

A Trust-based Recommender System Using an Improved Particle Swarm Optimization Algorithm

Sajad Ahmadian^{*}, Mohammad Hossein Olyae²

1. Assistant Professor, Faculty of Information Technology, Kermanshah University of Technology, Kermanshah, Iran. * *Corresponding Author*, s.ahmadian@kut.ac.ir
2. Assistant Professor, Faculty of Engineering, University of Gonabad, Gonabad, Iran.

Abstract

Introduction: Recommender systems are intelligent tools to help users find their desired information among a large number of choices based on their previous preferences in a way faster than search engines. One of the main challenges in recommender systems is the sparsity of the user-item rating matrix. This means that users mainly tend to express their opinions about a few items, leading to a large portion of the user-item rating matrix being empty. Trust-based recommender systems aim to alleviate the sparsity problem using trust relationships between users. Trust relationships can be used to calculate similarity values between users and determine the nearest neighbors set for the target user. However, the efficiency of trust-based recommender systems depends on the correct selection of neighboring users for the target user based on the similarity values between users.

Method: In this paper, a novel trust-based recommender system is proposed based on an improved particle swarm optimization algorithm. To this end, first, the similarity values between users are calculated based on the user-item rating matrix and trust relationships. Then, the improved particle swarm optimization algorithm is used to optimally weight the neighboring users of the target user. The main purpose of this algorithm is to assign an optimal weight to each user in the nearest neighbor set of the target user to predict the unknown items accurately. After the optimal weighting of neighboring users, unknown ratings are predicted for the target user.

Results: The proposed method is evaluated on a standard dataset in terms of mean absolute error, root mean square error, and rate coverage metrics. Experimental results demonstrate the high efficiency of the proposed method compared to other methods.

Discussion: We use the genetic algorithms operators and chaos-based asexual reproduction optimization algorithm to improve the original version of the particle swarm optimization algorithm. The genetic algorithms operators increase the exploration mechanism of the particle swarm optimization algorithm, leading to a decline in the probability of tapping into local optima. Moreover, the chaos-based asexual reproduction optimization algorithm is applied to the best solution to further search the area around the best solution.

Keywords: Recommender Systems, Trust, Meta heuristic Algorithms, Particle Swarm Optimization, Cold Start.

یک سیستم توصیه‌گر مبتنی بر اعتماد با استفاده از الگوریتم بهبودیافته بهینه‌سازی ازدحام ذرات

دوره پنجم، بهار ۱۴۰۳
شماره اول، صص: ۱-۱۲

تاریخ دریافت: ۱۴۰۲/۱۰/۱۲
تاریخ پذیرش: ۱۴۰۲/۱۱/۲۳

سجاد احمدیان^{۱*}، محمد حسین اولیائی^۲

۱. استادیار، دانشکده فناوری اطلاعات، دانشگاه صنعتی کرمانشاه، کرمانشاه، ایران. (نویسنده مسئول) s.ahmadian@kut.ac.ir

۲. استادیار، دانشکده مهندسی، مجتمع آموزش عالی گناباد، گناباد، ایران. mh.olyaee@gonabad.ac.ir

چکیده: سیستم‌های توصیه‌گر ابزارهای هوشمندی هستند که به کاربران کمک می‌کنند اطلاعات مورد نیاز خود را بر اساس علایق قبلی خود با صرف زمان کمتری نسبت به موتورهای جستجو پیداکنند. یکی از چالش‌های اصلی سیستم‌های توصیه‌گر تنگی ماتریس رتبه‌های کاربر-قلم می‌باشد. این چالش به این دلیل اتفاق می‌افتد که کاربران عمدتاً به تعداد کمی از اقلام موجود رتبه می‌دهند. سیستم‌های توصیه‌گر مبتنی بر اعتماد از روابط اعتماد بین کاربران به منظور کاهش مشکل تنگی ماتریس رتبه‌های کاربر-قلم استفاده می‌کنند. ایده اصلی این سیستم‌ها این است که وجود رابطه اعتماد بین دو کاربر نشان‌دهنده علایق مشابه آن دو کاربر می‌باشد. کارایی این سیستم‌ها به انتخاب درست کاربران همسایه برای کاربر هدف بر اساس میزان شباهت بین آن‌ها بستگی دارد. در این مقاله، یک سیستم توصیه‌گر مبتنی بر اعتماد جدید با استفاده از الگوریتم بهبودیافته بهینه‌سازی ازدحام ذرات ارائه شده است. در این روش، ابتدا میزان شباهت بین کاربران بر اساس ماتریس رتبه‌های کاربر-قلم و روابط اعتماد محاسبه می‌گردد. سپس، از الگوریتم بهبودیافته بهینه‌سازی ازدحام ذرات برای وزن‌دهی بهینه کاربران همسایه کاربر هدف استفاده می‌شود. به منظور بهبود الگوریتم بهینه‌سازی ازدحام ذرات از عملگرهای الگوریتم ژنتیک و الگوریتم بهینه‌سازی تولیدمثل تک‌جنسیتی مبتنی بر آشوب استفاده شده است. پس از وزن‌دهی بهینه کاربران همسایه، رتبه‌های نامشخص برای کاربر هدف پیش‌بینی می‌گردد. نتایج آزمایش‌ها بر روی یک مجموعه داده استاندارد کارایی بالایی روش پیشنهادی را نسبت به سایر روش‌های مقایسه‌شده، نشان می‌دهد.

واژه‌های کلیدی: سیستم‌های توصیه‌گر، اعتماد، الگوریتم فراابتکاری، بهینه‌سازی ازدحام ذرات، شروع سرد.

۱. مقدمه

هدف از سیستم‌های توصیه‌گر، فراهم‌نمودن اطلاعات شخصی سازی شده برای تعداد قابل توجهی از کاربران می‌باشد. با توسعه فناوری‌های اینترنت، در بسیاری از سیستم‌های برخط شامل شبکه‌های اجتماعی و وبسایت‌های تجاری، سیستم‌های توصیه‌گر به‌عنوان راه‌حلی برای مشکل سربار اطلاعات معرفی شده‌اند. سیستم‌های توصیه‌گر می‌توانند توصیه‌هایی را برای کاربران بر اساس علایق آن‌ها ارائه‌نمایند. به‌طور کلی، می‌توان روش‌های توصیه‌گر را به سه دسته مبتنی بر محتوا، پالایش گروهی و ترکیبی تقسیم‌نمود. روش‌های مبتنی بر محتوا از پروفایل‌های کاربران یا اقلام به‌منظور تولید توصیه‌ها استفاده می‌کنند [۱]. روش‌های پالایش گروهی از علایق کاربران شبیه به کاربر هدف در پیش‌بینی رتبه‌های نام‌شخص کاربر هدف استفاده می‌کنند [۲]. برای استفاده از مزایای روش‌های مبتنی بر محتوا و پالایش گروهی، این دو روش در قالب روش‌های ترکیبی با هم ترکیب می‌شوند. مهم‌ترین مرحله در روش‌های پالایش گروهی، انتخاب یک مجموعه مناسب از کاربران و استفاده از علایق آن‌ها در فرآیند پیش‌بینی رتبه‌های نام‌شخص کاربر هدف می‌باشد. بدین‌منظور، تحقیقات زیادی برای ارائه معیارهای شباهت بین کاربران و تعیین کاربران همسایه کاربر هدف بر اساس آن‌ها انجام شده‌است. برخی از این معیارها روابط کاربر-کاربر را در نظر گرفته و برخی دیگر نیز روابط قلم-قلم را ارزیابی می‌کنند. عملکرد این معیارها به تعداد کافی رتبه‌های موجود در ماتریس کاربر-قلم بستگی دارد. با این وجود، برخی از کاربران موجود در سیستم رتبه‌های بسیار کمی را برای اقلام موجود ارائه کرده‌اند که باعث تنگی شدید ماتریس کاربر-قلم می‌شود. همچنین، کاربران یا اقلامی که به تازگی به سیستم اضافه شده‌اند دارای تعداد بسیار کمی رتبه و یا حتی فاقد هر نوع رتبه‌ای می‌باشند. این کاربران یا اقلام را شروع سرد می‌نامند که معیارهای شباهت عملکرد بسیار ضعیفی در مورد این نوع کاربران یا اقلام دارند. یکی از روش‌های حل این مشکلات، استفاده از اطلاعات اضافه مانند روابط اجتماعی بین کاربران در فرآیند توصیه می‌باشد [۳]. به دلیل رشد سریع شبکه‌های اجتماعی، سیستم‌های توصیه‌گر مبتنی بر روابط اجتماعی بین کاربران توجه زیادی را به خود جلب کرده‌اند. این روابط اجتماعی معمولاً به‌صورت روابط اعتماد بین کاربران تعریف می‌شوند که می‌توان از آن‌ها در فرآیند توصیه استفاده کرد. ایده اصلی سیستم‌های توصیه‌گر مبتنی بر اعتماد این است که وجود رابطه اعتماد بین دو کاربر نشان‌دهنده علایق مشابه آن دو کاربر می‌باشد. بنابراین، از علایق کاربرانی که مورد اعتماد کاربر هدف می‌باشند می‌توان در پیش‌بینی رتبه‌های نام‌شخص کاربر هدف استفاده کرد. استفاده از روابط اعتماد در فرآیند توصیه می‌تواند به کاهش مشکل تنگی ماتریس رتبه‌های کاربر-قلم و همچنین چالش شروع سرد کمک کند. به‌طور کلی می‌توان روابط اعتماد را به دو نوع اعتماد صریح و اعتماد ضمنی تقسیم کرد [۴]. روابط اعتماد صریح شامل روابطی هستند که به صورت صریح توسط کاربران بیان شده‌اند.

