

Improving Collaborative Filtering Recommender System Results and Performance using Combination of Fuzzy Grey Wolf Optimizer Algorithm and Lion Optimization Algorithm

Zahra Nakhaei Rad*, Hessam Zandhessami,
Abbas Tolouee Ashlaghi*****

Abstract

Nowadays, recommender systems have reshaped the ways of information filtering between websites and the users in order to identify the users' interests and generate product suggestions for the active users. Recommender systems are generally divided into three groups: Content-based, Knowledge-based, and collaborative-based, and in some cases hybrid. The main idea of collaborative filtering is that they predict a user's interest in new items based on the recommendations of other people with similar interests. This Approach does not require having knowledge about items. Collaborative filtering has two main types: Memory-based and Model-based. Memory based Collaborative filtering makes use of user rating dataset to compute similarity index between set of users or set of items. The main purpose of this article is to offer a Memory-based Collaborative recommender system in order to optimize the results of Collaborative filtering algorithm. In the proposed method, the combination of fuzzy Grey Wolf Optimizer algorithm and Lion Optimization Algorithm is used to find the most similar users to the target user. The results of the proposed method confirmed a significant increment in Precision, Recall and F-measure in comparison with baseline methods.

Keywords: Recommender Systems; Collaborative Filtering; Metaheuristic Algorithms; Grey Wolf Optimizer Algorithm; Lion Optimization Algorithm.

Received: May. 26, 2021; Accepted: Sep. 09, 2021.

* Ph.D Candidate in Information Technology Management, Faculty of Management and Economics, Islamic Azad University, Science and Research Branch.

** Assistant Professor, Department of Industrial Management, Faculty of Management and Economics, Islamic Azad University, Science and Research Branch (Corresponding Author).

E mail: h.zand@srbiau.ac.ir

*** Professor, Department of Industrial Management, Faculty of Management and Economics, Islamic Azad University, Science and Research Branch.

چشم‌انداز مدیریت صنعتی

شاپای چاپی: ۹۸۷۴-۲۲۵۱، شاپای الکترونیکی: ۴۱۶۵-۲۶۴۵

سال یازدهم، شماره ۴۴، زمستان ۱۴۰۰، صص ۱۹۷-۲۲۲ (نوع مقاله: پژوهشی)

DOI: [10.52547/JIMP.11.4.197](https://doi.org/10.52547/JIMP.11.4.197)

بهبود عملکرد و نتایج سیستم توصیه‌گر پالایش مشارکتی با استفاده از الگوریتم بهینه‌سازی گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر

زهرا نخعی راد*، حسام زندحسامی** عباس طلوعی اسلقی***

چکیده

امروزه سیستم توصیه‌گر، روش پالایش اطلاعات بین وبسایتها و کاربران را به منظور شناسایی علاقه کاربر و ایجاد محصول پیشنهادی برای کاربران فعال تغییر داده است. سیستم‌های توصیه‌گر را به طور کلی به سه گروه مبتنی بر محتوا، مبتنی بر پالایش مشارکتی و در بعضی موارد ترکیبی تقسیم می‌کنند. ایده اصلی پالایش مشارکتی این است که اگر کاربران علائق مشابه یا یکسان در گذشته داشته باشند و آن را باشتراب بگذارند، در آینده نیز احتمالاً سلیقه‌های مشابه خواهند داشت. این رویکرد نیاز به هیچ دانشی در مورد آیتم‌ها ندارد. پالایش مشارکتی نیز دارای دو نوع اصلی مبتنی بر حافظه و مبتنی بر مدل است. روش مبتنی بر حافظه از اطلاعات امتیازدهی کاربران برای محاسبه شbahت بین کاربران یا آیتم‌ها استفاده می‌کند. هدف اصلی این پژوهش نیز ارائه یک سیستم پیشنهاددهنده مبتنی بر حافظه برای بهبود نتایج الگوریتم پالایش مشارکتی است. در روش پیشنهادی برای یافتن شبیه‌ترین کاربران به کاربر هدف از ترکیب دو الگوریتم گرگ خاکستری فازی و الگوریتم شیر استفاده شده است. نتایج اجرای روش پیشنهادی نشان می‌دهد که پارامترهای Precision، Recall و F-measure نسبت به روش‌های پایه افزایش یافته‌اند.

کلیدواژه‌ها: سیستم‌های توصیه‌گر؛ پالایش مشارکتی؛ الگوریتم‌های فراابتکاری؛ الگوریتم بهینه‌سازی گرگ خاکستری؛ الگوریتم بهینه‌سازی شیر.

تاریخ دریافت مقاله: ۱۴۰۰/۰۳/۰۵، تاریخ پذیرش مقاله: ۱۴۰۰/۰۶/۱۸.

* دانشجوی دکتری مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات.

** استادیار، گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات (نویسنده مسئول).
Email: h.zand@srbiau.ac.ir.

*** استاد، گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات.

۱. مقدمه

در این دوره مدرن، همه افراد برای یافتن نیازها، محصولات، خدمات و اقلام روزانه به اینترنت وابسته هستند. این امر یک پدیده طبیعی در روند تصمیم‌گیری انسان تلقی می‌شود. سیستم‌های پیشنهاددهنده با فیلترکردن اطلاعات عظیم در مورد میلیون‌ها محصول و اقلام از طریق وبسایت‌ها، به کاربران کمک می‌کنند تا راحت‌تر و سریع‌تر تصمیم بگیرند. مسئله اصلی این است که مواردی را به کاربران توصیه کنید که موردنیست واقع شوند و نرخ بالایی را برای پاسخگویی به انتظارات آن‌ها ارائه دهند [۱].

سیستم توصیه‌گر نقش خود را در قالب ارائه‌دهنده داده‌های دقیق‌تر و قابل‌اعتماد‌تر به کاربران خاص خود ایفا می‌کند. سیستم توصیه‌گر اطلاعات و نظرهای مربوطه را برای کاربر یا مجموعه‌ای از گروه‌ها جمع‌آوری خواهد کرد. برای مثال، اگر کاربر جدیدی برای ثبت‌نام در وبسایت آمازون وارد شود، موتور توصیه سعی می‌کند عملکرد و الگوی کاربر را بررسی کند [۲۳]؛ از سوی دیگر گسترش زیاد اطلاعات در اینترنت نیاز به سیستم توصیه‌گر در مقیاس بزرگ را به وجود آورده است. سیستم پیشنهاددهنده به فیلترکردن انبوهای داده‌های تولیدشده توسط کاربران در اینترنت کمک می‌کند و به شناسایی علائق کاربر بر اساس سوابق و رفتار گذشته وی منجر می‌شود. یک سیستم توصیه‌گر، تکنیک متمایزی است که برای طبقه‌بندی «N» موردی که ممکن است مورد توجه کاربر باشند، استفاده می‌شود؛ همچنین بر روی این موضوع تمرکز می‌کند که آیا یک فرد می‌تواند یک مورد خاص را دوست داشته باشد یا خیر؟ نخستین سیستم توصیه‌گر در سال ۱۹۹۲ معرفی شد و یک سیستم پیام الکترونیکی^۱ بود که به کاربران اجازه ارسال پیام با مفهوم خوب یا بد را می‌داد. این روش بیشتر برای عملیاتی مانند فیلترکردن، بازیابی و مرور اسناد الکترونیکی در جریان بی‌وقفه داده‌ها استفاده می‌شد. به طور معمول یک سیستم توصیه‌گر، یک تکنیک شخصی‌سازی است که با ارزیابی پروفایل شخص با بعضی از ویژگی‌های مرجع، به کاربران در پیداکردن یک محصول و یا اطلاعات مانند ویدیو، آهنگ، محصولات تجارت الکترونیک، فیلم و غیره کمک می‌کند. ویژگی‌های مرجع به سیستم توصیه‌گر در تصمیم‌گیری درباره «اولویت» کاربر برای یک مورد کشف‌نشده، کمک می‌کند [۳۱].

