کارآمد، امکان نمایش مستقیم مجموعه گره‌های کاندید را فراهم می‌کند. طول این آرایه، که معادل با تعداد

ژن‌های کروموزوم است، دقیقاً برابر با تعداد گره‌های دانه موردنظر در مسئله تعیین می‌شود. این طراحی، ضمن تضمین تطابق یک‌به‌یک بین ژن‌ها و گره‌های دانه، امکان جستجوی مؤثر در فضای راه‌حل را با حفظ محدودیت‌های مسئله فراهم می‌آورد.

مراحل این مدل به‌صورت زیر است:

1) ایجاد جمعیت اولیه: یک مجموعه از گره‌ها به‌صورت حریصانه که در مجموعه اولیه نیستند، به‌عنوان جمعیت اولیه ایجاد می‌شود. این کار با انتخاب حریصانه گره‌ها از میان گره‌هایی که در مجموعه اولیه نیستند و ایجاد مجموعه‌های تک گره‌ای برای هر فرد در جمعیت انجام می‌شود. به‌عنوان مثال، اگر مجموعه اولیه شامل گره‌های A و B باشد، از میان گره‌هایی که در G وجود دارند انتخاب‌های حریصانه انجام می‌شود و سپس برای هر فرد در جمعیت یک مجموعه تک گره‌ای (به‌عنوان مثال، {C} یا {D}) ایجاد می‌شود.

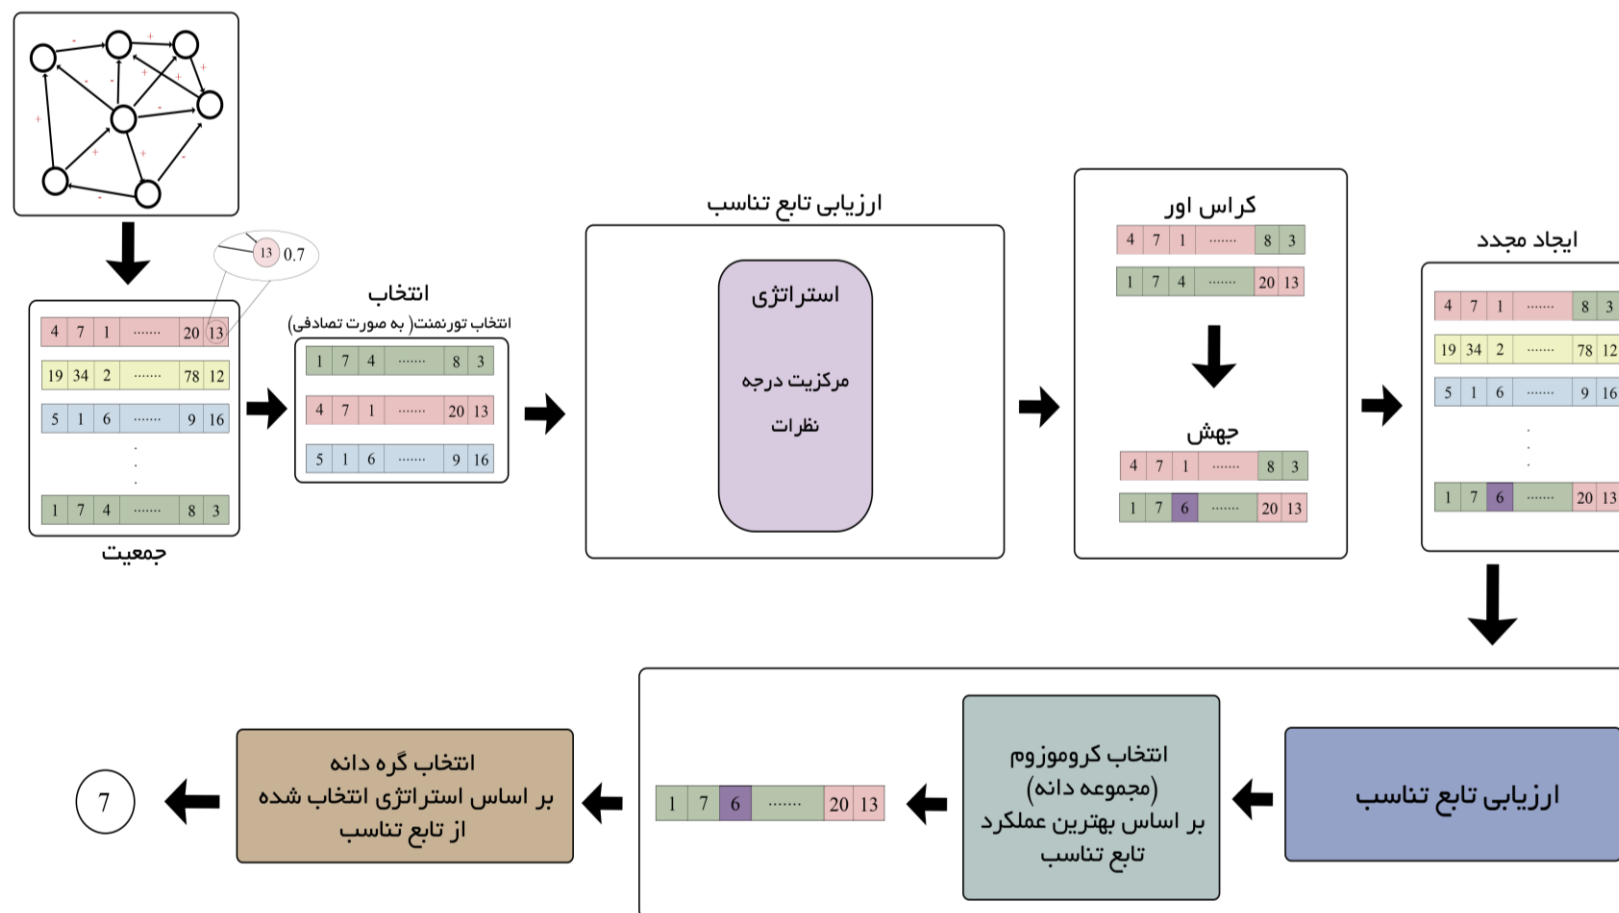
این جمعیت اولیه سپس برای اجرای الگوریتم ژنتیک که مبتنی بر حریصانه است، مورد استفاده قرار می‌گیرد.