در حالی که، روابط اعتماد ضمنی بر اساس سایر اطلاعات از قبیل تعاملات بین کاربران و اقلام به‌صورت ضمنی پیش‌بینی می‌شوند. با وجود قابلیت‌های بالای روابط اعتماد، چگونگی استفاده از آن‌ها در فرآیند توصیه و محاسبه وزن شباهت بین کاربران یک مسئله چالشی می‌باشد. در برخی از تحقیقات، الگوریتم‌های فرایته‌کاری به‌عنوان ابزارهای بهینه‌سازی جهت وزن‌دهی بهینه بین کاربر هدف و سایر کاربران استفاده شده‌اند [۵]. بیشتر سیستم‌های توصیه‌گر از الگوریتم‌های ژنتیک و بهینه‌سازی کلونی مورچگان استفاده کرده‌اند. در [۶]، یک روش به‌منظور یافتن مقادیر بهینه آستانه و وزن‌ها در محاسبه شباهت بین کاربران ارائه شده‌است. در واقع، هدف از این روش افزایش دقت پیش‌بینی رتبه‌ها با استفاده از در نظر گرفتن وزن‌های بهینه در فرآیند توصیه می‌باشد. بیشتر روش‌های قبلی ارائه شده بر مبنای ماتریس رتبه‌های کاربر-قلم می‌باشند که در حل مشکل تنگی این ماتریس مؤثر نیستند. تعداد کمی از پژوهش‌های مبتنی بر الگوریتم‌های فرایته‌کاری روابط اعتماد بین کاربران را در کنار ماتریس رتبه‌ها در نظر گرفته‌اند. بنابراین، می‌توان نتیجه گرفت که استفاده همزمان ماتریس رتبه‌ها و روابط اعتماد بین کاربران در فرآیند بهینه‌سازی الگوریتم‌های فرایته‌کاری می‌تواند باعث افزایش کارایی سیستم‌های توصیه‌گر شود.

در این مقاله، یک سیستم توصیه‌گر مبتنی بر اعتماد ارائه شده‌است که در آن از یک الگوریتم بهبود یافته ازدحام ذرات به‌منظور پیش‌بینی رتبه‌های نام‌شخص استفاده شده‌است. در روش پیشنهادی، ابتدا میزان شباهت بین کاربران با استفاده از ماتریس رتبه‌های کاربر-قلم و روابط اعتماد بین کاربران محاسبه می‌شود. سپس، بر اساس مقادیر شباهت محاسبه شده، یک همسایگی شامل نزدیک‌ترین کاربران به کاربر هدف، انتخاب می‌گردد. در مرحله بعد، از یک الگوریتم بهینه‌سازی به‌منظور یافتن وزن‌های شباهت بهینه بین کاربر هدف و سایر کاربران موجود در همسایگی آن استفاده می‌شود. بدین‌منظور، یک الگوریتم بهبود یافته ازدحام ذرات ارائه شده‌است که فرآیند جستجو و بهینه‌سازی در آن بر اساس عملگرهای ژنتیک و الگوریتم بهینه‌سازی تولیدمثل تک‌جنسیتی مبتنی بر آشوب بهبود یافته‌است. ایده اصلی الگوریتم پیشنهادی، افزایش قابلیت جستجو و کاهش احتمال گیرافتادن در بهینه‌های محلی می‌باشد. این الگوریتم قادر است وزن‌های شباهت بین کاربران را جهت به دست آوردن بیشترین میزان دقت در پیش‌بینی رتبه‌های نام‌شخص، بهینه نماید. در نهایت، بر اساس وزن‌های بهینه به دست آمده، همسایگی جدیدی برای کاربر هدف مشخص شده و رتبه‌های نام‌شخص پیش‌بینی می‌شوند.

۲. کارهای مرتبط

سیستم‌های توصیه‌گر اجتماعی با هدف استفاده از روابط اجتماعی بین کاربران در فرآیند توصیه به‌منظور کاهش مشکلات مربوط به شروع سرد و تنگی ماتریس رتبه‌ها ارائه شده‌اند. تاکنون، تحقیقات مختلفی در خصوص استفاده از روابط اجتماعی صریح و ضمنی در سیستم‌های

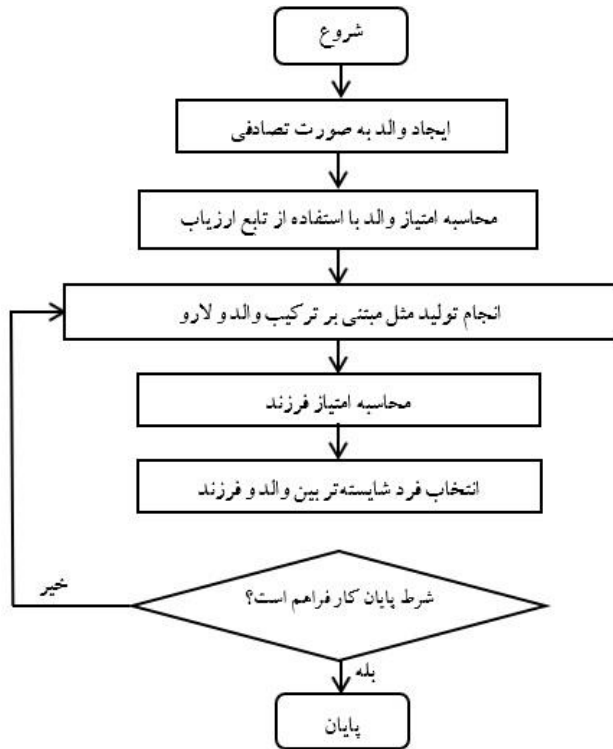
توصیه‌گر انجام شده‌اند. در [۷]، یک روش فاکتورسازی ماتریس ارائه شده است که از روابط اعتماد بین کاربران به منظور تولید توصیه برای کاربران استفاده می‌کند. نویسندگان در [۸] یک روش به نام SoRec معرفی کرده‌اند که روابط اعتماد صریح بین کاربران را به یک فضای ویژگی نگاشته می‌کند. سپس، فضای ویژگی به دست آمده برای پیش‌بینی رتبه‌های نامشخص کاربر هدف مورد استفاده قرار می‌گیرد. در [۹]، نویسندگان یک روش توصیه به نام TrustSVD پیشنهاد داده‌اند که از هر دو روابط اعتماد صریح و ضمنی برای کاهش مشکل تنگی ماتریس رتبه‌ها استفاده می‌کند. در [۱۰]، یک روش به نام SocialMF ارائه شده است که فرآیند انتشار روابط اعتماد در شبکه‌های اجتماعی را در تابع هدف فاکتورسازی ماتریس اعمال می‌کند. ایده اصلی این روش این است که ترجیحات یک کاربر به ترجیحات کاربران موجود در شبکه اجتماعی آن نزدیک می‌باشد. در [۱۱]، یک روش توصیه ارائه شده است که در آن یک گراف بر اساس روابط اعتماد صریح و ضمنی بین کاربران ایجاد می‌گردد. سپس، یک الگوریتم تشخیص جوامع به منظور خوشه‌بندی کاربران بر روی گراف به دست آمده، اجرا می‌شود. در این روش، رتبه‌های نامشخص بر اساس رتبه‌های کاربران موجود در خوشه مربوط به کاربر هدف، پیش‌بینی می‌شوند.