سیستم‌های توصیه‌گر کاربردهای متعددی از پایش اطلاعات موجود در وب به منظور غلبه بر مشکل سربار اطلاعات^۲ تا رشد و توسعه تجارت الکترونیکی دارند. یک سیستم توصیه‌گر مناسب به مدیران فروشگاه‌های اینترنتی کمک می‌کند که محصولات خود را به طور هدفمندتری به فروش برسانند؛ زیرا می‌تواند توجه افراد مشاهده‌گر در وبسایت را به محصولات مورد علاقه‌شان جلب کرده و آن‌ها را به خرید وارد کند؛ همچنین می‌تواند به کاربرانی که خرید انجام داده‌اند،

1. e-messaging system

2. Information Overload

پیشنهادهای مناسبی بدهد و آن‌ها را به خرید بیشتری ترغیب کند؛ درنتیجه سیستم توصیه‌گر خوب می‌تواند به فروش بیشتر محصولات کمک کند و از این نظر می‌توان آن را مکمل هوشمندی برای بازاریابی در نظر گرفت. درواقع یک سیستم توصیه‌گر مناسب به مدیران در ارائه محصولات سفارشی به مشتریان خود یاری می‌رساند و به عنوان ابزاری سودمند در مدیریت ارتباط با مشتری^۱ مطرح می‌شود. در این پژوهش، هدف بهبود سیستم توصیه‌گر برای توصیه محصولات مورد علاقه به کاربران مختلف است؛ به طوری که درنهایت این بهبود به ارتقای کیفیت فرآیند بازاریابی و مدیریت ارتباط با مشتریان منجر خواهد شد.

چندین مدل برای پیشنهاد در سیستم توصیه‌گر استفاده می‌شوند که بر پایه سه مدل اصلی هستند [۳۲]:

۱. مدل پالایش مشارکتی^۲: این مدل که بیشترین استفاده را در سیستم توصیه‌گر دارد، بر اساس این فرض پایه است که کاربران دارای سلیقه مشابه در گذشته احتمالاً دارای سلیقه مشابه در آینده هستند.

این مدل دارای دو نوع روش است که عبارت‌اند از: روش مبتنی بر همسایگی و روش مبتنی بر مدل. روش مبتنی بر همسایگی می‌تواند در دو حالت زیر تعریف شود: پالایش مشارکتی مبتنی بر کاربر^۳: به کمک تحلیل اطلاعات، استخراج داده‌ها و هدف‌قراردادن فعالیت‌های کاربر، همسایه‌های کاربر با علاقه‌های مشابه مشخص می‌شوند؛ سپس به وسیله یافتن نزدیک‌ترین همسایه‌ها به کاربر موردنظر، گزینه‌های کاربر را بر اساس این همسایه‌ها پیشنهاد می‌کند.

پالایش مشارکتی مبتنی بر آیتم^۴: محصولات مشابه را با نتایج مطلوب پیدا می‌کند و سپس به کسانی که آن محصول را دوست دارند، پیشنهاد می‌دهد.

۲. سیستم توصیه‌گر مبتنی بر محتوا^۵: توصیه‌های سیستم‌های توصیه‌گر مبتنی بر محتوا به وسیله بیان ارتباط میان ویژگی‌های آیتم‌ها ایجاد می‌شود؛ به عبارت دیگر این سیستم‌ها اطلاعات موردنیاز از کاربر را از طریق آیتم‌هایی که پیش از آن مشاهده کرده‌اند، جمع‌آوری می‌کنند. این سیستم‌ها تنوعی از آیتم‌های غیرمعروف و معروف به وسیله استفاده از تکنیک‌های هوشمند مانند شبکه‌های عصبی پیشنهاد می‌دهند؛ همچنین برخی از این سیستم‌ها از پیوند بین آیتم‌ها برای یافتن قواعد وابستگی آیتم و آیتم‌های متجانس استفاده می‌کنند.

1. CRM(Customer Relationship Management)

2. Collaborative Filtering (CF)

3. User-based CF

4. Item-based CF

5. Content-based RS

۳. سیستم توصیه‌گر مبتنی بر دانش^۱: این سیستم از نیازهای کاربر که به صراحت توسط وی تعیین شده است برای پیشنهاد آیتم‌ها استفاده می‌کند. این سیستم را می‌توان در زمینه خاصی، مانند خرید خانه یا افلام عتیقه، اجرا کرد. به این دلیل که تاریخچه کاربر/ آیتم کافی در این زمینه‌ها وجود ندارد و اطلاعات دردسترس از کاربر یا محصول وجود ندارد.

۴. سیستم‌های توصیه‌گر ترکیبی^۲ نیز مطرح شده‌اند و بر اساس قدرت الگوریتم‌های خود، مدل‌های مختلف را در سیستم‌های مرکب ترکیب کرده‌اند؛ البته همراه با رویکردهای مبتنی بر محتوی، پالایش مشارکتی، هر دو روش تکی و ترکیبی هنوز مؤثر هستند.

با توجه به اینکه سیستم‌های توصیه‌گر پالایش مشارکتی مبتنی بر کاربر از اطلاعات امتیاز کاربران به آیتم‌ها استفاده می‌کند و بر خلاف روش‌های مشابه به اطلاعات دیگری نیاز ندارند، در این پژوهش، سیستم توصیه‌گر پالایش مشارکتی مبتنی بر کاربر در نظر گرفته شده است.