2) تعریف تابع Fitness:

در این بخش برای تابع تناسب از استراتژی نظر گره یا کاربر به‌عنوان ضریبی برای مرکزیت درجه استفاده کردیم. این تابع تناسب هر کاندیدی گره دانه را ارزیابی می‌کند. تناسب باید بر اساس معیاری باشد که نشان می‌دهد یک گره چقدر برای تبدیل شدن به یک گره دانه مناسب است. این معیار می‌تواند ترکیبی از عوامل مختلف مانند درجه گره، خوشه‌بندی مرکزی یا یک امتیاز نظر اختصاصی باشد. در این استراتژی، برای تعریف تابع تناسب در ابتدا از درجه گره استفاده شد که نتایج به‌دست‌آمده مطلوب نبودند. پس با مرکزیت درجه تغییر داده شد که به دلیل اینکه مرکزیت درجه برای هر گره ثابت است نتایج به‌دست‌آمده ثابت بودند. پس با بررسی انجام‌شده و اعمال پویایی مسئله رابطه زیر برای تابع تناسب به دست آمد:


$$\text{Fitness}(\text{individual}) = X_{\text{individual}} \times DC_{\text{individual}} \quad (5)$$

دلیل استفاده از نظر هر گره برای ضریب مرکزیت درجه این است که برای افزایش تعداد گره‌های با نظر مثبت نیازمند گره‌هایی با نظر مثبت هستیم که دارای ضریب نفوذ بالایی هستند، پس برای انتخاب گره دانه از نظر هر گره و مرکزیت درجه آن گره که اهمیت یک گره توسط تعداد گره‌هایی که به آن متصل هستند تعیین می‌شود.




شکل (5). مراحل انجام الگوریتم ژنتیک

با افزایش بیشتر نرخ جهش، احتمال ایجاد نظرات جدید به طور قابل توجهی کاهش می یابد.



شکل (۶). نمودار نرخ ترکیب و جهش بر تعداد تولید نسل



شکل (۷). نمودار نرخ ترکیب و جهش نسبت به تابع تناسب

3-4) انتخاب نسل بعدی: کاندیداهای برتر از نسل فعلی و فرزندان جهش یافته به عنوان نسل بعدی انتخاب می شوند. 3-5) انتخاب بهترین گره دانه: در مرحله نهایی الگوریتم ژنتیک برای انتخاب گره های دانه تأثیرگذار، پس از اعمال عملگرهای ژنتیک و ارزیابی مجدد جمعیت، کروموزم با بالاترین مقدار تابع تناسب به عنوان راه حل بهینه انتخاب می گردد. این کروموزم منتخب، حاوی اطلاعات ژنتیکی مربوط به مجموعه گره های دانه با بیشترین تأثیرگذاری است. سپس، با استفاده از استراتژی برگزیده شده از تابع تناسب، که می تواند شامل معیارهایی چون مرکزیت درجه، قابلیت مسدودسازی یا ترکیبی از استراتژی های مختلف باشد، گره های دانه تأثیرگذار از این کروموزم استخراج و به عنوان راه حل نهایی مسئله ارائه می شوند.

در چارچوب الگوریتم ژنتیک برای انتخاب گره های دانه تأثیرگذار، هر ژن در کروموزم نماینده یک گره کاندید است. پس از اتمام چرخه های تکاملی، ژنی که بالاترین مقدار تابع تناسب را در نسل نهایی کسب کرده، به عنوان برترین ژن شناخته می شود. این ژن منتخب، که معرف یک گره دانه بهینه است، به مجموعه ژن های اصلی کروموزم افزوده می گردد. این فرآیند انتخاب ماهیتی حریصانه دارد، زیرا الگوریتم صرفاً به دنبال شناسایی و گزینش

3) الگوریتم ژنتیک:

در هر تکرار، نسل جدیدی از کاندیداهای گره دانه با استفاده از مراحل زیر ایجاد می شود: 3-1) انتخاب:

با توجه به شکل (5)، در الگوریتم ژنتیک برای مسئله یافتن گره های دانه تأثیرگذار، کروموزم نشان دهنده مجموعه اولیه گره های کاندید است. هر ژن در این کروموزم معرف یک گره از گراف است که در ترکیب با سایر ژن ها، بهینه ترین مجموعه دانه را تشکیل می دهد. فرآیند انتخاب والدین از جمعیت اولیه به روش انتخاب تورنمنتی صورت می گیرد. در این روش، به جای گزینش مستقیم بهترین فرد از کل جمعیت، زیرمجموعه ای تصادفی (تورنمنت) انتخاب شده و سپس مناسب ترین فرد از این زیرمجموعه به عنوان والد برگزیده می شود. این فرآیند برای انتخاب هر دو والد تکرار می گردد.

3-2) ترکیب:

در این مرحله، دو والد می توانند فرزندان را با تبادل بخشی از اطلاعات خود ایجاد کنند. هدف از ترکیب در این مدل این است که تنوع ژنتیکی در جمعیت را افزایش دهد و از گیرکردن الگوریتم در مینیمم محلی جلوگیری کند. با ترکیب ویژگی های مختلف از والدین، احتمال به دست آمدن بهترین گره به عنوان یک گره دانه نیز افزایش می یابد. با توجه به حریصانگی الگوریتم، معمولاً تعداد کمتری از ترکیب ها انجام می شود یا اینکه به صورت حریصانه و تصادفی برای ترکیب استفاده می شود.