الگوریتم‌های فراابتکاری برای یافتن راه حل بهینه در مسائل بهینه‌سازی پیچیده استفاده می‌شوند. در سال‌های اخیر، چندین الگوریتم فراابتکاری در طراحی سیستم‌های توصیه‌گر مطالعه شده‌اند. به عنوان مثال، در [۱۲]، نویسندگان ابتدا ویژگی‌هایی را برای محاسبه شباهت بین کاربران انتخاب کرده و سپس، الگوریتم‌های فراابتکاری را به منظور یافتن وزن‌های بهینه این ویژگی‌ها استفاده کرده‌اند. در [۱۳]، یک سیستم توصیه‌گر ارائه شده است که در آن از الگوریتم ژنتیک برای یافتن یک تابع شباهت بهینه بین دو کاربر بر اساس رتبه‌های آن‌ها استفاده شده است. یک سیستم توصیه‌گر مبتنی بر موقعیت جغرافیایی در [۱۴] معرفی شده است که از ترجیحات کاربران و اطلاعات زمینه‌ای در فرآیند تولید توصیه استفاده می‌کند. این روش از الگوریتم ژنتیک برای محاسبه شباهت بین کاربران بر اساس اطلاعات زمینه‌ای استفاده می‌کند. در برخی از تحقیقات سعی شده است که از مسائل بهینه‌سازی چندهدفه در طراحی سیستم‌های توصیه‌گر استفاده شود. به عنوان مثال، در [۱۵]، یک روش فراابتکاری چندهدفه برای پیشنهاد لیستی از اقلام مورد علاقه کاربر هدف ارائه شده است که در آن معیارهای مختلفی نظیر دقت، تنوع و جدید بودن توصیه‌ها به طور همزمان در نظر گرفته شده‌اند. در [۱۶]، یک روش به نام TARS برای یافتن بهترین همسایگی برای کاربر هدف بر اساس روابط اعتماد بین کاربران معرفی شده است. بدین منظور، از الگوریتم بهینه‌سازی کلونی مورچگان استفاده شده است. در [۱۷]، از الگوریتم بهینه‌سازی ازدحام ذرات برای یافتن وزن‌های بهینه ویژگی‌های کاربران به کار رفته است. علاوه بر این،

در این روش از مجموعه‌های فازی برای ارائه مؤثر ویژگی‌های کاربران استفاده شده است.

۳. الگوریتم بهینه‌سازی تولیدمثل تک‌جنسیتی مبتنی بر آشوب

روش بهینه‌سازی تولیدمثل تک‌جنسیتی (ARO) یک روش جستجوی تکاملی مبتنی بر فرد می‌باشد که از راهکار تولیدمثل تک‌جنسیتی موجود در طبیعت الهام گرفته است [۱۸]. در این روش، از طریق یک والد با استفاده از عملگر تولیدمثل، فرزند جدید ایجاد می‌شود. سپس، از بین فرزند و والد برحسب اینکه کدام یک کیفیت بهتری دارد، یکی حذف و دیگری باقی می‌ماند. این مقایسه از طریق تابع ارزیابی صورت می‌گیرد. همانند سایر روش‌های بهینه‌سازی، این روند تا زمانی که شرط پایان فراهم نشده، تکرار می‌شود. شکل (۱) جزئیات بیشتر این روش را نشان می‌دهد. از مزیت‌های مهم این روش، سادگی و عدم وجود پارامترهای قابل تنظیم می‌باشد. همچنین، با توجه به فرد-محور بودن الگوریتم، از زمان اجرای مناسبی برخوردار است.



شکل ۱: مراحل کلی الگوریتم تکاملی تولیدمثل تک‌جنسیتی

در این روش، نحوه انجام تولیدمثل از اهمیت بالایی برخوردار است، زیرا هر دو ویژگی حفظ ژن‌های مرغوب و اکتشاف در این مرحله انجام می‌گیرد. شکل (۲) روال کلی این مرحله را نمایش می‌دهد. ابتدا یک زیربازه با طول تصادفی انتخاب شده و سپس با فرض دودویی بودن مقادیر ژن‌ها، صفرها به یک و یک‌ها به صفر تغییر می‌یابند. توالی حاصل

را لارو می نامیم. در ادامه، با ترکیب ژن های والد و لارو، تولیدمثل کامل شده و کروموزوم فرزند ایجاد می شود.



شکل ۲: نحوه تولیدمثل در الگوریتم تکاملی تولیدمثل تک جنسیتی

در صورت به کارگیری این الگوریتم در مسائل بهینه سازی با فضای پیوسته، مرحله تولیدمثل بر اساس روابط زیر انجام می شود:

$$Larva = Parent + \beta, \quad \beta \sim [-1,1] \quad (1)$$

$$Child = \alpha.Larva + (1 - \alpha).Parent \quad (2)$$

در رابطه فوق، β یک مقدار تصادفی در بازه $[-1,1]$ و همچنین α در بازه $[0,1]$ می باشد و میزان توجه به کاوش یا حفظ ژن ها را کنترل می کند. در پایان، انتخاب بین فرزند و والد برحسب رابطه زیر انجام می شود:

$$Parent = \begin{cases} Child, & \text{if } f(Child) > f(Parent) \\ Parent, & \text{else} \end{cases} \quad (3)$$

که f تابعی برای محاسبه ی میزان برازش^۲ فرزند و والد می باشد. با توجه به پیوسته بودن فضای جستجو و نیاز کاوش بیشتر آن، در این مقاله از نسخه بهبود یافته این روش به نام CARO^۳ استفاده می شود [۱۹]. در این نسخه، به منظور تغییر هرچه بیشتر ژن ها در فضای پیوسته، از یک تابع آشوب در مرحله تولیدمثل استفاده می شود. به این صورت که در مراحل اولیه از اجرای الگوریتم (زمانی که تعداد تکرارها کمتر از مقدار پیش فرض k_1 است)، ایجاد لارو به صورت زیر انجام می گیرد:

$$Larva = Parent + S_1(.) \cdot \max\{U - Parent, Parent - L\} \quad (4)$$

در رابطه فوق، L و U به ترتیب کران پایین و بالا در فضای جستجو می باشند، $S_1(.)$ ، یک تابع آشوب^۴ دلخواه می باشد که در این مقاله به صورت معادله زیر انتخاب شده است:

$$r_{k+1} = S_1(r_k) = \sin\left(\frac{70}{r_k}\right), \quad -1 < r_k < 1, k = 1, 2, 3, \dots \quad (5)$$

زمانی که تعداد تکرارها در الگوریتم بیش از مقدار k_1 باشد، به منظور بهره مندی از مرغوبیت ژن ها و اعمال تغییرات جزئی در آن ها، ایجاد لارو به صورت زیر تغییر می یابد:

$$Larva = Parent + S_1(.) \cdot \frac{U - L}{2} \cdot \left(\frac{k_{max} - k}{k_{max}}\right)^2 \quad (6)$$

در رابطه فوق، k_{max} تعداد کل تکرارها می باشد. در ترکیب لارو و والد، مقدار α در رابطه (۲) می تواند در فرآیند جستجو بسیار تعیین کننده باشد. بنابراین، تعیین این مقدار نیز به کمک یک تابع آشوب به صورت زیر انجام می گیرد:

$$Child = S_2(.) \cdot Larva + (1 - S_2(.)) \cdot Parent \quad (7)$$

لازم به ذکر است که تابع آشوب S_2 همانند S_1 می باشد، با این تفاوت که مقدار اولیه متفاوتی برای آن در نظر گرفته می شود.

۴. الگوریتم بهبود یافته بهینه سازی ازدحام ذرات مبتنی بر روش CARO

در این بخش، ابتدا به مرور الگوریتم بهینه سازی ازدحام ذرات^۵ (PSO) پرداخته و سپس تغییرات و بهبود صورت گرفته در آن شرح داده می شود. الگوریتم بهینه سازی ازدحام ذرات یک روش مبتنی بر قواعد احتمال است که برگرفته از رفتار پرندگان در هنگام جستجوی غذا می باشد [۲۰]. در این روش، ابتدا مجموعه ای از جواب های اولیه به صورت تصادفی تولید می شود. به هر یک از این جواب ها یک ذره می گوئیم. هر ذره دلخواه P_i با دو بردار موقعیت $[x_{i,1}, x_{i,2}, \dots, x_{i,D}]$ و سرعت $V_i = [v_{i,1}, v_{i,2}, \dots, v_{i,D}]$ توصیف می شود و در هر مرحله، سرعت ذره متناسب با بهترین موقعیت محلی ذره (pbest) و بهترین موقعیت بین تمام ذرات (gbest) اصلاح شده و در ادامه موقعیت مکانی جدید ذره تعیین می گردد. روابط زیر به ترتیب به روزرسانی بردار سرعت و بردار موقعیت هر ذره را نشان می دهند:

$$v_{i,d} = \omega \cdot v_{i,d} + c_1 \cdot r_{1,d} \cdot (pbest_{i,d} - x_{i,d}) + c_2 \cdot r_{2,d} \cdot (gbest_d - x_{i,d}) \quad (8)$$

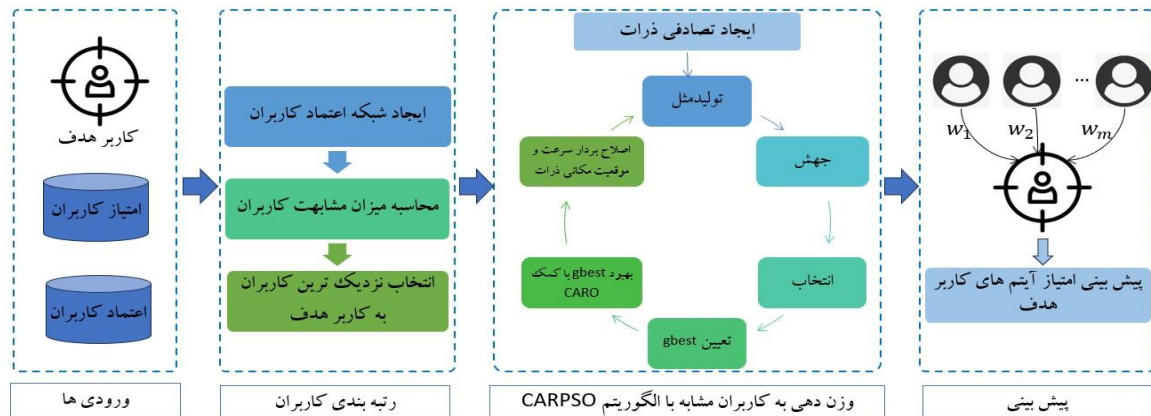
$$x_{i,d} = x_{i,d} + v_{i,d} \quad (9)$$

در رابطه (۸)، ω اینرسی ذره را توصیف کرده و بر پایداری آن تأثیر می گذارد. ضرایب شتاب c_1 و c_2 به ترتیب اهمیت pbest و gbest را در تصمیم گیری ذره تنظیم می کنند. اعداد تصادفی $r_{1,d}$ و $r_{2,d}$ به طور یکنواخت در بازه $[0,1]$ انتخاب شده و تمایل ذره به کاوش را بیان می نمایند.