امروزه در حوزه‌های مختلف بهینه‌سازی، الگوریتم‌های فرالبتکاری^۳ به دلیل قدرتمندی در یافتن بهترین جواب و سادگی محاسباتی بهشدت مورد توجه قرار گرفته‌اند و در مطالعات مختلف الگوریتم‌های ترکیبی فراوانی بهمنظور تقویت نقاط قوت و پوشش نقاط ضعف الگوریتم‌های فرالبتکاری پایه ارائه شده است. از طرفی سیستم‌های توصیه‌گر^۴، به دلیل نقش بسزای آن‌ها در مدیریت ارتباط با مشتریان^۵، تجارت الکترونیک^۶، بازاریابی و مدیریت کلان داده^۷، به عنوان یک زمینه پژوهشی جدید در دنیا مطرح شده‌اند. علی‌رغم اهمیت سیستم‌های توصیه‌گر، طبق بررسی‌های صورت‌گرفته مشخص شد که در مطالعات انجام‌شده در زمینه بهبود سیستم‌های توصیه‌گر، روش‌های پیشنهادی پیچیدگی محاسباتی و هزینه محاسباتی بالایی دارند و الگوریتم‌های فرالبتکاری با وجود داشتن مزایای بسیار، در این زمینه چندان به کار گرفته نشده‌اند و در مطالعات محدود انجام‌شده بیشتر الگوریتم‌های فرالبتکاری پایه بهمنظور بهبود عملکرد سیستم توصیه‌گر بررسی شده‌اند که یا از نظر جست‌وجوی محلی یا جست‌وجوی سراسری یا هر دو ضعیف هستند و بهبودی در این الگوریتم‌ها ایجاد نشده است. مطالعاتی که الگوریتم‌های پایه را بهبود داده‌اند و یا الگوریتم‌های ترکیبی ارائه داده‌اند، هنوز هم مشکلاتی در زمینه هوشمندی‌بودن، تنظیم پارامترها، تعادل بین جست‌وجوی محلی و جست‌وجوی سراسری دارند؛ بنابراین با توجه به اینکه مسئله طراحی سیستم توصیه‌گر یک مسئله پیچیده با بهینه‌های محلی زیاد است، برای حل این مسئله نیاز به الگوریتم‌های ترکیبی بهینه‌سازی فرالبتکاری و هوشمند

1. Knowledge-based RS
 2. Hybrid Recommender Systems (HRS)
 3. Metaheuristic Algorithms
 4. Recommender Systems
 5. CRM(Customer Relationship Management)
 6. E-Commerce
 7. Big Data

قدرتمند بهشدت احساس می‌شود؛ ازین‌رو در این پژوهش، الگوریتمی از ترکیب الگوریتم گرگ خاکستری و الگوریتم شیر (هر دو جستجوی محلی قوی دارند) ارائه شده است و از منطق فازی بهمنظور هوشمند کردن الگوریتم پیشنهادی و تنظیم پارامترهای آن برای تقویت جستجوی سراسری و محلی استفاده شده است تا بتوان عملکرد سیستم توصیه‌گر را از طریق بهبود در پارامترهای دقت^۱، فراخوانی^۲ و معیار^۳ F^۴ ارتقا داد.

۲. مبانی نظری و پیشینه پژوهش

الگوریتم‌های فرآبتكاری، روش‌هایی تصادفی و مبتنی بر جمعیت هستند که در پژوهش‌های زیادی شامل بهینه‌سازی مسئله خط مونتاژ جریان کارگاهی توسط غلامی و همکاران (۱۳۹۷)، بهینه‌سازی مسئله زمان‌بندی جریان کارگاهی توسط فرجی و بهنامیان (۱۳۹۹) و حل مسئله مسیریابی وسایل نقلیه الکتریکی توسط اسلامی‌نیا و عظیمی (۱۳۹۸)، به کار برده شده‌اند [۱۵، ۱۳، ۱۸]. در این پژوهش از الگوریتم‌های بهینه‌سازی فرآبتكاری در حل مسئله سیستم توصیه‌گر استفاده شده است.

بر اساس پژوهش‌های دنگ و همکاران^۴ (۲۰۱۶)، دیکسیت و جین^۵ (۲۰۱۸) و یاداو و همکاران^۶ (۲۰۱۸)، بهینه‌سازی پارامترهای سیستم توصیه‌گر با استفاده از رویکردهای متاهیوریستی یا رویکردهای الهام‌گرفته از طبیعت، نقش اساسی در افزایش عملکرد هر مدل پیشنهادی دارد [۱۰، ۱۱، ۳۶]. رویکردهای الهام‌گرفته از زیست‌شناختی مشابه هر گونه زیست‌شناختی عمل می‌کنند. هوش کلی محاسباتی به بداهه‌سازی چندین حوزه مانند سیستم فیلترینگ مشارکتی مبتنی بر فیلم، توصیه اسناد و غیره کمک می‌کند. کاتاریا و ورما^۷ (۲۰۱۸)، یک سیستم توصیف مشارکتی مبتنی بر فیلم جدید ارائه کرده‌اند که از الگوریتم بهینه‌ساز گرگ خاکستری و تکنیک خوش‌بندی^۸–میانگین فازی^۹ استفاده کرده و رتبه‌بندی فیلم را برای یک کاربر خاص بر اساس داده‌های تاریخی خود پیش‌بینی می‌کند [۲۰]. در پژوهش وانگ و همکاران^۹ (۲۰۱۹)، با عنوان «طرحی برای توصیه اجتماعی با استفاده از الگوریتم بهینه‌سازی شیر و تکنیک‌های فیلترینگ مبتنی بر مشارکت»، برای توصیه برچسب اجتماعی، چارچوبی ارائه شده است که ترکیبی از تکنیک‌های داده‌کاوی مانند انتخاب ویژگی و

1. Precision

2. Recall

3. F-Measure

4. Deng, et al.

5. Dixit & Jain

6. Yadav, et al.

7. Katarya & Verma

8. fuzzy c-mean (FCM) clustering technique

9. Wang, et al.

خوشبندی با الگوریتم‌های پالایش مشارکتی است. در این پژوهش از روش بهینه‌سازی شیر برای انتخاب ویژگی و خوشبندی استفاده شده است [۳۵].

سینه‌ها و دانکالاکشمی^۱ (۲۰۱۹)، تجزیه و تحلیل مقایسه‌ای تعدادی از تکنیک‌های بهینه‌سازی که برای پیاده‌سازی سیستم توصیه کننده در حال اجرا هستند را مطابق جدول ۱، انجام دادند [۳۱].

جدول ۱. تجزیه و تحلیل مقایسه‌ای تعدادی از تکنیک‌های بهینه‌سازی در سیستم توصیه‌گر [۳۱]

منبع	موضوع	تکنیک بهینه‌سازی
[۳۶]	این رویکرد فراتکاری برای محاسبه وزن‌های مورداستفاده برای یافتن همسایه‌های بهتر استفاده می‌شود.	الگوریتم خفash ^۲
[۱۹]	این رویکرد برای بهینه‌سازی نتایج بدست‌آمده از الگوریتم K-means استفاده می‌شود.	الگوریتم فاخته ^۳
[۲۰]	در این رویکرد از بهینه‌سازی گرگ خاکستری برای تصمیم‌گیری در مورد موقعیت‌های خوش‌ها و نقاط خوشبندی اولیه استفاده شده است.	بهینه‌ساز گرگ خاکستری ^۴
[۳۳]	این رویکرد نتایج بدست‌آمده از الگوریتم K-means را بهینه می‌کند.	کلونی زنبور عسل ^۵
[۹]	از این رویکرد برای بدست آوردن وزن ویژگی برای کاربر فعال استفاده می‌شود و از این‌رو در تصمیم‌گیری در مورد کاربر کمک می‌کند.	بهینه‌سازی ازدحام ذرات ^۶
[۲۷]	این رویکرد تنظیمات مربوط به وزن ویژگی‌ها را تنظیم می‌کند.	الگوریتم جستجوی گرانشی ^۷
[۷]	این الگوریتم در تصمیم‌گیری در مورد اولویت بهینه ویژگی‌های هر محصول کاربر برای مجموعه‌های مختلف کاربران کمک می‌کند.	الگوریتم علف هرز مهاجم ^۸
[۳۰]	این سیستم با استفاده از الگوریتم ژنتیک یک سیستم پیشنهادی جدید را ارائه می‌دهد که در کنار استفاده از هر یک از معیارهای شباهت پرکاربرد، مانند پیرسون و شباهت کسینوسی، نتیجه رضایت‌بخش‌تری ارائه می‌کند.	الگوریتم ژنتیک ^۹