3-3) جهش:

با احتمال نرخ جهش، هر فرزند ممکن است جهش یابد. با توجه به شکل (6) و (7)، نرخ جهش تعیین شده در این مدل 0.5 است. دلایل انتخاب این مقدار به شرح زیر است:

- نقطه تقاطع: در این نمودارها، دو خط نرخ جهش و نرخ ترکیب در نقطه ای با نرخ 0.5 به هم می رسند البته در شکل (7)، نقطه 0.115 هم تقاطع مشاهده می شود اما با توجه به اینکه به دنبال حداکثر کردن تابع تناسب هستیم در مقدار 0.5 این مهم محقق می شود.
- نمودار نرخ جهش: در شکل (6)، محدوده نرخ جهش 0 تا 0.5، نرخ جهش به طور پیوسته در حال افزایش است. این بدان معناست که با افزایش نرخ جهش در این محدوده، می توان انتظار داشت که تعداد نظرات جدید نیز افزایش یابد. همچنین در شکل (7)، بعد از تقاطع در 0.5 با افزایش نرخ جهش تابع تناسب تغییر نمی کند بلکه به مرور با افزایش به سمت صفر نزدیک می شود.
- نمودار نرخ ترکیب: پس از رسیدن به نرخ 0.5، نرخ ترکیب شروع به کاهش می کند. این نشان می دهد که

$$A(v, t) = \begin{cases} 1 & \text{if } \sum_{u \in N(v)} w(u, v) * O(u, t-1) \geq \theta(v) \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

در رابطه (6)، $A(v, t)$ وضعیت فعال بودن گره v در زمان t را نشان می‌دهد (1 برای فعال و 0 برای غیرفعال). $N(v)$ مجموعه همسایگان گره v است و $w(u, v)$ قدرت تأثیرگذاری بین گره‌های u و v را نشان می‌دهد ($O(u, t-1)$ نظر گره u در زمان قبلی- t) (1 است و $\theta(v)$ آستانه‌ای است که برای فعال شدن گره v در نظر گرفته شده است (در این مطالعه، این آستانه برابر با 0.7 است). t نیز نشان‌دهنده گام زمانی فعلی است. این رابطه نشان می‌دهد که اگر مجموع تأثیر وزن دار نظرات همسایگان یک گره در زمان $t-1$ از آستانه $\theta(v)$ بیشتر یا مساوی باشد، آن گره در زمان t فعال می‌شود.

(2) تابع سیگموئید:

ما از یک تابع سیگموئید برای به دست آوردن قدرت تأثیرگذاری بین گره‌های متصل استفاده می‌کنیم. تابع سیگموئید تأثیرگذاری خام (به عنوان مثال، امتیازدهی) را به یک مقدار بین 0 و 1 نگاشت می‌کند. تابع سیگموئید یک تابع فعال‌سازی است که معمولاً برای تبدیل ورودی‌هایی که مقادیر آن‌ها در بازه‌ای خاصی قرار دارد به مقادیری بین 0 و 1 استفاده می‌شود. این تابع به صورت ریاضی (7) تعریف می‌شود. در مدل پویای نظرات، این تابع برای محاسبه احتمال فعال‌سازی گره‌ها استفاده می‌شود. به عبارت دیگر، با ورودی دادن تأثیر تجمعی از نظرات همسایه یک گره به تابع سیگموئید، می‌توانیم احتمال فعال‌سازی آن گره را محاسبه کنیم که بر اساس آن تصمیم‌گیری می‌کنیم که آیا آن گره فعال شود یا خیر.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

(3) به روزرسانی Q-learning بدون حالت:

در اینجا، با الهام از یادگیری تقویتی، ما مقادیر Q را برای هر گره در گراف معرفی می‌کنیم. هدف اصلی این روش، تسهیل همگرایی یا واگرایی نظرات گره‌ها بر اساس تعاملات محلی آن‌ها با همسایگان و در نهایت، حداکثر سازی پویایی نظرات در شبکه است. برای هر گره در شبکه، مقدار Q به عنوان معیاری جهت ارزیابی ارزش آن گره تعریف می‌شود. این مقدار نشان‌دهنده انتظارات گره از تأثیر نظرات همسایگان بر نظر خودش است. مقدار Q هر گره بر اساس تعاملات محلی با همسایگان و تغییرات مثبت یا منفی در نظرات آن به روزرسانی می‌شود. در این روش بدون حالت، فضای حالت به صورت ضمنی و بر اساس تعاملات با همسایگان مشخص می‌شود. سازوکار یادگیری بر اساس دریافت پاداش یا تنبیه طراحی شده است. هر گره با مشاهده همسایگان خود، پاداش مثبت دریافت می‌کند اگر نظرش با نظر اکثریت همسایگان همخوانی داشته باشد و به بهبود نظر آن‌ها کمک کند. در مقابل، اگر نظر گره با نظرات همسایگان

ژنی است که بیشترین تأثیر را در بهبود عملکرد کل کروموزوم دارد، بدون در نظر گرفتن تعاملات پیچیده احتمالی با سایر ژن‌ها در نسل‌های آتی.

2-3-2. مدل پویایی نظر فعال شده

در این بخش، دو مکانیسم تعاملی را معرفی می‌نمایم که به منظور مدل‌سازی فرایند فعال‌سازی و به روزرسانی پویای نظرات کاربران در طول زمان طراحی شده‌اند.

مکانیسم نخست، با الهام از مدل‌های انتشار اطلاعات در شبکه‌های اجتماعی، فرایند فعال‌سازی اولیه یک گره دانه را شبیه‌سازی می‌نماید. در این مرحله، ابتدا همسایگان گره دانه از گراف شبکه توسط الگوریتم seeding استخراج شده و سپس مدل آستانه خطی، گره دانه به همراه همسایگان آن فعال می‌گردند.

مکانیسم دوم، با هدف به روزرسانی پویای نظرات کاربران، از الگوریتم یادگیری تقویتی Q-learning استفاده می‌نماید. این الگوریتم، بدون نیاز به اطلاعات حالت کامل، نظرات کاربران را بر اساس تعاملات آن‌ها در شبکه به روزرسانی می‌نماید.

اجزای تشکیل‌دهنده رویکرد پیشنهادی عبارت‌اند از:

(1) فعال‌سازی آستانه خطی:

ما از یک مدل آستانه خطی پویا برای تعیین اینکه آیا یک گره در طول زمان بر اساس نظرات همسایگانش فعال می‌شود، استفاده می‌کنیم. فعال‌سازی آستانه خطی پویا به ما کمک می‌کند تا تصمیم بگیریم که آیا یک گره در گراف باید در هر گام زمانی بر اساس نظرات همسایگانش فعال باشد یا خیر. در اینجا، ما از یک مدل آستانه خطی وابسته به زمان استفاده می‌کنیم، به این معنی که اگر تأثیر تجمعی از نظرات گره‌های همسایه در یک بازه زمانی مشخص از یک آستانه خاصی که پیشاپیش تعیین شده است، بیشتر باشد، آن گره به عنوان فعال در آن گام زمانی در نظر گرفته می‌شود.