تبادل اطلاعات بین ذره ها نقش مؤثری در سوق دادن آن ها به بهترین مکان در فضای جستجو ایفا می کند. با این وجود، همگرایی زودرس ذرات و گرفتاری آن ها در بهینه های محلی از نقاط ضعف این روش محسوب می شود. یکی دیگر از روش های بهینه سازی شناخته شده و محبوب، الگوریتم ژنتیک^۶ (GA) می باشد که همانند الگوریتم PSO در حوزه الگوریتم های مبتنی بر طبیعت محسوب می شود. الگوریتم ژنتیک دارای سه عملگر اصلی انتخاب، تولیدمثل و جهش می باشد. عملگر انتخاب با

$$C_{i,d} = rand(0,1), \text{ if } r_d < p_m$$

(۱۱) حفظ کروموزوم‌های برتر در هر نسل، زمینه ارتقا و تکامل نسل را فراهم-



شکل ۳: مراحل کلی سیستم توصیه گر پیشنهادی

در رابطه فوق، r_d یک مقدار تصادفی در بازه $[0,1]$ و p_m احتمال جهش می‌باشد.

مرحله ۳) انتخاب: پس از اعمال عملگرهای تولید مثل و جهش، در این مرحله مقدار تابع برازش برای فرزند به دست آمده و مقایسه آن با ذره اولیه مشخص می‌نماید کدامی ک در نسل بعدی قرار گیرد. در صورت بهتر بودن ذره اولیه، فرزند مغلوب و حذف می‌شود و چنانچه فرزند بهتر باشد، به عنوان مقدار جایگزین در نسل بعدی قرار می‌گیرد.

مرحله ۴) استفاده از الگوریتم CARO: پس از انتخاب بهترین ذره در پایان هر مرحله، به منظور بهبود کیفیت gbest، از الگوریتم CARO که در بخش (۳) توضیح داده شد جهت جستجوی بیشتر در اطراف آن استفاده می‌گردد. با توجه به پیوسته بودن فضای جستجو، این عملگر امکان جستجوی دقیق تر موقعیت gbest را فراهم می‌نماید.

۵. سیستم توصیه گر پیشنهادی

در این بخش، مراحل اصلی روش مقاله توضیح داده می‌شود. هدف اصلی این روش پیش‌بینی دقیق مقدار امتیازهای کاربر هدف به اقلام پیشنهادی می‌باشد. رسیدن به این هدف با هم‌افزایی داده‌های موجود از امتیاز سایر کاربران (ماتریس کاربر-قلم) و شبکه اعتماد کاربران امکان‌پذیر می‌باشد. برای این منظور، میزان مشابهت سایر کاربران با کاربر هدف محاسبه گردیده و کاربران بر این اساس رتبه‌بندی می‌شوند. با توجه به تنگ بودن ماتریس کاربر-قلم، بهره‌مندی از شبکه اعتماد کاربران می‌تواند کمک موثری در محاسبه دقیق نرخ مشابهت باشد. روش ارائه شده، شامل سه مرحله اصلی می‌باشد که عبارتند از: رتبه‌بندی، وزن‌دهی و پیش‌بینی. در گام نخست، بر اساس اطلاعات ماتریس کاربر-قلم و اعتماد کاربران میزان شباهت آن‌ها با کاربر هدف سنجیده و رتبه‌بندی می‌شوند. لازم به ذکر است که برای انجام این کار از رابطه ضریب همبستگی پیرسون^۷ استفاده می‌شود. در گام بعد، همسایگان

می‌کند و عملگرهای تولیدمثل و جهش با ترکیب و تغییر ژن‌ها در تکامل کروموزوم‌ها به ایفای نقش می‌پردازند. اما در الگوریتم PSO، بهبود ذرات براساس اشتراک‌گذاری اطلاعات بین آن‌ها و تجربه شخصی هر ذره از بهترین مکان ملاقات شده، انجام می‌گیرد. به عبارت دیگر، مسیر حرکت ذرات معادل تغییر محتوای ژن‌ها در الگوریتم ژنتیک می‌باشد.

تبادل تصادفی ژن‌ها در کروموزوم‌های والد و تغییرات ژنی از طریق جهش، تنوع گسترده‌ای از ترکیب‌های ممکن را در GA ارائه می‌دهد. در PSO، ذرات به بهترین موقعیت‌های قبلی (pbest) و بهترین جمعیت (gbest) توجه می‌کنند. به این ترتیب، جستجو در مسیری معین و با پراکندگی کمتر نسبت به GA صورت می‌گیرد. بنابراین، می‌توان گفت که GA در اکتشاف برتری دارد، در حالی که PSO به همگرایی سریع توجه می‌کند. با هدف بهره‌مندی از قابلیت‌های هر دو الگوریتم و ایجاد هم‌افزایی بین آن‌ها، پژوهش‌های مختلفی انجام گرفته است. در این مقاله، به منظور کاوش بیشتر فضای جستجو از عملگرهای الگوریتم ژنتیک و همچنین الگوریتم CARO استفاده شده و موقعیت ذرات بهبود می‌یابد. در ادامه، مراحل مختلف این الگوریتم که به اختصار CARPSO می‌نامیم، با جزییات بیشتر توضیح داده می‌شود.

مرحله ۱) تولید مثل: برای هر ذره P_i ، عملگر تولید مثل با در نظر گرفتن pbest، gbest و ذره دیگر P_k که به صورت تصادفی انتخاب شده، مطابق رابطه زیر انجام شده و فرزند آن (C_i) به دست می‌آید:

$$C_{i,d} = \begin{cases} r_d \cdot pbest_{i,d} + (1 - r_d) \cdot gbest_d, & \text{if } f(P_i) < f(P_{k,d}) \\ r_d \cdot pbest_{k,d} + (1 - r_d) \cdot gbest_d & \text{else} \end{cases} \quad (۱۰)$$

در رابطه فوق، r_d یک مقدار تصادفی در بازه $[0,1]$ می‌باشد و k_d اندیس ذره دلخواهی می‌باشد که به طور تصادفی انتخاب می‌شود.

مرحله ۲) جهش: هر یک از مؤلفه‌های فرزند به دست آمده (C_i) از مرحله قبلی، مطابق رابطه زیر تغییر می‌یابد:

کاربران انتخاب شده در مرحله قبل) با استفاده از الگوریتم CARPSO ضریب اهمیت دریافت می‌کنند. این ضریب میزان اثرگذاری کاربر در پیش‌بینی رتبه‌دهی کاربر هدف را توصیف می‌کند. در مرحله نهایی، اقلام قابل پیشنهاد به کاربر هدف پیش‌بینی می‌شوند. شکل (۳) مراحل کلی سیستم توصیه‌گر پیشنهادی را نمایش می‌دهد.