1. Sinha & Dhanalakshmi
2. Bat Algorithm
3. Cuckoo Search
4. Grey Wolf optimizer
5. Artificial Bee colony (ABC)
6. Particle Swarm optimization (PSO)
7. Gravitational Search Algorithm (GSA)
8. Invasive weed optimization (IWO) algorithm
9. Genetic Algorithm (GA)

۳. روش‌شناسی پژوهش

هدف اصلی در این پژوهش، بهبود نتایج الگوریتم پالایش مشارکتی با پیشنهاد یک تابع شباهت بهینه است که دقت سیستم توصیه‌گر مبتنی بر پالایش مشارکتی را افزایش دهد. در روش پیشنهادی برای یافتن شبیه‌ترین کاربران به کاربر هدف از ترکیب دو الگوریتم گرگ خاکستری فازی و الگوریتم شیر، استفاده شده است [۳۵، ۲۶].

روش ارائه شده در پژوهش حاضر این مزیت را دارد که به اطلاعات اضافی ارائه شده توسط مدل کاربر نیاز ندارد و به همین دلیل، آن را می‌توان در همه سیستم‌های توصیه‌گر به سادگی روی تکنیک‌های پالایش مشارکتی، مورداستفاده قرار داد. علت این واقعیت این است که روش ما تنها از رتبه‌دهی کاربران استفاده می‌کند که حداقل اطلاعات ممکن در هر سیستم توصیه‌گر است. سیستم پیشنهادی از دو فاز آموزش و آزمایش تشکیل شده است. درواقع بخشی از مجموعه داده شامل کاربران آموزشی و آیتم‌های آموزشی به منظور به دست آوردن یکتا شباهت بهینه در فاز آموزش استفاده می‌شود. پس از به دست آوردن این تابع شباهت، آزمایش‌ها برای ارزیابی عملکرد شباهت به دست آمده با استفاده از کاربران آزمایشی و آیتم‌های آزمایشی، یعنی کاربران و آیتم‌هایی که در فاز آموزش استفاده نشده‌اند، انجام می‌شود.

الگوریتم نزدیک‌ترین همسایه‌ها^۱. یکی از متداول‌ترین الگوریتم‌های مورداستفاده در سیستم‌های توصیه‌گر پالایش مشارکتی، «الگوریتم k نزدیک‌ترین همسایه‌ها» است. در یک شبکه اجتماعی می‌توان یک همسایگی از کاربر موردنظر را با علائق مشابه با آن کاربر تعیین کرد؛ به این ترتیب که همسایه‌ها را بر حسب شباهت آن‌ها با کاربر موردنظر مرتب کرده و k همسایه بالاتر انتخاب می‌شود. در این پژوهش الگوریتم نزدیک‌ترین همسایه مبتنی بر کاربر موردنظر قرار می‌گیرد [۵].

الگوریتم نزدیک‌ترین همسایه‌ها بر کاربر. نخستین بار در پژوهه گروپ‌لنژ^۲ در سال ۱۹۹۴، اساس الگوریتم پالایش مشارکتی مبتنی بر کاربر پیشنهاد شد. این الگوریتم پالایش مشارکتی، «مبتنی بر کاربر» نامیده می‌شود به این دلیل که هسته اصلی محاسبات این رویکرد، «محاسبه شباهت بین زوج کاربران» است [۱۷]. شباهت بین دو کاربر با استفاده از یک معیار شباهت محاسبه می‌شود. انتخاب صحیح معیار شباهت، یک فاکتور حیاتی در پالایش مشارکتی است، زیرا دقت توصیه را به شدت تحت تاثیر قرار می‌دهد. مسئله‌ای انتخاب همسایه نیز یکی از فاکتورهای کلیدی و مهم در پالایش مشارکتی است. هرلوکر و همکاران^۳ (۲۰۰۲)، تأثیر انتخاب همسایه در دقت توصیه را بررسی نمودند [۱۷]. سپس این کاربران به عنوان

1. K-Nearest Neighbors(KNN)

2. Group Lens

3. Herlocker, et al.

"کاربران همکار" یا "نزدیک‌ترین همسایه‌ها" شناخته می‌شوند، در نهایت برای هر محصول ۱ که کاربر هدف هنوز ندیده (رتبه‌بندی نکرده)، یک پیش‌بینی براساس رتبه‌بندی‌های کاربران همسایه روی آیتم ۱، محاسبه می‌شود.

نخستین گام توصیه، تعیین تابع شباهت بهینه پیشنهادی است. محاسبه شباهت میان هر دو کاربر a, u در دیتابست به صورت رابطه (۱) تعریف شده است، این فرمول بندی همان میانگین وزن‌دار شده است که با استناد به بوبادیلا و همکاران^۱ (۲۰۱۱) و حاتمی و پاشازاده^۲ (۲۰۱۴) استخراج شده است [۵]:

$$\text{sim}_w(a, u) = \frac{1}{M - m + 1} \sum_{i=0}^{M-m} W^{(i)} V_{a,u}^{(i)} \quad \text{رابطه (۱)}$$

در رابطه ۱، M بالاترین رتبه و m پایین‌ترین رتبه تعریف شده در سیستم است که کاربر می‌تواند به هر یک از آیتم‌ها بدهد، $V_{a,u}$ بردار مقادیر برای هر زوج کاربر a, u و W بردار وزن و هم اندازه با بردار V است که در ادامه روش محاسبه هر دو بردار تشریح خواهد شد.

گام دوم یافتن نزدیک‌ترین همسایه می‌باشد که تعیین می‌شود که در محاسبه پیش‌بینی رتبه‌بندی برای کاربر فعال، کدام کاربران شرکت کنند. معمولاً دو پارامتر برای یافتن نزدیک‌ترین همسایه در روش‌های توصیه گر پالایش مشارکتی مبتنی بر کاربر وجود دارد: k و ϵ آستانه‌ی تنظیم. یک حد آستانه به عنوان حداقل وزن همبستگی تنظیم می‌شود تا مشخص شود که آیا یک همسایه از میان همسایه‌ها، در مجموعه‌ی $S(a)$ قرار می‌گیرد یا خیر). به زبان ریاضی داریم:

$$S(a) = \{u | \text{sim}(a, u) \geq \epsilon, \text{rank}(\text{sim}(a, u)) \leq k\} \quad \text{رابطه (۲)}$$

در اینجا با توجه به شباهت بدست آمده k نزدیک‌ترین همسایه به کاربر انتخاب می‌شود. $S(a)$ شامل K شبیه‌ترین کاربران (شبیه‌ترین همسایه) به کاربر فعال a است.