به طور مثال، اگر مجموع تأثیر نظرات همسایه یک گره در یک دوره زمانی معین (مثلاً یک روز یا یک هفته) بیشتر از یک آستانه خاص باشد، آن گره به عنوان فعال در آن دوره زمانی شناخته می‌شود و در فرایند پویای نظرات مورد توجه قرار می‌گیرد. این آستانه را مقدار 0.7 مشابه مقاله پایه برای ارزیابی بهتر قرار داده‌ایم.

در این مدل پویا، وضعیت فعال یا غیرفعال بودن هر گره می‌تواند در هر گام زمانی تغییر کند. این امر امکان مدل‌سازی تغییرات نظرات در طول زمان و تأثیر آن‌ها بر روی شبکه را فراهم می‌کند. همچنین، می‌توانیم تأثیر اقدامات مختلف برای حداکثر سازی نظرات را در بازه‌های زمانی مختلف ارزیابی کنیم و استراتژی‌های بهینه را برای هر مرحله زمانی تعیین نماییم.

کاربران شبکه هستند. مشخصات و ویژگی‌های این مجموعه داده‌ها در بخش مجموعه داده فصل دوم به صورت کامل توضیح داده شده‌اند. با توجه به جدول (1)، در این پژوهش پیشنهاد می‌شود از چهار مجموعه داده مرجع موجود در این حوزه استفاده شود. هریک از این مجموعه داده‌ها شامل تعدادی گره و یال هستند.

جدول (1). مشخصات مجموعه داده

نام مجموعه داده	تعداد گره	تعداد یال
wiki-RfA[28]	10835	159388
Wikipedia election[29,30]	7115	103689
Bitcoin Alpha[26,27]	3783	24186
Slashdot[31]	77350	516575

معیارهای ارزیابی که برای ارزیابی روش پیشنهادی در مجموعه داده‌های فوق، عبارت‌اند از:

- با توجه به رابطه (10)، معیار ارزیابی که برای این پژوهش نرخ نظرات مثبت است. این معیار نشان‌دهنده نسبت افرادی است که نظر مثبت دارند. با توجه به اینکه وقتی یک مسئله‌ای در شبکه اجتماعی منتشر می‌شود، در ابتدا امکان دارد که کاربران به آن موضوع نظر منفی یا خنثی داشته باشند. به همین دلیل برای ارزیابی کار از نسبت نظرات مثبت استفاده می‌شود. X_i نظر گره i و N تعداد گره‌های شبکه است.

$$PR = \frac{\sum X_i}{N} \quad (10)$$

- با توجه به رابطه (11)، معیار ارزیابی دیگری که برای این پژوهش پیشنهاد شده است، نسبت نظرات مثبت یا گره‌های فعال شده به گره‌های دانه است. این معیار نشان‌دهنده با افزایش مقدار گره‌های مجموعه اولیه، نظرات مثبت یا تعداد گره‌های فعال شده چه تغییری می‌کند. با توجه به هدف نمودارهایی که از این بخش به دست می‌آید، می‌بایست به سمت بیشینه شدن نظرات مثبت و روند صعودی داشته باشد. در رابطه (11)، X_i نظرات گره i و m اندازه مجموعه اولیه یا تعداد گره‌های دانه است.

$$ANR = \frac{\sum X_i}{m} \quad (11)$$

در این مطالعه، نسبت نظرات مثبت به عنوان معیاری برای سنجش میزان پذیرش یک نظر جدید در نظر گرفته شده است. برای شبیه‌سازی شرایط واقعی شبکه اجتماعی برخط، در ابتدای

تضاد داشته باشد و باعث کاهش کیفیت تعاملات شود، پاداش منفی دریافت می‌کند. فرمول به روزرسانی مقدار Q گره بر اساس رابطه (8) است.

مقادیر Q به عنوان یک راهنمای پویا عمل کرده و نقش مهمی در به روزرسانی نظرات ایفا می‌کنند. گره‌ها با به روزرسانی نظرات خود بر اساس مقادیر Q و نظرات همسایگان، به سمت همگرایی و تطابق با همسایگان یا واگرایی از آن‌ها حرکت می‌کنند. به عبارت دیگر، مقادیر Q رفتارهای انطباقی گره‌ها را در شبکه اجتماعی هدایت کرده و به ترویج اجماع یا تقویت تضاد کمک می‌کنند.

استفاده از Q-learning بدون حالت در این مسئله مزایایی دارد که از جمله آن‌ها می‌توان به تصمیم‌گیری مستقل و توزیع شده توسط گره‌ها، حذف نیاز به حافظه وضعیت‌های قبلی، سادگی محاسبات و کنترل مستقیم پویایی شبکه از طریق مقادیر Q اشاره کرد. این روش به گره‌ها امکان می‌دهد که بر اساس تعاملات محلی و بدون نیاز به دانش کامل از شبکه، به تعادل مطلوبی برسند. در نهایت، این سازوکار با ایجاد تعادل میان همگرایی و واگرایی، نقش مهمی در دستیابی به هدف حداکثر سازی پویایی نظرات ایفا می‌کند.

$$Q(x_i') = Q(x_i) + \alpha \cdot [r - Q(x_i)] \quad (8)$$

در رابطه (8)، $Q(x_i)$ مقدار Q را برای نظر گره i نشان می‌دهد. α نرخ یادگیری است که بین 0 تا 1 بوده و میزان به روزرسانی مقدار Q را تعیین می‌کند. r پاداش دریافت شده است که نشان می‌دهد آیا نظر گره با نظرات همسایگانش همخوانی دارد یا خیر. اگر اختلاف کم باشد، پاداش 1 است و در غیر این صورت نیز 1 باقی می‌ماند (طبق رابطه 9).

$$r = \begin{cases} |X_i - X_j| \leq \epsilon & 1 \\ \text{Otherwise} & -1 \end{cases} \quad (9)$$

در رابطه (9)، ما تنها از مقدار Q قبلی برای نظر گره i ام استفاده می‌کنیم و آن را با پاداش فعلی به روزرسانی می‌کنیم. این روش بدون حالت بودن به ما اجازه می‌دهد که بدون نیاز به ذخیره و به روزرسانی وضعیت‌ها، به روزرسانی مقادیر Q را انجام دهیم و از آن برای انتخاب عمل‌ها در آینده استفاده کنیم.