۱.۵. رتبه‌بندی کاربران

هدف اصلی این مرحله از روش پیشنهادی، محاسبه میزان شباهت کاربران با کاربر هدف با استفاده از اطلاعات در دسترس می‌باشد. این مرحله شامل ایجاد یک گراف وزن‌دار می‌باشد که شبکه اعتماد ضمنی بین کاربر هدف و سایر کاربران را توصیف می‌کند. در این گراف، هر گره نشان‌دهنده یک کاربر می‌باشد و وزن یال‌ها بر اساس تحلیل داده‌های مربوط به اعتماد کاربران و ماتریس کاربر-قلم به‌دست می‌آید. برای کاربرانی که بین آن‌ها و کاربر هدف روابط اعتمادی وجود ندارد، میزان اعتماد بر اساس ضریب همبستگی پیرسون بین قلم‌های مشترک تعیین می‌شود. به این ترتیب، مقدار شباهت مبتنی بر اعتماد بین کاربران مطابق با رابطه زیر به‌دست می‌آید [۲۱]:

$$W_{a,u} = \begin{cases} \frac{2 \times \text{sim}(a,u) \times T_{a,u}}{\text{sim}(a,u) + T_{a,u}}, & \text{sim}(a,u) + T_{a,u} \neq 0 \text{ and } \text{sim}(a,u) \times T_{a,u} \neq 0 \\ T_{a,u}, & \text{sim}(a,u) = 0 \text{ and } T_{a,u} \neq 0 \\ \text{sim}(a,u), & \text{sim}(a,u) \neq 0 \text{ and } T_{a,u} = 0 \end{cases} \quad (12)$$

در رابطه فوق، $T_{a,u}$ مقدار اعتماد بین کاربر هدف a و کاربر دلخواه u را نشان می‌دهد. این مقدار به کمک رابطه زیر به‌دست می‌آید:

$$T_{a,u} = \frac{d_{\max} - d_{a,u} + 1}{d_{\max}} \quad (13)$$

در این رابطه، $d_{a,u}$ فاصله انتشار اعتماد بین دو کاربر a و u را نشان می‌دهد. همچنین، d_{\max} حداکثر مقدار فاصله انتشار اعتماد بین کاربران می‌باشد که به‌صورت زیر محاسبه می‌شود:

$$d_{\max} = \frac{\ln(n)}{\ln(k)} \quad (14)$$

در این رابطه، n تعداد کل کاربران در شبکه اعتماد و k میانگین درجه در گراف اعتماد می‌باشد. همچنین، $\text{sim}(a,u)$ بیانگر میزان شباهت بین کاربران a و u می‌باشد که با استفاده از ضریب همبستگی پیرسون به صورت زیر محاسبه می‌شود:

$$\text{sim}(a,u) = \frac{\sum_{i \in A_{a,u}} (r_i(a) - \bar{r}(a))(r_i(u) - \bar{r}(u))}{\sqrt{\sum_{i \in A_{a,u}} (r_i(a) - \bar{r}(a))^2} \sqrt{\sum_{i \in A_{a,u}} (r_i(u) - \bar{r}(u))^2}} \quad (15)$$

در رابطه فوق، $r_i(u)$ مقدار امتیاز کاربر u به قلم i ، $\bar{r}(u)$ مقدار میانگین امتیازهای داده شده توسط کاربر u و $A_{a,u}$ مجموعه اقلام مشترک بین دو کاربر a و u می‌باشد که توسط هر دو کاربر امتیازدهی شده‌اند. در نهایت، کاربرانی که نرخ شباهت آن‌ها از مقدار آستانه θ بیشتر باشد، به عنوان همسایگان کاربر هدف انتخاب می‌شوند. این مقدار آستانه به عنوان

یکی از ورودی‌های روش پیشنهادی قابل مقداردهی اولیه می‌باشد. فرض کنید K_a مجموعه‌ای از کاربران همسایه‌ی کاربر هدف a باشد که مقدار شباهت آن‌ها با کاربر هدف بیشتر از مقدار آستانه θ باشد. این مجموعه با استفاده از رابطه زیر بدست می‌آید:

$$K_a = \{u \in U | W_{a,u} > \theta\} \quad (16)$$

که U مجموعه تمام کاربران موجود در سیستم می‌باشد و $W_{a,u}$ مقدار شباهت بین کاربران a و u است که از رابطه (۱۲) به‌دست می‌آید.

۲.۵. وزن‌دهی به کاربران مشابه

در این مرحله، به کاربران انتخاب‌شده در مرحله قبل ضریبی در بازه [0,1] تخصیص می‌یابد که میزان اهمیت کاربر در پیش‌بینی امتیاز اقلام را بیان می‌کند. برای این منظور از الگوریتم پیشنهادی CARPSO که در بخش (۴) توضیح داده‌شد، استفاده می‌شود. در این الگوریتم، هر ذره دارای یک بردار موقعیت و یک بردار سرعت مجزا می‌باشد. طول این بردارها متناسب با تعداد کاربرانی است که در مجموعه K_a (رابطه ۱۶) وجود دارند. در واقع، هدف استفاده از الگوریتم CARPSO در این مرحله، به‌دست آوردن وزن بهینه W_u برای هر کاربر $u \in K_a$ می‌باشد. این وزن نشان‌دهنده اهمیت کاربر u در پیش‌بینی رتبه‌های کاربر هدف a می‌باشد. لازم به ذکر است که در هر مرحله از تکرار این الگوریتم، بهترین موقعیت بین ذرات با استفاده از الگوریتم پیشنهادی CARO که در بخش (۳) توضیح داده‌شد، بهبود می‌یابد. استفاده از الگوریتم CARO باعث می‌شود که فضای اطراف بهترین موقعیت یافت‌شده به‌طور مؤثرتری جستجو شود.

به‌منظور محاسبه کیفیت جواب‌های به‌دست‌آمده از الگوریتم CARPSO از رابطه میانگین قدرمطلق خطا^۱ استفاده می‌شود. همچنین، جهت پیش‌بینی اقلام کاربر هدف از اطلاعات کاربران مشابه استفاده می‌شود. برای این هدف، ابتدا بخشی از امتیازات از پیش تعیین‌شده کاربر هدف حذف شده و به کمک کاربران همسایه تخمین زده می‌شود. امتیازات کاربر هدف با استفاده از رابطه زیر قابل پیش‌بینی می‌باشند: ناقص

$$\hat{r}_{a,i} = \frac{\sum_{u \in K_a} W_u r_{u,i}}{\sum_{u \in K_a} W_u} \quad (17)$$

در رابطه فوق، $\hat{r}_{a,i}$ مقدار امتیاز پیش‌بینی شده برای کاربر هدف a و آیتم i می‌باشد. مقدار امتیاز کاربر u به قلم i می‌باشد. به این ترتیب، کیفیت هر جواب کاندید به صورت زیر قابل محاسبه خواهد بود:

$$\text{fitness} = \frac{\sum_{i=1}^{I_u} |\hat{r}_{u,i} - r_{u,i}|}{|I_u|} \quad (18)$$

در رابطه فوق، I_u مجموعه‌ای از اقلام است که امتیاز آن‌ها توسط روش پیشنهادی پیش‌بینی شده‌اند.

^۱ Mean Absolute Error

۳.۵. پیش‌بینی رتبه

در این رابطه، Z ، r_{uj} و \hat{r}_{uj} به ترتیب تعداد آیت‌ها، مقدار پیش‌بینی شده و مقدار امتیاز کاربر u به آیت j می‌باشد. معیار RMSE دیگر معیار رایج و مورد استفاده جهت ارزیابی نتایج می‌باشد و بصورت زیر محاسبه می‌شود:

$$RMSE = \sqrt{\frac{1}{Z} \sum_{(u,j)} (\hat{r}_{uj} - r_{uj})^2} \quad (20)$$

معیار دیگری که برای ارزیابی نتایج استفاده می‌شود، معیار پوشش رتبه (RC) می‌باشد. این معیار نسبت رتبه‌های پیش‌بینی شده توسط سیستم توصیه‌گر به کل رتبه‌های قابل پیش‌بینی را محاسبه می‌کند. بنابراین، این معیار به صورت زیر قابل محاسبه است:

$$RC = \frac{\text{number of predicted rates}}{\text{number of all rates}} \quad (21)$$

۲.۶. مجموعه داده

آزمایش‌های انجام شده در این مقاله بر روی مجموعه داده‌ای Epinions^۳ اجرا شده‌اند. این مجموعه داده‌ای شامل اطلاعات رتبه‌های داده شده به اقلام مختلف توسط کاربران می‌باشد که این رتبه‌ها در بازه یک (کمترین علاقه) تا پنج (بیشترین علاقه) تعریف شده‌اند. علاوه بر این، اطلاعات مربوط به روابط اعتماد بین کاربران نیز در مجموعه داده‌ای وجود دارد. این اطلاعات به صورت اعداد یک و صفر می‌باشند که عدد یک نشان‌دهنده وجود رابطه اعتماد بین دو کاربر می‌باشد و عدد صفر عدم وجود رابطه اعتماد بین دو کاربر را نشان می‌دهد. تعداد کل رتبه‌های موجود در این مجموعه داده‌ای برابر ۶۶۴۸۲۴ می‌باشد که توسط ۴۰۱۶۳ کاربر به ۱۳۹۷۳۸ قلم موجود داده شده‌اند. همچنین، تعداد کل روابط اعتماد بین کاربران برابر ۴۸۷۱۸۳ می‌باشد. با توجه به محدودیت‌های سخت‌افزاری برای اجرای آزمایش‌ها و همچنین برای کاهش پیچیدگی محاسباتی الگوریتم‌ها، تعداد ۵۰۰۰ کاربر به همراه رتبه‌ها و روابط اعتماد بین آن‌ها به صورت تصادفی انتخاب شده‌اند. همچنین، به منظور ارزیابی جنبه‌های مختلف روش پیشنهادی، مجموعه داده موجود به بخش‌های مختلف زیر تقسیم شده است:

- Cold-start users: مجموعه‌ای از کاربران که کمتر از پنج رتبه داده شده دارند.
- Heavy raters: مجموعه‌ای از کاربران که به بیش از ۱۰ قلم رتبه داده‌اند.
- Opinion users: مجموعه‌ای از کاربران با بیش از چهار رتبه که انحراف معیار استاندارد این رتبه‌ها بیشتر از ۱,۵ می‌باشد.
- Niche items: مجموعه‌ای از اقلام که کمتر از پنج رتبه دارند.
- Controversial items: مجموعه‌ای از اقلام که انحراف معیار رتبه آن‌ها بیشتر از ۱,۵ می‌باشد.