1. Bobadilla, et al.
2. Hatami & Pashazadeh

در گام پیش‌بینی رتبه‌ها، رتبه‌بندی‌های همسایه‌های کاربر از طریق فرمول (۳) به پیش‌بینی رتبه‌بندی برای کاربر هدف تبدیل می‌شوند.

$$P_a^i = \bar{r}_a + \frac{\sum_{u \in U_i \cap S(a)} sim(a, u) \cdot (r_{u,i} - \bar{r}_u)}{\sum_{u \in U_i \cap S(a)} |sim(a, u)|} \quad (3)$$

در صورتی که $U_i \cap S(a) = \emptyset$ باشد، پیش‌بینی رتبه‌بندی P_a^i برای کاربر هدف a روی آیتم i را نمی‌توان محاسبه کرد. سیستم توصیه‌گر آیتم‌هایی با بالاترین پیش‌بینی رتبه‌بندی (P_a^i) را به کاربر هدف a پیشنهاد می‌دهد [۵].

برای محاسبه پیش‌بینی رتبه‌بندی، تمام همسایه‌ها در نظر گرفته ن و فقط آن‌هایی انتخاب می‌شوند که ضریب مشتبی با کاربر فعال داشته و آیتم موردنظر را رتبه‌بندی کرده باشند. اگر از تمامی همسایه‌ها برای محاسبه پیش‌بینی رتبه‌بندی استفاده شود، با توجه به زمان محاسبه موردنیاز، نه تنها اثر منفی بر عملکرد دارد، بلکه کاهش دقت توصیه را نیز در پی خواهد داشت [۵].

پیش‌فرضهای سیستم. یک پایگاه داده با یک مجموعه از کاربران $\{U_1, \dots, U_m\}$ و یک مجموعه از آیتم‌ها $\{I_1, \dots, I_n\}$ را در نظر خواهیم گرفت. کاربران، آیتم‌ها را با مقادیری در یک محدوده گسترش می‌کنند که معمولاً نشان‌دهنده نارضایتی کامل کاربر در مورد آیتم i معمولاً نشانه رضایت کامل کاربر از یک آیتم است، رتبه‌دهی کرده‌اند. پایگاه‌های داده معمولاً m را با مقدار ۱ و M را با مقدار ۵ یا ۱۰ استفاده می‌کنند؛ بنابراین محدوده رتبه‌های ممکن $\{1, \dots, 5\}$ یا $\{1, \dots, 10\}$ است. رتبه‌دهی ایجادشده توسط یک کاربر u به‌وسیله بردار $r_u = (r_u^{(1)}, r_u^{(2)}, \dots, r_u^{(n)})$ با اندازه I (تعداد آیتم‌ها در مجموعه داده) رایه می‌شود؛ به‌طوری‌که $r_u^{(i)}$ نشان‌دهنده رتبه‌ای است که کاربر u برای آیتم i ایجاد کرده است. بدیهی است که یک کاربر ممکن است همه آیتم‌ها را رتبه‌بندی نکند. عبارت $r_u^{(i)} = 0$ برای حالتی که کاربر u هنوز آیتم i را رتبه نداده است، استفاده می‌شود [۵].

محاسبه بردارهای مقادیر (V). به منظور مقایسه دو بردار r_a و r_u که در واقع رتبه‌های داده شده به آیتم‌ها توسط دو کاربر a و u هستند، بردار $V_{a,u}$ به صورت $V_{a,u} = (v_{a,u}^{(0)}, \dots, v_{a,u}^{(M-m)})$ تعریف می‌شود که تعداد عناصر آن برابر تعداد رتبه‌های امکان‌پذیری است که یک کاربر می‌تواند روی یک آیتم ایجاد کند. هر عنصر $V_{a,u}^{(i)}$ از بردار $V_{a,u}$ به صورت کسر $\frac{A}{B}$ تعریف می‌شود که در آن B نمایانگر تعداد آیتم‌های رتبه‌بندی شده توسط هر دو کاربر (یعنی $0 < r_a^{(i)} < 1$ و $0 < r_u^{(i)} < 1$) است.

A نشان‌دهنده تعداد آیتم‌های رتبه‌بندی‌شده توسط هر دو کاربر است؛ با این شرط که تفاصل مطلق رتبه‌بندی‌های کاربر a و کاربر u برابر i باشد $\left(\left| r_a^i - r_u^i \right| = i \right)$.^[۵] اجرای یک مثال. فرض می‌شود که $M=5$ و $m=1$ (مجموعه امکان‌پذیر رتبه‌ها $\{1, \dots, 5\}$) است، ۹ آیتم موجود است $i=9$ و دو کاربر وجود دارند که رتبه‌بندی‌هایشان به‌وسیله بردارهای r_1 و r_2 زیر نشان داده شده است:

$$\begin{aligned} r_1 &= (4, 5, 0, 3, 2, 0, 1, 1, 4) \\ r_2 &= (4, 3, 1, 2, 0, 3, 4, 0, 2) \end{aligned} \quad \text{رابطه (۴)}$$

بر اساس تعریف بالا بردار $V_{1,2}$ به صورت زیر خواهد بود:

$$V_{1,2} = \left(\frac{1}{5}, \frac{1}{5}, \frac{2}{5}, \frac{1}{5}, 0 \right) \quad \text{رابطه (۵)}$$

همه عناصر بردار $V_{1,2}$ بر ۵ تقسیم شده‌اند؛ چراکه ۵ آیتم رتبه‌بندی‌شده توسط دو کاربر وجود دارد. در عنصر $V_{1,2}^{(0)}$ ، صورت تعداد آیتم‌هایی که رتبه دو کاربر به آن‌ها یکسان بوده (اختلاف مطلق آن‌ها صفر است) و مخرج تعداد کل آیتم‌های رتبه‌بندی‌شده توسط هر دو کاربر، را نشان می‌دهد. در مثال $v_{1,2}^{(0)} = \frac{1}{5}$ به این دلیل که فقط یکی از آیتم‌ها (آیتم اول) با رتبه مشابه ۴ توسط دو کاربر رتبه‌دهی شده است $\left(\left| r_1^{(1)} - r_2^{(1)} \right| = 0 \right)$. به همین ترتیب در $v_{1,2}^{(M-m)}$ صورت تعداد آیتم‌هایی که دو کاربر کاملاً متفاوت رتبه‌دهی کرداند و مخرج تعداد کل آیتم‌های رتبه‌بندی شده توسط هر دو کاربر را نشان می‌دهد. در مثال $v_{1,2}^{(4)} = v_{1,2}^{(0)} = \frac{0}{5} = 0$ چراکه هیچ دو آیتم رتبه‌بندی‌شده‌ای با مقادیر ۱ و ۵ توسط کاربران ۱ و ۲ وجود ندارند. در مثال $v_{1,2}^{(2)} = \frac{2}{5}$ به این دلیل که دقیقاً دو آیتم (آیتم ۲ و آیتم ۹) وجود دارند که $\left| r_1^{(2)} - r_2^{(2)} \right| = 2$.^[۵]

طبق قاع شباخت به‌ازای هر بردار V با همان اندازه باید تعریف شود که هر عنصر $V^{(i)}$ نشان‌دهنده اهمیت عنصر $V_{a,u}^{(i)}$ در محاسبه شباخت بین دو کاربر است. ویژگی هر عنصر بردار $(W = (W^{(0)}, \dots, W^{(M-m)})$ که عناصر آن در بازه $[1, -1]$ قرار دارند را می‌توان با درنظرگرفتن یک بردار نمونه $(1, 0.5, 0, -0.5, -1) = W$ به صورت زیر تشریح کرد: $=1$ آیتم‌هایی که مشابه هم رتبه‌دهی شدند را در محاسبه شباخت بسیار مثبت ارزیابی می‌کند.