۳. نتایج و بحث

در این بخش، بررسی عملکرد مدل ما در ارتقاء پویایی نظرات را ارائه می‌دهیم. هدف اصلی این بخش، افزایش تعداد نظرات مثبت در شبکه با در نظر گرفتن جنبه پویایی است. نتایج ارزیابی بر اساس معیارهای مشخص شده تحلیل شده و گزارش می‌شوند. در این تحقیق، از چهار مجموعه داده مرجع که در جدول 2-4 مشخص شده‌اند، برای ارزیابی روش پیشنهادی حداکثر سازی نظرات با در نظر گرفتن پویایی نظرات استفاده شده است. این مجموعه داده‌ها از شبکه‌های اجتماعی واقعی گرفته شده‌اند و شامل تعداد گره‌ها و یال‌هایی هستند که نشان‌دهنده روابط بین

در مجموعه داده مدیریت درخواست ویکی پدیا نیز، الگوریتم ژنتیک حریصانه با افزایش نظرات مثبت نسبت به روش‌های QDOM، Pagerank، Aral و ICOM برتری دارد. در مقایسه با روش Pagerank، این الگوریتم بهبودهایی به ترتیب 38/64، 30/32، 24/22، 62/21 و 28/21 در مجموعه‌های گره 20 تا 100 به‌دست‌آمده آورده است. این الگوریتم همچنین نسبت به روش Aral، برای گره‌های 20 و 40 به ترتیب بهبودهای 52/58 و 44/44 را نشان داده که تأثیر مثبت الگوریتم در گسترش گره‌های مثبت در این شبکه است.

در مجموعه داده انتخابات ویکی پدیا، الگوریتم ژنتیک حریصانه در ایجاد گره‌های مثبت، به‌ویژه در مقایسه با روش‌های QDOM و Pagerank، عملکرد بهتری نشان می‌دهد. در مقایسه با روش Pagerank، این الگوریتم بهبودهایی به ترتیب 14/44، 15/46، 10/28 و 34/48 در مجموعه‌های گره 20 تا 100 داشته است. این الگوریتم نسبت به روش Aral نیز، برای گره‌های 20 و 40 به ترتیب بهبودهای 14/37 و 15/15 را در افزایش گره‌های مثبت به همراه داشته است که کارایی آن را در این زمینه نشان می‌دهد.


در مجموعه داده اسلش دات، الگوریتم ژنتیک حریصانه در ایجاد گره‌های مثبت برتری خود را نسبت به روش‌های دیگر، به‌ویژه در مجموعه‌های گره‌های 20 تا 100، نشان داده است. به‌عنوان مثال، در مقایسه با روش Pagerank، این الگوریتم بهبودهایی به ترتیب 100/56، 25/60، بدون تغییر، 82/81 را ثبت کرده است. همچنین، در مقایسه با روش ICOM، برای گره‌های 20، 40 و 80 به ترتیب بهبودهای 99/76، 69/81 و 14/18 حاصل شده است و نسبت به روش QDOM، زمانی که تعداد گره‌های دانه در مجموعه اولیه 20، 40، 80 و 100 است، به ترتیب 33/33، 4/17، 21/74 و 15/48، توانسته است تعداد گره‌های با نظر مثبت را افزایش دهد که کارایی الگوریتم در این مجموعه را نیز به‌خوبی نشان می‌دهد.

این نتایج نشان‌دهنده کارایی بالای الگوریتم ژنتیک مبتنی بر حریصانه در ایجاد و افزایش نظرات مثبت در شبکه‌ها و مجموعه داده‌های مختلف است.


هر آزمایش، نسبت افرادی که دیدگاه مثبتی نسبت به موضوع دارند، کمتر از 20 درصد در نظر گرفته شده است. این فرض بر اساس این واقعیت است که در مواجهه با نظرات نو، اغلب افراد به دلیل عدم آشنایی کافی، واکنش‌های محتاطانه یا حتی منفی از خود نشان می‌دهند. برای مدل‌سازی این رفتار، نظرات اولیه افراد به‌صورت تصادفی در بازه‌ای پیوسته بین -1 (کاملاً منفی) تا 1 (کاملاً مثبت) انتخاب شده است. این فرایند برای افزایش اعتبار نتایج، 20 بار تکرار شده و میانگین نظرات مثبت در تمامی تکرارها محاسبه شده است. همچنین، با تغییر تعداد افراد تأثیرگذار اولیه در بازه 0 تا 100، تأثیر این افراد بر شکل‌گیری نهایی نظرات موردبررسی قرار گرفته است. همچنین، ما عملکرد روش خود با چهار روش موجود در حل مسئله حداکثر سازی نظرات (یعنی QDOM [11]، Aral [32]، Pagerank [33] و ICOM [34]) مقایسه می‌کنیم.

شکل (8) نرخ نظرات مثبت نسبت به گره‌های دانه را برای چهار مجموعه داده شبکه اجتماعی امضاشده نمایش می‌دهد. در اینجا، تعداد گره‌های دانه در پنج سناریو متفاوت از 0 تا 100 متغیر بوده و زمان شبیه‌سازی برای تمامی سناریوها به مدت 200 واحد زمانی (مطابق با سایر روش‌های مقایسه شده) در نظر گرفته شده است. نتایج حاصل از چهار مجموعه داده نشان می‌دهد که با افزایش تعداد گره‌های دانه، نرخ نظرات مثبت به‌طور کلی روند صعودی داشته است. رویکرد پیشنهادی با الگوریتم ژنتیک مبتنی بر حریصانه در افزایش تعداد گره‌های با نظر مثبت نسبت به روش‌های دیگر در مجموعه داده بیت کوین آلفا عملکرد بهتری نشان داده است.