در این مرحله، بر اساس وزن‌های حاصل از الگوریتم CARPSO در مرحله قبل، رتبه مربوط به اقلام نامشخص کاربر هدف پیش‌بینی می‌شود. بدین منظور، ابتدا کاربران بر اساس وزن‌های بدست آمده مرتب شده و تعداد N کاربر با بیشترین وزن موجود به عنوان همسایگی کاربر هدف انتخاب می‌شوند. سپس، رتبه اقلام نامشخص با استفاده از رابطه (۱۷) پیش‌بینی می‌شوند. همانطور که از این رابطه قابل مشاهده است، رتبه‌های نامشخص بر اساس نظرات کاربران همسایه کاربر هدف پیش‌بینی می‌شوند. همچنین، میزان اهمیت نظر هر کاربر همسایه بر اساس وزن اختصاص داده شده به آن کاربر مشخص می‌گردد. در واقع، یک کاربر همسایه با وزن اختصاص داده شده بیشتر، تاثیر بیشتری نیز در پیش‌بینی رتبه نامشخص خواهد داشت.

۶. آزمایش‌ها

به منظور ارزیابی کارایی روش پیشنهادی نسبت به سایر روش‌های موجود، آزمایش‌ها مختلفی بر اساس یک مجموعه داده‌ای استاندارد انجام شده است. در این آزمایش‌ها، از روش ارزیابی 5-fold cross-validation استفاده شده است که در آن مجموعه داده‌ای به پنج زیرمجموعه مساوی تقسیم می‌شود و در هر تکرار، چهار زیرمجموعه به عنوان مجموعه آموزشی انتخاب شده و زیرمجموعه باقیمانده به عنوان مجموعه آزمایشی در نظر گرفته می‌شود. در نهایت، نتایج نهایی بر اساس میانگین نتایج بدست آمده از پنج اجرای مختلف محاسبه می‌شوند. به منظور مقایسه نتایج روش پیشنهادی با سایر روش‌های موجود، روش TrustSVD [۹]، TrustMF [۲۲]، SocialMF [۱۰]، Bobadilla [۱۳]، Yilmaz [۶] و TARS [۱۶] در نظر گرفته شده‌اند. روش‌های TrustSVD، TrustMF و SocialMF جزو روش‌های مبتنی بر اعتماد می‌باشند. روش‌های Bobadilla، Yilmaz و TARS بر اساس الگوریتم‌های تکاملی طراحی شده‌اند، به طوری که الگوریتم ژنتیک برای روش‌های Bobadilla و Yilmaz و الگوریتم کلونی مورچگان (ACO) برای روش TARS مورد استفاده قرار گرفته‌اند.

۱.۶. معیارهای ارزیابی


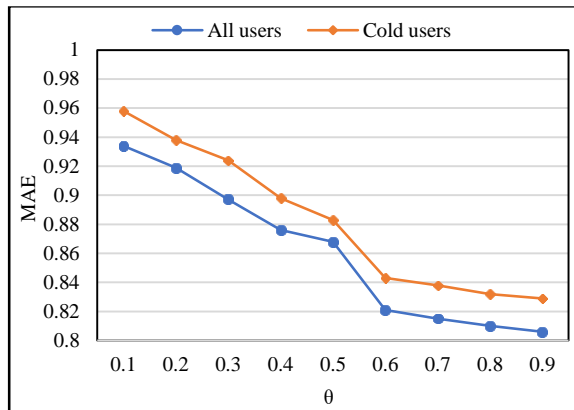
در این مقاله، خطای میانگین قدرمطلق (MAE) و خطای جذر میانگین مربعات (RMSE) به عنوان معیارهای ارزیابی استفاده می‌شوند. از معیار MAE برای بررسی اختلاف مقادیر تخمین زده شده با جواب‌های هدف استفاده می‌شود. جهت محاسبه این مقدار، تعدادی از آیت‌های کاربر هدف انتخاب و به کمک امتیازهای کاربران فیلتر شده از مرحله قبل، پیش‌بینی می‌شوند. در ادامه مطابق رابطه زیر مقدار خطا محاسبه می‌شود:

$$MAE = \frac{1}{Z} \sum_{(u,j)} |\hat{r}_{uj} - r_{uj}| \quad (19)$$

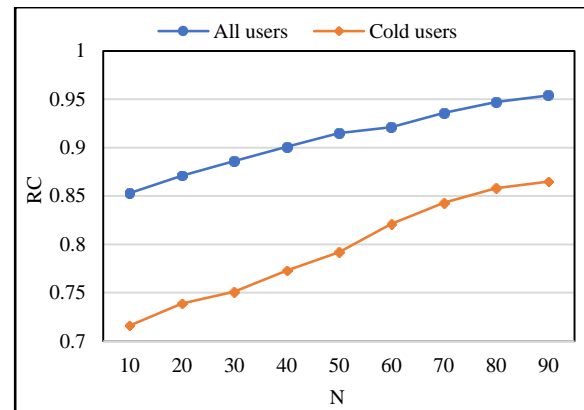
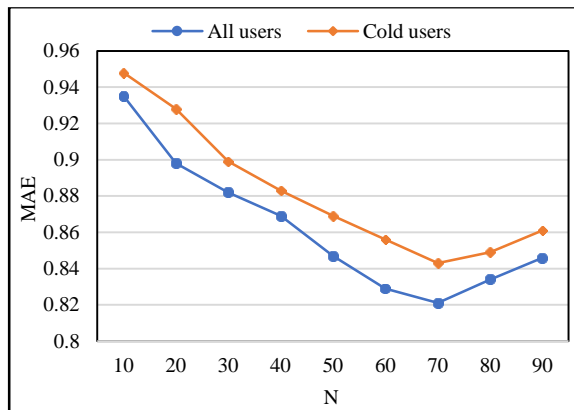
^۹ <http://www.trustlet.org/epinions.html>

جدول ۱: مقایسه روش‌های مختلف بر اساس معیار ارزیابی MAE

Methods	Datasets					
	All users	Cold users	Heavy raters	Opinion users	Controversial items	Niche items
TrustSVD	۰.۸۷۹	۰.۹۰۱	۱.۹۴۲	۰.۹۷۲	۱.۶۱۳	۰.۸۴۶
TrustMF	۰.۹۱۴	۰.۹۵۹	۱.۸۲۳	۰.۹۴۹	۱.۸۷۳	۰.۸۸۱
SocialMF	۰.۸۹۶	۰.۹۴۳	۱.۷۰۶	۰.۹۳۷	۱.۷۱۴	۰.۸۶۵
Bobadilla	۰.۸۹۴	۰.۹۲۴	۱.۵۹۱	۰.۹۴۱	۱.۷۸۱	۰.۸۲۹
Yilmaz	۰.۸۸۷	۰.۹۱۸	۱.۵۷۸	۰.۹۲۴	۱.۷۴۳	۰.۸۵۷
TARS	۰.۸۶۲	۰.۸۹۷	۱.۵۸۲	۰.۹۱۰	۱.۷۱۲	۰.۸۷۳
روش پیشنهادی	۰.۸۲۱	۰.۸۴۳	۱.۴۴۵	۰.۸۶۷	۱.۴۸۶	۰.۷۹۱



شکل ۴: تأثیر مقادیر مختلف پارامتر θ بر روی کارایی روش پیشنهادی



شکل ۵: تأثیر مقادیر مختلف پارامتر N بر روی کارایی روش پیشنهادی

تعداد تکرارها و تعداد جمعیت می‌باشد که مقادیر آن‌ها به ترتیب برابر ۳۰ و ۲۰ انتخاب شده‌اند. به منظور مقایسه عادلانه روش پیشنهادی با سایر روش‌های مبتنی بر الگوریتم‌های فراابتکاری Yilmaz, Bobadilla و TARS، تعداد تکرارها و تعداد جمعیت در این روش‌ها نیز دقیقاً برابر مقادیر انتخاب شده برای روش پیشنهادی در نظر گرفته شده‌است. مقادیر پارامترهای ورودی سایر روش‌های مقایسه شده شامل TrustSVD، TrustMF و SocialMF بر اساس مقادیر بهینه گزارش شده در مقالات متناظر آن‌ها انتخاب شده‌اند.

• All users: در این حالت، تمام کاربران در نظر گرفته می‌شوند.