$W^{(1)} = 0.5$ آیتم‌هایی را که اختلاف بین رتبه‌های آن‌ها ۱ است را با یک مقدار متوسط مثبت ارزیابی می‌کند.

$W^{(2)} = 0$, آیتم‌هایی را که اختلاف رتبه‌دهی دو کاربر به آن‌ها ۲ است را در محاسبه شباخت در نظر نمی‌گیرد.

$W^{(3)} = -0.5$, آیتم‌هایی را که اختلاف رتبه آن‌ها ۳ است را با یک مقدار متوسط منفی ارزیابی می‌کند.

$W^{(4)} = -1$, آیتم‌هایی که متصاد هم رتبه‌دهی شدند را در محاسبه شباخت بسیار منفی ارزیابی می‌کند.

به این ترتیب می‌توان به طور منطقی انتظار داشت کهتابع شباخت بهینه یک مقدار مثبت بالای $W^{(0)}$ و یک مقدار منفی بالاتر از $W^{(M-m)}$ داشته باشد [۵].

هدف از این پژوهش، بهبود در سیستم‌های توصیه‌گر مبتنی بر پالایش مشارکتی مبتنی بر کاربر است. مهم‌ترین چالش در این زمینه یافتن سیستم توصیه‌گر با پارامترهای عملکردی بالا در مقایسه با پژوهش‌های پیشین است. از آنجاکه این مسئله به تابع شباخت و وزن‌های آن وابسته است، هدف طراحی سیستم توصیه‌گری است که از نظر عملکرد در مقایسه با سایر پژوهش‌های مشابه عملکرد بهتری داشته باشد؛ بنابراین به یک الگوریتم بهینه‌سازی فرآیندکاری بهاندازه کافی قدرتمند برای حل این مسئله نیاز است؛ از این‌رو در این پژوهش، یک الگوریتم بهینه‌سازی فرآیندکاری بهبودیافته از ترکیب الگوریتم بهینه‌سازی گرگ خاکستری با الگوریتم شیر برای حل این مسئله پیشنهاد می‌شود. از الگوریتم گرگ خاکستری در این پژوهش استفاده شده است؛ زیرا هم پارامتر قابل تنظیم کمی دارد و ارائه‌هندگان آن نشان دادند که در مقایسه با روش‌های فرا-اکتشافی مشابه عملکرد بهتری از خود نشان داده است [۲۶]؛ اما برای بهبود این الگوریتم ابتدا از قوانین فازی استفاده می‌شود که مهم‌ترین پارامتر آن a که وظیفه تعادل بین جستجوی سراسری و محلی را برعهده دارد به کمک قواعد فازی تنظیم می‌شود؛ همچنین پارامتر C این الگوریتم نیز به عنوان خروجی دیگر سیستم فازی تنظیم شده است که به بهبود در جستجوی سراسری و محلی الگوریتم کمک می‌کند. برای بهبود در جستجوی محلی از معادله مربوط به شکار در شیر بهره گرفته شده است. علت استفاده از الگوریتم شیر کمک به تنوع در حالت شکار گرگ‌ها با ایده‌گرفتن از الگوریتم شیر است. استفاده از هر دو ایده شکار گرگ و شیر منجر می‌شود که کیفیت جواب‌های یافته شده توسط الگوریتم گرگ و شیر پیشنهادی در مقایسه با گرگ معمولی بهبود یابد.

الگوریتم‌های فرااکتشافی^۱. تکنیک‌های بهینه‌سازی مبتنی بر فرااکتشافی، مثل الگوریتم ژنتیک، بهینه‌سازی توده ذرات^۲، بهینه‌سازی کلونی مورچگان^۳ در دو دهه گذشته خیلی معروف

1. Metaheuristic Algorithms

2. Particle Swarm Optimization(PSO)

3. Ant Colony Optimization (ACO)

شده‌اند [۱۲، ۲۲]. این تکنیک‌های بهینه‌سازی در نواحی گوناگون کاربردی استفاده شده‌اند. جواب اینکه چرا این‌ها اینقدر مشهور شده‌اند را می‌توان به چهار علت جمع‌بندی کرد: سادگی، انعطاف‌پذیری، مکانیسم مشتق آزاد و اینکه آن‌ها توانایی بیشتری در مقایسه با روش‌های سنتی برای اجتناب از بهینه محلی دارند.

در ادامه الگوریتم گرگ خاکستری بیان می‌شود؛ سپس نوع فازی شده آن توضیح داده می‌شود. در انتهای این بخش از معادلات مربوط به الگوریتم بهینه‌سازی شیر الگوریتم گرگ خاکستری بهبود داده خواهد شد.

الگوریتم بهینه‌سازی گرگ خاکستری. الگوریتم بهینه‌سازی گرگ خاکستری^۱ یک روش فرا-اکتشافی است که توسط میرجلیلی در سال ۲۰۱۴ ارائه شد؛ زیرا در پژوهش‌ها، هوش جمعی مبتنی بر ویژگی‌های گرگ خاکستری وجود نداشته است [۳، ۲۶]. تکنیک‌های فرااکتشافی را امروزه می‌توان به چند دسته زیر دسته‌بندی کرد:

- تکاملی (مبتنی بر مفاهیم تکامل در طبیعت) [۲۵]: الگوریتم ژنتیک، برنامه‌ریزی تکاملی^۲ و برنامه‌ریزی ژنتیک^۳

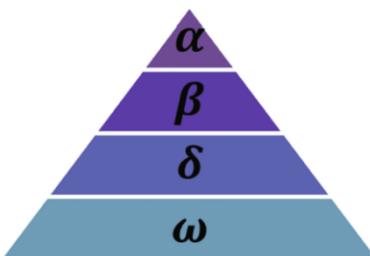
- بر اساس فیزیک (برگرفته شده از قوانین فیزیکی) [۷]: الگوریتم بهینه‌سازی فروپاشی بزرگ بیگ - بنگ^۴، الگوریتم جست‌وجوی گرانشی^۵ و الگوریتم بهینه‌سازی واکنش‌گر شیمیایی مصنوعی^۶

- هوش جمعی (رفتار اجتماعی توده‌ها، گروه‌ها، دسته‌ها یا دسته جانداران در طبیعت) [۳۷]: بهینه‌سازی توده ذرات، بهینه‌سازی کلونی مورچگان، الگوریتم خفash.

رودریگز و همکاران^۷ (۲۰۱۶)، یک الگوریتم گرگ خاکستری فازی پیشنهاد کردند. مشکل پژوهش آن‌ها این بود که فقط از یک پارامتر به نام «پارامتر a » برای فازی کردن استفاده کردند؛ اما در این تحقیق علاوه بر a ، پارامتر c نیز با استفاده از منطق فازی تنظیم خواهد شد. مفاهیم مربوط به الگوریتم گرگ خاکستری پایه و نوع فازی بهبود داده شده در این پژوهش در ادامه توضیح داده خواهد شد.