با توجه به شکل (8) و (9)، در مقایسه با روش QDOM، الگوریتم ژنتیک مبتنی بر حریصانه توانسته در سناریوهای 20، 40، 60، 80 و 100 گره به ترتیب بهبودهایی معادل 68/18، 40/63، 57/28، 11/42 و 82/31 به دست آورد. این الگوریتم نسبت به روش‌های Pagerank و Aral نیز به ترتیب بهبودهای 67/146 و 25/131 را در سناریوهای 20 نشان می‌دهد. همچنین زمانی که تعداد گره‌های دانه در مجموعه اولیه به ترتیب به تعداد 20، 40، 60، 80 و 100 می‌رسد، نتایج آن نسبت به الگوریتم ICOM به ترتیب 9/17، 83/14، 15/79 و 63/11 و 82/31 افزایش یافته است که برتری این روش را در ایجاد گره‌های مثبت در شبکه مشخص می‌سازد.



شکل (8). نظرات مثبت نسبت به گره‌های دانه در چهار شبکه اجتماعی امضا شده



شکل (9). درصد اختلاف میانگین نظرات مثبت الگوریتم‌های مقایسه‌شدن در چهار شبکه اجتماعی امضاشده



شکل (10). گره‌های فعال‌شده نسبت به گره‌های دانه در چهار شبکه اجتماعی امضاشده

ژنتیک مبتنی بر حریصانه با تعداد گره‌های دانه 20، 40، 60، 80 و 100 به ترتیب بدون تغییر، $32/34$ ، $51/19$ و $58/25$ بهبود یافته است. الگوریتم ژنتیک مبتنی بر حریصانه در مقایسه با روش Aral و ICOM نیز با درصد‌های قابل توجهی توانسته است تعداد گره‌های فعال شده را افزایش دهد.


در نهایت، مجموعه داده‌ی اسلش‌دات، نشان‌دهنده‌ی برتری الگوریتم ژنتیک مبتنی بر حریصانه نسبت به سایر روش‌ها است. این الگوریتم با تعداد گره‌های دانه 20، 40، 60، 80 و 100 نسبت به QDOM به ترتیب $5/88$ ، $17/5$ ، بدون تغییر و $3/92$ افزایش داشته است. همچنین در مقایسه با Pagerank با تعداد گره‌های دانه 20، 40، 60، 80 و 100، این الگوریتم به ترتیب $250/23$ ، $33/3$ ، $14/57$ ، $89/38$ و $45/20$ بهبود داشته است. در برابر روش Aral، ژنتیک مبتنی بر حریصانه به ترتیب $75/$ ، $23/08$ ، $10/1$ ، $25/$ و $17/78$ بهبود نشان داده است و نسبت به ICOM نیز در همه مراحل نتایج بهتری ارائه کرده است.

نتایج به‌دست‌آمده از تحلیل عملکرد الگوریتم ژنتیک مبتنی بر حریصانه در مقایسه با الگوریتم‌های دیگر، نشان‌دهنده‌ی برتری قابل توجه این الگوریتم در افزایش تعداد نظرات مثبت و تعداد گره‌های فعال شده در شبکه‌های اجتماعی است. این الگوریتم در تمامی مجموعه داده‌های بررسی شده، از جمله بیت کوین آلفا، ویکی‌پدیا و اسلش‌دات، بهبود چشمگیری را نسبت به روش‌های رایج مانند Aral، Pagerank، QDOM و ICOM نشان داده است.

این دستاوردها نشان می‌دهد که استفاده از الگوریتم ژنتیک مبتنی بر حریصانه برای بهبود فرآیندهای انتشار اطلاعات و افزایش نظرات کاربران در شبکه‌های اجتماعی مؤثر است. این الگوریتم با به‌کارگیری رویکرد ژنتیک مبتنی بر حریصانه در انتخاب گره‌های دانه، توانسته است هم در فعال‌سازی تعداد بیشتری گره و هم در کارایی شبکه‌ها به‌طور کلی، عملکرد بهتری نسبت به سایر روش‌ها داشته باشد. این نتایج می‌تواند به‌عنوان مبنایی برای تحقیقات بیشتر در حوزه‌ی بهینه‌سازی انتشار اطلاعات در شبکه‌های اجتماعی مورد استفاده قرار گیرد.

شکل (10) گره‌های فعال شده نسبت به گره‌های دانه‌نشان می‌دهد. تعداد گره‌های دانه برابر با 50 و زمان 200 واحد زمانی تنظیم شده است. از نتایج، می‌توان دید که گره‌های فعال در پنج الگوریتم نسبت به گره‌های دانه روند صعودی دارند و رویکرد پیشنهادی دارای گره‌های فعال بیشتری نسبت به الگوریتم‌های معیار در چهار مجموعه داده شبکه اجتماعی امضا شده دارد. با توجه به دو شکل (10) و (11)، مجموعه داده‌ی بیت کوین آلفا نشان می‌دهد که الگوریتم ژنتیک مبتنی بر حریصانه نسبت به الگوریتم‌های دیگر در افزایش تعداد گره‌های فعال شده عملکرد بهتری داشته است. نتایج نشان می‌دهد که این الگوریتم در مقایسه با روش QDOM با تعداد گره‌های دانه 20، 40، 60، 80 و 100 به ترتیب $9/17$ ، $11/25$ ، بدون تغییر و $11/54$ افزایش داشته است. همچنین نسبت به روش Pagerank در همین ترتیب تعداد گره‌ها، به ترتیب $31/37$ ، $41/29$ ، $14/29$ و $35/35$ افزایش داشته است. این الگوریتم در مقایسه با روش Aral نیز به ترتیب $9/17$ ، $36/92$ ، $15/79$ ، $11/63$ و $31/82$ بهبود یافته و نسبت به روش ICOM نیز در تمامی موارد بهبود قابل توجهی نشان داده است. تحلیل داده‌های مدیریت ویکی‌پدیا نیز به نتایج مشابهی دست یافته است. الگوریتم ژنتیک مبتنی بر حریصانه نسبت به روش QDOM با تعداد گره‌های دانه 20، 40، 60، 80 و 100 به ترتیب $6/89$ ، $5/$ ، $18/75$ و $17/44$ بهبود داشته است. این الگوریتم نسبت به روش Pagerank نیز با گره‌های دانه در مقادیر 20، 40، 60، 80 و 100 به ترتیب $37/78$ ، $34/62$ ، $10/29$ ، $31/94$ و $24/69$ افزایش نشان داده است. همچنین، در مقایسه با الگوریتم Aral، ژنتیک مبتنی بر حریصانه به ترتیب $44/19$ ، $28/05$ ، $5/63$ و $20/25$ و $22/42$ عملکرد بهتری داشته و در مقابل الگوریتم ICOM نیز در تمامی مراحل نتایج بهتری ارائه کرده است.