۳.۶. تنظیم پارامترها

به منظور اجرای آزمایش‌ها مختلف باید مقادیر پارامترهای ورودی الگوریتم‌ها را مقداردهی نماییم. روش پیشنهادی دارای دو پارامتر ورودی θ و N می‌باشد که مقادیر آن‌ها به ترتیب برابر ۰.۶ و ۷۰ انتخاب شده‌اند. علاوه بر این، الگوریتم فراابتکاری استفاده شده در روش پیشنهادی به منظور بهینه‌سازی وزن‌های بین کاربران نیز دارای دو پارامتر اصلی شامل

۴.۶. تحلیل حساسیت پارامترها

روش پیشنهادی دارای دو پارامتر ورودی θ و N می‌باشد که مقادیر آن‌ها تأثیر بسزایی بر روی کارایی الگوریتم دارند. پارامتر θ در رابطه (۱۶) برای مشخص کردن همسایگی کاربر هدف به عنوان یک مقدار آستانه برای میزان شباهت بین کاربران مورد استفاده قرار می‌گیرد. پارامتر N برابر تعداد کاربران موجود در همسایگی کاربر هدف به منظور پیش‌بینی رتبه‌های نامشخص می‌باشد. در این بخش، آزمایش‌ها مختلفی به منظور بررسی تأثیر مقادیر مختلف این پارامترها بر روی کارایی روش پیشنهادی انجام شده‌است. شکل (۴) تأثیر مقادیر مختلف پارامتر θ بر روی کارایی روش پیشنهادی بر اساس معیارهای ارزیابی MAE و RC را نشان می‌دهد. بدین منظور، دو مجموعه داده‌ای شامل همه کاربران و کاربران شروع سرد در نظر گرفته شده‌اند. همان‌طور که ملاحظه می‌شود، افزایش مقادیر این پارامتر از ۰.۱ تا ۰.۹ باعث کاهش مقادیر معیارهای MAE و RC می‌شود. بنابراین، می‌توان نتیجه گرفت که مقادیر بزرگتر پارامتر θ

۵.۶. مقایسه کارایی روش‌های مختلف

در این بخش، کارایی روش پیشنهادی با سایر روش‌های توصیه‌گر بر اساس معیارهای ارزیابی MAE، RMSE و RC مقایسه می‌شود. نتایج آزمایش‌های مربوط به معیار MAE برای تمامی روش‌های مقایسه شده در جدول (۱) نشان داده شده‌اند. این نتایج نشان می‌دهند که روش پیشنهادی در مقایسه با سایر روش‌ها بر اساس جنبه‌های مختلف مجموعه داده‌ای ورودی عملکرد بهتری دارد. به عنوان مثال، مقدار MAE حاصل توسط روش پیشنهادی بر روی All users برابر ۰.۸۲۱ می‌باشد، در صورتی که روش TARS به عنوان دومین روش، مقدار ۰.۸۹۴ را به دست آورده‌است. باید توجه شود که مقدار کمتر MAE نشان‌دهنده خطای کمتر و در نتیجه عملکرد بهتر می‌باشد. روش TARS در اکثر موارد نسبت به سایر روش‌های مقایسه شده با روش پیشنهادی، عملکرد بهتری را از خود نشان می‌دهد. بر اساس مجموعه Heavy raters، روش Yilmaz با کسب مقدار ۱.۵۷۸ برای معیار MAE، دومین روش بعد از

جدول ۲: مقایسه روش‌های مختلف بر اساس معیار ارزیابی RMSE

Methods	Datasets					
	All users	Cold users	Heavy raters	Opinion users	Controversial items	Niche items
TrustSVD	۱,۱۵۸	۱,۱۸۲	۲,۰۴۵	۱,۳۵۴	۱,۸۷۳	۱,۱۵۸
TrustMF	۱,۲۰۳	۱,۴۰۱	۲,۱۰۹	۱,۳۶۸	۲,۰۹۵	۱,۲۳۴
SocialMF	۱,۱۷۴	۱,۳۵۲	۱,۹۷۳	۱,۳۳۷	۲,۰۱۲	۱,۱۸۰
Bobadilla	۱,۱۸۰	۱,۱۹۷	۱,۹۴۹	۱,۳۲۴	۱,۹۳۶	۱,۱۱۴
Yilmaz	۱,۱۶۴	۱,۱۹۲	۱,۹۵۲	۱,۳۰۳	۱,۹۳۱	۱,۱۴۶
TARS	۱,۱۴۶	۱,۱۸۳	۱,۹۷۱	۱,۱۸۷	۱,۸۶۵	۱,۱۷۳
روش پیشنهادی	۱,۱۲۰	۱,۱۱۴	۱,۸۵۴	۱,۱۰۶	۱,۷۱۳	۰,۹۹۵

روش پیشنهادی می‌باشد. همچنین، روش Bobadilla بهترین عملکرد را بعد از روش پیشنهادی بر روی مجموعه Niche items دارد. جدول (۲) نتایج آزمایشات بر اساس معیار ارزیابی RMSE را برای تمامی روش‌های توصیه‌گر نشان می‌دهد. هر چقدر مقدار حاصل برای معیار ارزیابی RMSE کمتر باشد، نشان‌دهنده کارایی بالاتر مدل خواهد بود. همان‌طور که از این نتایج مشاهده می‌شود، روش پیشنهادی بهترین عملکرد را در مقایسه با سایر روش‌ها بر اساس تمامی جنبه‌های در نظر گرفته شده برای مجموعه داده‌ای به دست می‌آورد. روش TARS در تمامی جنبه‌ها به غیر از Heavy raters و Niche items بهترین عملکرد را بعد از روش پیشنهادی به دست می‌آورد. روش Bobadilla با به دست آوردن مقادیر ۱,۹۴۹ و ۱,۱۱۴ به ترتیب برای مجموعه‌های Heavy raters و Niche items، دومین روش از لحاظ معیار RMSE می‌باشد. با توجه به نتایج حاصل از جدول (۲)، می‌توان نتیجه گرفت که استفاده از روش پیشنهادی جهت پیش‌بینی رتبه‌های کاربران باعث افزایش کارایی سیستم‌های توصیه‌گر در مقایسه با سایر روش‌ها می‌شود. به عبارت دیگر، روش پیشنهادی پیش‌بینی‌های با خطای کمتری را نسبت به سایر روش‌ها به دست می‌آورد.

باعث کاهش میزان خطای پیش‌بینی‌ها شده ولی در عین حال نرخ پیش‌بینی رتبه‌ها بر اساس معیار RC را کاهش می‌دهد. آزمایش‌های مشابهی به منظور بررسی تأثیر مقادیر مختلف پارامتر N بر روی کارایی روش پیشنهادی انجام شده‌اند که نتایج آن‌ها در شکل (۵) نشان داده شده‌اند. بدین منظور، مقادیر مختلف این پارامتر برای دو مجموعه داده‌ای شامل همه کاربران و کاربران شروع سرد بر اساس معیارهای ارزیابی MAE و RC بررسی شده‌اند. این نتایج نشان می‌دهند که افزایش مقدار پارامتر N از ۱۰ تا ۷۰ باعث کاهش خطای پیش‌بینی‌ها بر اساس معیار MAE می‌شود. با این حال، زمانی که مقدار این پارامتر بیشتر از ۷۰ باشد، نرخ خطا افزایش پیدامی‌کند. این نتایج قابل‌انتظار می‌باشند زیرا افزایش بیش از حد تعداد کاربران در همسایگی کاربر هدف باعث اضافه‌نمودن کاربران با علایق متفاوت نسبت به علایق کاربر هدف شده و در نتیجه خطای پیش‌بینی افزایش خواهد یافت. علاوه بر این، نتایج نشان می‌دهند که افزایش مقدار پارامتر N باعث افزایش معیار ارزیابی RC می‌شود.

همسایگی جدیدی برای کاربر هدف مشخص شده و رتبه‌های نامشخص این کاربر بر اساس علائق کاربران همسایه پیش‌بینی می‌شود. نتایج آزمایش‌ها بر روی یک مجموعه داده استاندارد نشان دادند که روش پیشنهادی نسبت به سایر روش‌های مقایسه‌شده از عملکرد بهتری برخوردار می‌باشد. در کارهای آتی می‌توان از روابط عدم اعتماد بین کاربران در کنار روابط اعتماد و ماتریس‌ها در تولید توصیه‌ها استفاده نمود. همچنین، الگوریتم فراابتکاری پیشنهادی در این مقاله می‌تواند به

روش‌های مختلف بر اساس معیار ارزیابی RC نیز مقایسه‌شده‌اند که نتایج حاصل از این آزمایش‌ها در جدول (۳) نشان‌دهنده‌اند. معیار RC بیان‌کننده میزان توانایی روش‌های توصیه‌گر در پیش‌بینی رتبه‌های نامشخص می‌باشد. بنابراین، مقدار بالاتر این معیار نشان‌دهنده کارایی بالاتر روش‌ها می‌باشد. بر اساس نتایج در جدول (۳) می‌توان نتیجه گرفت که روش پیشنهادی در تمامی مجموعه‌های داده‌ای به غیر از Cold users کارایی بالاتری نسبت به سایر روش‌ها دارد. برای مجموعه

جدول ۳: مقایسه روش‌های مختلف بر اساس معیار ارزیابی RC

Methods	Datasets					
	All users	Cold users	Heavy raters	Opinion users	Controversial items	Niche items
TrustSVD	۰.۹۲۱	۰.۸۳۱	۰.۹۳۴	۰.۸۵۲	۰.۸۶۰	۰.۷۵۸
TrustMF	۰.۹۰۴	۰.۷۹۶	۰.۹۱۸	۰.۸۰۹	۰.۸۳۱	۰.۷۰۱
SocialMF	۰.۹۲۵	۰.۸۴۵	۰.۹۴۲	۰.۸۶۱	۰.۸۷۲	۰.۷۷۴
Bobadilla	۰.۸۹۳	۰.۷۸۱	۰.۹۰۳	۰.۷۹۵	۰.۸۰۱	۰.۶۹۲
Yilmaz	۰.۹۰۸	۰.۸۱۴	۰.۹۲۷	۰.۸۲۷	۰.۸۳۴	۰.۷۱۳
TARS	۰.۸۸۴	۰.۷۶۰	۰.۹۱۴	۰.۷۸۱	۰.۷۹۵	۰.۶۵۷
روش پیشنهادی	۰.۹۳۶	۰.۸۴۳	۰.۹۵۸	۰.۸۶۹	۰.۸۸۱	۰.۷۹۲

منظور طراحی انواع دیگر سیستم‌های توصیه‌گر نظیر سیستم‌های توصیه‌گر مبتنی بر اطلاعات زمینه نیز استفاده شود.