سلسله‌مراتب رهبران و مکانیسم شکار گرگ خاکستری در شکل ۱، به صورت هرم نشان داده شده است.

-
1. Grey Wolf Optimizer(GWO)
 2. Evolutionary Programming (EP)
 - 3 . Genetic Programming (GP)
 - 4 . The Big Bang–Big Crunch (BB–BC) optimization algorithm
 - 5 . Gravitational Search Algorithm (GSA)
 6. Artificial Chemical Reaction Optimization Algorithm(ACROA)
 7. Rodríguez, et al.



شکل ۱. هرم سلسله‌مراتب گرگ خاکستری [۲۹]

سلسله‌مراتب اجتماعی گرگ خاکستری در گروه شکارچی‌ها دارای رفتار اجتماعی جالبی است: ۱. تعقیب کردن، دنبال کردن و نزدیک شدن به شکار؛ ۲. تعقیب کردن، احاطه کردن و حملات پی‌درپی به شکار تا وقتی که شکار متوقف شود؛ ۳. حمله به سمت شکار [۲۹].

سلسله‌مراتب اجتماعی. بهمنظور مدل‌سازی ریاضی سلسله‌مراتب اجتماعی گرگ‌ها وقتی که الگوریتم بهینه ساز گرگ خاکستری^۱ طراحی می‌شود، برآزنده‌ترین جواب به عنوان گرگ آلفا (α) در نظر خواهد شد؛ سپس جواب‌های دوم و سوم به ترتیب به نام بتا (β) و دلتا (δ) در نظر گرفته می‌شود. مابقی جواب‌های کاندید به صورت گرگ امگا (ω) در نظر گرفته می‌شود. در الگوریتم بهینه ساز گرگ خاکستری، شکار (بهینه‌سازی) به وسیله گرگ‌های α ، β و δ انجام می‌شود. گرگ‌های امگا این گرگ‌ها را دنبال می‌کنند [۲۹].

احاطه کردن شکار. همان‌طور که ذکر شد، گرگ‌های خاکستری شکار را احاطه می‌کنند. بهمنظور مدل‌سازی ریاضی رفتار احاطه کردن شکار معادلات زیر پیشنهاد شده است:

$$D = |CX_p(t) - X(t)| \quad (6)$$

$$X(t+1) = X_p(t) - AD \quad (7)$$

در روابط ۶ و ۷، t نشان‌دهنده تکرار فعلی است. A و C ضرایب، X_p بردار موقعیت شکار و X نشان‌دهنده بردار موقعیت یک گرگ خاکستری است. ضرایب A و C به صورت زیر محاسبه می‌شوند:

$$A = 2a(t)r_1 - a(t) \quad (8)$$

$$C = 2r_2 \quad (9)$$

1. Grey Wolf Optimizer (GWO)

ضریب a در هر تکرار به طور خطی از ۲ به سمت صفر کاهش می‌یابد و t_1 و t_2 اعداد تصادفی در محدوده $[0, 1]$ هستند. [۲۹].

شکار. گرگ‌های خاکستری دارای توانایی تشخیص موقعیت شکار و احاطه کردن آن هستند. شکار معمولاً به وسیله گرگ آلفا هدایت می‌شود. به منظور شبیه‌سازی ریاضی رفتار شکار گرگ‌های خاکستری، فرض می‌شود که آلفا (بهترین جواب کاندید)، بتا و دلتا دانش بهتری درباره موقعیت بالقوه شکار دارند؛ بنابراین بهترین سه جواب به دست آمده ذخیره شده و دیگر عوامل جست‌وجو (شامل گرگ‌های امگا) مجبور می‌شوند که موقعیت خود را بر اساس بهترین عوامل جست‌وجو تنظیم کنند. معادلات زیر در این زمینه پیشنهاد شده‌اند:

$$D_\alpha = |C_1 X_\alpha(t) - X(t)|, X_1 = X_\alpha - A_1 D_\alpha \quad \text{رابطه (۱۰)}$$

$$D_\beta = |C_2 X_\beta(t) - X(t)|, X_2 = X_\beta - A_2 D_\beta \quad \text{رابطه (۱۱)}$$

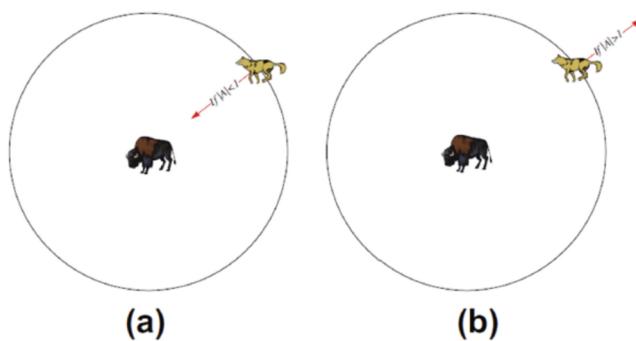
$$D_\delta = |C_3 X_\delta(t) - X(t)|, X_3 = X_\delta - A_3 D_\delta \quad \text{رابطه (۱۲)}$$

$$X_{(t+1)} = \frac{X_1 + X_2 + X_3}{3} \quad \text{رابطه (۱۳)}$$

معادله ۱۳، نشان‌دهنده بروزرسانی موقعیت‌ها مبتنی بر بهترین سه گرگ است که X_1 ، X_2 و X_3 نشان‌دهنده گرگ‌های آلفا، بتا و دلتا هستند و $X(t+1)$ نشان‌دهنده یک گرگ امگا است که باید به سمت جایی که رهبران دسته (مرکز) نشان داده شده‌اند، حرکت کند [۲۹].

حمله و جست‌وجوی شکار. بر اساس روابط ۱۰ تا ۱۲ مشخص می‌شود که پارامتر A نقش مهمی در مدیریت اکتشاف^۱ و استخراج^۲ در فضای جستجو دارد.

1.Exploration
2.Exploitation



شکل ۲. حمله به شکار در مقابل جست‌وجوی شکار [۲۶]

اگر مقادیر تصادفی A در $[1, -1]$ باشد، شکل ۲ نشان می‌دهد که:

(a) اگر $|A| < 1$ آنگاه به شکار حمله شود (استخراج).

(b) اگر $|A| > 1$ آنگاه جست‌وجو برای شکار انجام شود (اکتشاف).

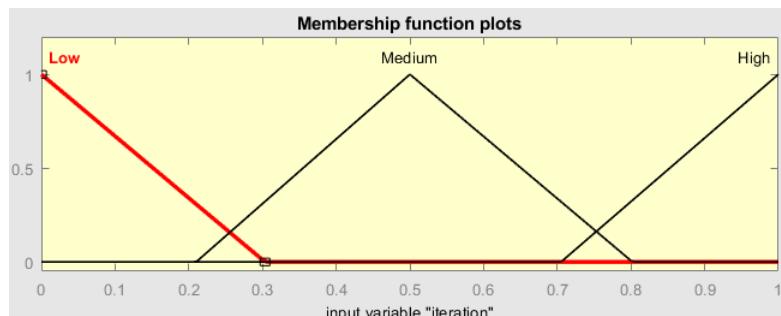
به علاوه ضریب C همچنین اکتشاف در الگوریتم را نشان می‌دهد؛ زیرا یک حرکت تصادفی از یک گرگ خاکستری در جست‌وجو برای شکار نشان داده است و اگر موقعیت بعدی نزدیک به شکار باشد، به طور غیرمستقیم استخراج انجام می‌دهد [۲۶].