در شکل (8)، مجموعه داده‌ی انتخابات ویکی‌پدیا مورد ارزیابی قرار گرفته و نتایج حاکی از عملکرد برتر الگوریتم ژنتیک مبتنی بر حریصانه است. این الگوریتم در مقایسه با روش QDOM با تعداد گره‌های دانه 20، 40، 60 و 100 به ترتیب $10/2$ ، $38/2$ و $7/84$ افزایش داشته است. همچنین در مقایسه با الگوریتم Pagerank،



شکل (11). درصد اختلاف گره‌های فعال الگوریتم‌های مقایسه شده در چهار شبکه اجتماعی امضاشده

4. نتیجه‌گیری

در این مقاله، چارچوب حداکثر سازی پویایی نظرات مبتنی بر الگوریتم ژنتیک حریصانه در شبکه‌های اجتماعی برخط امضا شده برای حل مسئله حداکثر سازی پویایی نظرات ارائه شده است. این چارچوب شامل دو مرحله مدل نظرات پویای فعال و فرآیند انتخاب گره‌ها با الگوریتم ژنتیک حریصانه است. مسئله حداکثر سازی پویایی نظرات و تابع هدف که بر اساس نظرات مثبت گره‌های فعال شده تعریف شده، در اینجا به طور دقیق مشخص شده است. با بهره‌گیری از نظریه Q -learning بدون وضعیت، مدل انتشار نظرات ارائه شده و از الگوریتم ژنتیک حریصانه برای تعیین گره‌های دانه استفاده شده است. نتایج آزمایش‌ها بر روی چهار مجموعه داده شبکه اجتماعی نشان می‌دهد که الگوریتم ژنتیک حریصانه در نظرات مثبت، نسبت نظرات مثبت و تعداد گره‌های فعال شده عملکرد بهتری نسبت به الگوریتم‌های پایه دارد.

در نتایج نشان داده شده، چارچوب پیشنهادی در مقایسه با الگوریتم‌های موجود مانند *Aral*, *Pagerank*, *QDOM* و *ICOM* بهبود قابل توجهی را در افزایش نظرات مثبت و تعداد گره‌های فعال شده به دست آمده آورده است. الگوریتم ژنتیک حریصانه با افزایش تعداد گره‌های دانه در شبکه، روند صعودی در نظرات مثبت و تعداد گره‌های فعال شده را نشان داده و عملکردی مؤثرتر در تقویت مشارکت و انتشار نظرات مثبت در شبکه‌های اجتماعی داشته است. این دستاوردها نشان‌دهنده قابلیت بالقوه این الگوریتم در افزایش بازدهی شبکه‌ها و بهینه‌سازی فرآیندهای انتشار اطلاعات در شبکه‌های اجتماعی بوده و می‌تواند مبنایی برای توسعه تحقیقات بیشتر در این زمینه قرار گیرد.

در مطالعات آتی، می‌توان به بهبود دقت مدل با استفاده از الگوریتم‌های ژنتیک پیشرفته‌تر و تکنیک‌های بهینه‌سازی پیچیده‌تر پرداخت. همچنین، بررسی تأثیر پارامترهای مختلف مدل بر نتایج و ارائه راهکارهایی برای تنظیم بهینه این پارامترها، می‌تواند موضوع تحقیقات آتی باشد. علاوه بر این، اعمال این روش در محیط‌های رقابتی با در نظر گرفتن استراتژی‌های حریف و با داده‌های واقعی می‌تواند دیدگاه جامعی از کارایی آن در شرایط واقعی فراهم آورد.

5. مراجع

- [4] Q. He et al., "Dynamic Opinion Maximization Framework With Hybrid Method in Social Networks," *IEEE Trans. Netw. Sci. Eng.*, vol. 10, no. 1, pp. 441–451, 2023, doi: 10.1109/TNSE.2022.3212124.
- [5] Y. Li, J. Fan, Y. Wang, and K. L. Tan, "Influence Maximization on Social Graphs: A Survey," *IEEE Trans. Knowl. Data Eng.*, vol. 30, no. 10, pp. 1852–1872, 2018, doi: 10.1109/TKDE.2018.2807843.
- [6] G. Zhang and C. You, "Influence Maximization Algorithms Research Based on Big Graphs," *Proc. - 2018 IEEE 18th Int. Conf. Softw. Qual. Reliab. Secur. Companion, QRS-C 2018*, pp. 537–544, 2018, doi: 10.1109/QRS-C.2018.00096.
- [7] A. Zareie and R. Sakellariou, "Influence maximization in social networks: a survey of behaviour-aware methods," *Soc. Netw. Anal. Min.*, vol. 13, no. 1, pp. 1–21, 2023, doi: 10.1007/s13278-023-01078-9.
- [8] M. Azaouzi, W. Mnasri, and L. Ben Romdhane, "New trends in influence maximization models," *Comput. Sci. Rev.*, vol. 40, p. 100393, 2021, doi: 10.1016/j.cosrev.2021.100393.
- [9] S. Banerjee, M. Jenamani, and D. K. Pratihari, "A survey on influence maximization in a social network," *Knowl. Inf. Syst.*, vol. 62, no. 9, pp. 3417–3455, 2020, doi: 10.1007/s10115-020-01461-4.
- [10] M. Jaouadi and L. Ben Romdhane, "A survey on influence maximization models," *Expert Syst. Appl.*, vol. 248, no. September 2023, p. 123429, 2024, doi: 10.1016/j.eswa.2024.123429.
- [11] Q. He et al., "Reinforcement-Learning-Based Dynamic Opinion Maximization Framework in Signed Social Networks," *IEEE Trans. Cogn. Dev. Syst.*, vol. 15, no. 1, pp. 54–64, 2023, doi: 10.1109/TCDS.2022.3141952.
- [12] Q. He, H. Fang, J. Zhang, and X. Wang, "Dynamic Opinion Maximization in Social Networks," *IEEE Trans. Knowl. Data Eng.*, vol. 35, no. 1, pp. 350–361, 2023, doi: 10.1109/TKDE.2021.3077491.
- [13] Bazdar, G., Abdollahi Azgomi, M., 'a computational model to evaluate the agent of influence operations in online social networks', *Electronic and Cyber Defense*, vol. 12, no. 1, pp. 89–107, 2024. (In Persian).
- [14] Jabbari Lotf, J., Abdollahi Azgomi, M., & Ebrahimi Dishabi, M. R., "A Dynamic Metaheuristic Algorithm for Influence Maximization in Social Networks," vol. 11, no. 2, pp. 57–69, 2023 (In Persian).
- [15] J. Jabari Lotf, M. Abdollahi Azgomi, and M. R. Ebrahimi Dishabi, "An improved influence maximization method for social networks based on genetic algorithm," *Phys. A Stat. Mech. its Appl.*, vol. 586, p. 126480, 2022, doi: 10.1016/j.physa.2021.126480.
- [16] Q. He, Y. Lv, X. Wang, M. Huang, and Y. Cai, "Reinforcement Learning-Based Rumor Blocking Approach in Directed Social Networks," *IEEE Syst. J.*, vol. 16, no. 4, pp. 6457–6467, 2022, doi: 10.1109/JSYST.2022.3159840.
- [17] Q. He et al., "Reinforcement-Learning-Based Competitive Opinion Maximization Approach in Signed Social Networks," *IEEE Trans. Comput. Soc. Syst.*, vol. 9, no. 5, pp. 1505–1514, 2022, doi: 10.1109/TCSS.2021.3120421.
- [18] Q. He et al., "Dynamic Opinion Maximization Framework with Hybrid Method in Social
- [1] D. C. Cercel and S. Trausan-Matu, "Opinion propagation in online social networks: A survey," *ACM Int. Conf. Proceeding Ser.*, 2014, doi: 10.1145/2611040.2611088.
- [2] P. Xu, W. Hu, J. Wu, and W. Liu, "Opinion maximization in social trust networks," *IJCAI Int. Jt. Conf. Artif. Intell.*, vol. 2021-Janua, pp. 1251–1257, 2020, doi: 10.24963/ijcai.2020/174.
- [3] X. Liu, X. Kong, and P. S. Yu, "Active opinion maximization in social networks," *Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, pp. 1840–1849, 2018, doi: 10.1145/3219819.3220061.