References

- [۱] M. M. Bendouch, F. Frasinca, and T. Robal, "A visual-semantic approach for building content-based recommender systems," *Information Systems*, vol. 117, p. 102243, 2023/07/01/ 2023.
- [۲] A. Fareed, S. Hassan, S. B. Belhaouari, and Z. Halim, "A collaborative filtering recommendation framework utilizing social networks," *Machine Learning with Applications*, vol. 14, p. 100495, 2023/12/15/ 2023.
- [۳] C. Xu, Y. Zhang, H. Chen, L. Dong, and W. Wang, "A fairness-aware graph contrastive learning recommender framework for social tagging systems," *Information Sciences*, vol. 640, p. 119064, 2023/09/01/ 2023.
- [۴] G. Wang, H. Wang, J. Gong, and J. Ma, "Joint item recommendation and trust prediction with graph neural networks," *Knowledge-Based Systems*, vol. 285, p. 11, 2024.
- [۵] Y.-J. Gong, J.-J. Li, Y. Zhou, Y. Li, H. S.-H. Chung, Y.-H. Shi, et al., "Genetic learning particle swarm optimization," *IEEE transactions on cybernetics*, vol. 46, pp. 2277-2290, 2015.
- [۶] Y. Ar and E. Bostanci, "A genetic algorithm solution to the collaborative filtering problem," *Expert Systems with Applications*, vol. 61, pp. 122-128, 2016/11/01/ 2016.
- [۷] H. Ma, I. King, and M. R. Lyu, "Learning to recommend with social trust ensemble," presented at the Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval, Boston, MA, USA, 2009.
- [۸] H. Ma, H. Yang, M. R. Lyu, and I. King, "SoRec: social recommendation using probabilistic matrix factorization," presented at the Proceedings of the 17th ACM conference on Information and knowledge management, Napa Valley, California, USA, 2008.

users، روش پیشنهادی و روش SocialMF به ترتیب مقادیر ۰.۸۴۳ و ۰.۸۴۵ را به دست آورده‌اند. بنابراین، کارایی روش SocialMF نسبت به روش پیشنهادی بر اساس معیار RC برای مجموعه Cold users بالاتر می‌باشد. با این وجود باید توجه داشت که میزان تفاوت این دو روش برابر ۰.۰۰۲ می‌باشد که مقداری ناچیز است. همچنین، روش پیشنهادی نسبت به روش SocialMF بر اساس معیارهای MAE و RMSE عملکرد به مراتب بهتری را از خود نشان می‌دهد. بنابراین، در مجموع می‌توان نتیجه گرفت که روش پیشنهادی نسبت به سایر روش‌های مبتنی بر اعتماد و روش‌های مبتنی بر الگوریتم‌های فراابتکاری بر اساس معیارهای ارزیابی مختلف نتایج بهتری را به دست می‌دهد.

۷. نتیجه‌گیری

در این مقاله، یک سیستم توصیه‌گر مبتنی بر روابط اعتماد بین کاربران معرفی شد. روش پیشنهادی شامل سه مرحله اصلی می‌باشد. در مرحله اول، میزان شباهت بین کاربران بر اساس ماتریس رتبه‌های کاربر-قلم و روابط اعتماد بین کاربران محاسبه می‌شود. سپس، بر اساس مقادیر شباهت محاسبه‌شده، یک همسایگی شامل نزدیک‌ترین کاربران به کاربر هدف مشخص می‌گردد. در مرحله دوم، یک روش بهینه‌سازی به منظور یافتن وزن‌های شباهت بهینه بین کاربران مورد استفاده قرار می‌گیرد. بدین منظور، یک الگوریتم فراابتکاری جدید بر اساس الگوریتم بهینه‌سازی ازدحام ذرات ارائه شده است. در این الگوریتم، از عملگرهای الگوریتم ژنتیک و همچنین از الگوریتم بهینه‌سازی تولیدمثل تک-جنسیتی مبتنی بر آشوب به منظور افزایش قابلیت جستجوی روش پیشنهادی و کاهش احتمال گیر افتادن در بهینه‌های محلی استفاده شده است. در مرحله سوم، بر اساس وزن‌های شباهت بهینه حاصل شده،

پی‌نوشت:

1. Asexual Reproduction Optimization
2. Fitness
3. Chaotic Asexual Reproduction Optimization
4. Chaotic
5. Particle Swam Optimization
6. Generic Algorithm
7. Pearson Correlation Coefficient
8. قدر مطلق خطا
9. Epinions

- [۹] G. Guo, J. Zhang, and N. Yorke-Smith, "TrustSVD: Collaborative Filtering with Both the Explicit and Implicit Influence of User Trust and of Item Ratings," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 29, 02/09 2015.
- [۱۰] M. Jamali and M. Ester, "A matrix factorization technique with trust propagation for recommendation in social networks," presented at the Proceedings of the fourth ACM conference on Recommender systems, Barcelona, Spain, 2010.
- [۱۱] P. Moradi, S. Ahmadian, and F. Akhlaghian, "An effective trust-based recommendation method using a novel graph clustering algorithm," *Physica A: Statistical Mechanics and its Applications*, vol. 436, pp. 462-481, 2015/10/15/ 2015.
- [۱۲] V. Agarwal and K. K. Bharadwaj, "Trust-Enhanced Recommendation of Friends in Web Based Social Networks Using Genetic Algorithms to Learn User Preferences," in *Trends in Computer Science, Engineering and Information Technology*, Berlin, Heidelberg, 2011, pp. 476-485.
- [۱۳] J. Bobadilla, F. Ortega, A. Hernando, and J. Alcalá, "Improving collaborative filtering recommender system results and performance using genetic algorithms," *Knowledge-Based Systems*, vol. 24, pp. 1310-1316, 2011/12/01/ 2011.
- [۱۴] T. H. Dao, S. R. Jeong, and H. Ahn, "A novel recommendation model of location-based advertising: Context-Aware Collaborative Filtering using GA approach," *Expert Systems with Applications*, vol. 39, pp. 37, 2012.
- [۱۵] M. T. Ribeiro, A. Lacerda, A. Veloso, and N. Ziviani, "Pareto-efficient hybridization for multi-objective recommender systems," presented at the Proceedings of the sixth ACM conference on Recommender systems, Dublin, Ireland, 2012.
- [۱۶] P. Bedi and R. Sharma, "Trust based recommender system using ant colony for trust computation," *Expert Systems with Applications*, vol. 39, pp. 1183-1190, 2012/01/01/ 2012.
- [۱۷] M. Wasid and V. Kant, "A Particle Swarm Approach to Collaborative Filtering based Recommender Systems through Fuzzy Features," *Procedia Computer Science*, vol. 54, pp. 440-448, 2015/01/01/ 2015.
- [۱۸] A. Farasat, M. B. Menhaj, T. Mansouri, and M. R. S. Moghadam, "ARO: A new model-free optimization algorithm inspired from asexual reproduction," *Applied Soft Computing*, vol. 10, pp. 1284-1292, 2010.
- [۱۹] X. Yuan, Y. Xiang, Y. Wang, and X. Yan, "Parameter identification of bidirectional IPT system using chaotic asexual reproduction optimization," *Nonlinear Dynamics*, vol. 78 ,pp. 2113-2127, 2014.
- [۲۰] R. Eberhart and J. Kennedy, "A new optimizer using particle swarm theory," in *MHS'95. Proceedings of the sixth international symposium on micro machine and human science*, 1995, pp. 39-43.
- [۲۱] P. Moradi and S. Ahmadian, "A reliability-based recommendation method to improve trust-aware recommender systems," *Expert Systems with Applications*, vol. 42, pp. 7386-7398, 2015.
- [۲۲] B. Yang, Y. Lei, J. Liu, and W. Li, "Social Collaborative Filtering by Trust," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, pp. 1633-1647, 2017.