- [26] S. Kumar, F. Spezzano, V.S. Subrahmanian, C. Faloutsos. Edge Weight Prediction in Weighted Signed Networks. IEEE International Conference on Data Mining (ICDM), 2016.
- [27] S. Kumar, B. Hooi, D. Makhija, M. Kumar, V.S. Subrahmanian, C. Faloutsos. REV2: Fraudulent User Prediction in Rating Platforms. 11th ACM International Conference on Web Search and Data Mining (WSDM), 2018.
- [28] Robert West, Hristo S. Paskov, Jure Leskovec, and Christopher Potts: Exploiting Social Network Structure for Person-to-Person Sentiment Analysis. Transactions of the Association for Computational Linguistics, 2(Oct):297–310, 2014.
- [29] J. Leskovec, D. Huttenlocher, J. Kleinberg. Signed Networks in Social Media. CHI 2010.
- [30] J. Leskovec, D. Huttenlocher, J. Kleinberg. Predicting Positive and Negative Links in Online Social Networks. WWW 2010.
- [31] J. Leskovec, D. Huttenlocher, J. Kleinberg: Signed Networks in Social Media. 28th ACM Conference on Human Factors in Computing Systems (CHI), 2010.
- [32] S. Aral and P. S. Dhillon, “Social influence maximization under empirical influence models,” Nat. Hum. Behav., vol. 2, no. 6, pp. 375–382, 2018, doi: 10.1038/s41562-018-0346-z.
- [33] S. Brin and L. Page, Reprint of: the anatomy of a large-scale hypertextual web search engine, Computer Networks. 56(18) 2012 3825-3833.
- [34] J. Luo, X. Liu, and X. Kong, “Competitive opinion maximization in social networks,” Proc. 2019 IEEE/ACM Int. Conf. Adv. Soc. Networks Anal. Mining, ASONAM 2019, pp. 250–257, 2019, doi: 10.1145/3341161.3342899.
- Networks,” IEEE Trans. Netw. Sci. Eng., pp. 1–11, 2022, doi: 10.1109/TNSE.2022.3212124.
- [19] Q. He et al., “Positive opinion maximization in signed social networks,” Inf. Sci. (Ny)., vol. 558, pp. 34–49, 2021, doi: 10.1016/j.ins.2020.12.091.
- [20] Y. Li, J. Zhu, J. Jiao, and Q. Zhang, “Competitive Influence Minimization in Multi-Group Social Networks: An Opinion-Based Solution,” IEEE Trans. Netw. Sci. Eng., vol. 9, no. 4, pp. 2617–2630, 2022, doi: 10.1109/TNSE.2022.3168042.
- [21] L. S. Alla and A. S. Kare, Opinion Maximization in Signed Social Networks Using Centrality Measures and Clustering Techniques. Springer Nature Switzerland, 2023. doi: 10.1007/978-3-031-24848-1_9.
- [22] Q. He et al., “CAOM: A community-based approach to tackle opinion maximization for social networks,” Inf. Sci. (Ny)., vol. 513, pp. 252–269, 2020, doi: 10.1016/j.ins.2019.10.064.
- [23] J. Jabari Lotf, M. Abdollahi Azgomi, and M. R. Ebrahimi Dishabi, “An improved influence maximization method for social networks based on genetic algorithm,” Phys. A Stat. Mech. its Appl., vol. 586, p. 126480, 2022, doi: 10.1016/j.physa.2021.126480.
- [24] C. Dong, G. Xu, P. Yang, and L. Meng, “TSIFIM: A three-stage iterative framework for influence maximization in complex networks,” Expert Syst. Appl., vol. 212, no. August 2022, p. 118702, 2023, doi: 10.1016/j.eswa.2022.118702.
- [25] L. Zhang, Y. Liu, F. Cheng, J. Qiu, and X. Zhang, “A Local-Global Influence Indicator Based Constrained Evolutionary Algorithm for Budgeted Influence Maximization in Social Networks,” IEEE Trans. Netw. Sci. Eng., vol. 8, no. 2, pp. 1557–1570, 2021, doi: 10.1109/TNSE.2021.3064828.