الگوریتم بهینه‌سازی گرگ خاکستری فازی ترکیب شده با الگوریتم بهینه‌سازی شیر. در این بخش ابتدا نحوه فازی کردن الگوریتم گرگ خاکستری و سپس بهبود آن به کمک الگوریتم بهینه‌سازی شیر بیان خواهد شد.

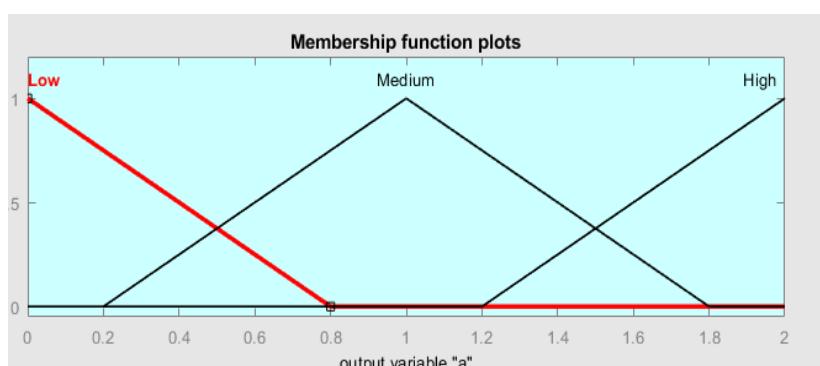
طراحی سیستم استنتاج فازی برای بهبود الگوریتم گرگ خاکستری. ازانجاکه تنظیم پارامترهای الگوریتم‌های بهینه‌سازی در شرایط مختلف مشکل است، در اینجا از قوانین فازی استفاده می‌شود. در واقع استفاده از منطق فازی بهدلیل رفع حساسیت نسبت به پارامترهای الگوریتم است؛ به این صورت که پارامترهای اصلی گرگ خاکستری که شامل a و C است، به کمک قوانین فازی تنظیم می‌شوند؛ به طوری این پارامترها خود را بر طبق شرایط مسئله تعییر می‌دهند؛ بنابراین مشکل تنظیم پارامترهای الگوریتم اصلی نیز رفع می‌شود. درنهایت با توجه به اینکه پارامترهای a و C به طور هوشمندانه تعیین می‌شوند، بر عملکرد جست‌وجوی محلی و سراسری الگوریتم تأثیر مثبت می‌گذارد.

سیستم منطق فازی بهمنظور بهبود الگوریتم گرگ خاکستری به این صورت طراحی می‌شود که ورودی این سیستم تکرارهای الگوریتم نرمال شده و خروجی‌های این سیستم پارامتر a و C

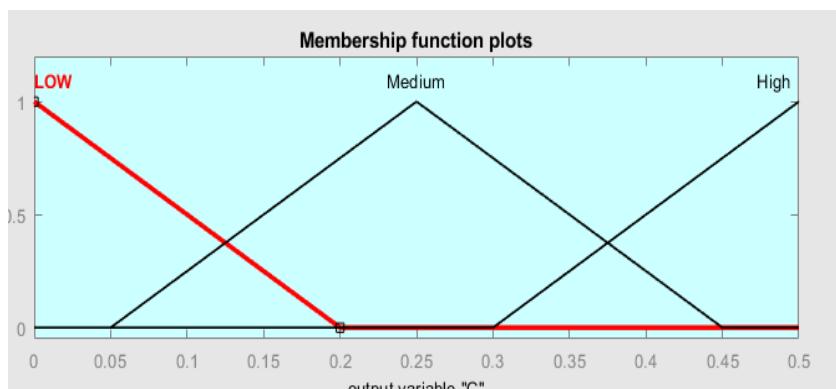
است. برای هر ورودی و هر خروجی سهتابع عضویت فازی (کم، متوسط و زیاد) نوع ممدادی تقسیم‌بندی می‌شوند که دارای نوع غیرفازی مرکز ثقل است و تمام توابع عضویت مثلثی هستند که توابع عضویت در شکل‌های ۳ تا ۵ قرار می‌گیرند.



شکل ۳. توابع عضویت فازی مربوط به ورودی تکرار



شکل ۴. توابع عضویت مربوط به خروجی a



شکل ۵. توابع عضویت مربوط به خروجی C

قواعد فازی پیشنهادی در جدول ۲، ارائه شده است.

جدول ۲. قواعد فازی برای تنظیم پارامترهای C و a

1- If (iteration is Low) then (a is High) and (C is High)
2- If (iteration is Medium) then (a is Medium) and (C is Medium)
3- If (iteration is High) then (a is Low) and (C is Low)

بهبود الگوریتم بهینه‌سازی گرگ خاکستری فازی با الگوریتم بهینه‌سازی شیر. برای بهبود الگوریتم گرگ خاکستری از معادلات مربوط به فرآیند شکار الگوریتم شیر استفاده می‌شود. به این صورت که بهای احتمال $5/0$ درصد بهروزرسانی موقعیت گرگ‌ها توسط معادله‌های ۱۰ تا ۱۲، انجام شده و در غیر این صورت معادله ۱۴، اجرا می‌شود [۳۸].

$$\begin{aligned} x_1 &= x_\alpha + (\text{rand})(PI)(x_\alpha - x_1); \\ x_2 &= x_\beta + (\text{rand})(PI)(x_\beta - x_2); \\ x_3 &= x_\delta + (\text{rand})(PI)(x_\delta - x_3); \end{aligned} \quad \text{رابطه (۱۴)}$$

در روابط بالا، PI نرخ بهبود برازنده‌گی است که به صورت معادله ۱۵ محاسبه می‌شود:

$$PI = \frac{f(x(t)) - f(x(t-1))}{f(x(t-1))} \quad \text{رابطه (۱۵)}$$

معادله اصلی بهروزرسانی الگوریتم گرگ خاکستری با احتمال بزرگ‌تر از $5/0$ اجرا می‌شود. در غیر این صورت اگر این احتمال بزرگ‌تر از $1/0$ باشد، یک حرکت به سمت بهترین گرگ با ضریب تصادفی rand با رابطه ۱۶ انجام می‌شود.

$$x = x + 3(\text{rand})a(x_\alpha - x) \quad \text{رابطه (۱۶)}$$

معادله ۱۶ از الگوریتم بهینه سازی توده ذرات الهام گرفته شده است که ضریب ۳ آن با توجه به چند آزمایش با توجه به نوع مسئله تعیین شده است. در غیر این صورت با احتمال وقوع $1/0$ جستجو پیرامون بهترین گرگ که گرگ آلفا است با ضریب تصادفی زیر انجام می‌شود:

$$x = x_\alpha + 0.0001a(\text{randn}) \quad \text{رابطه (۱۷)}$$

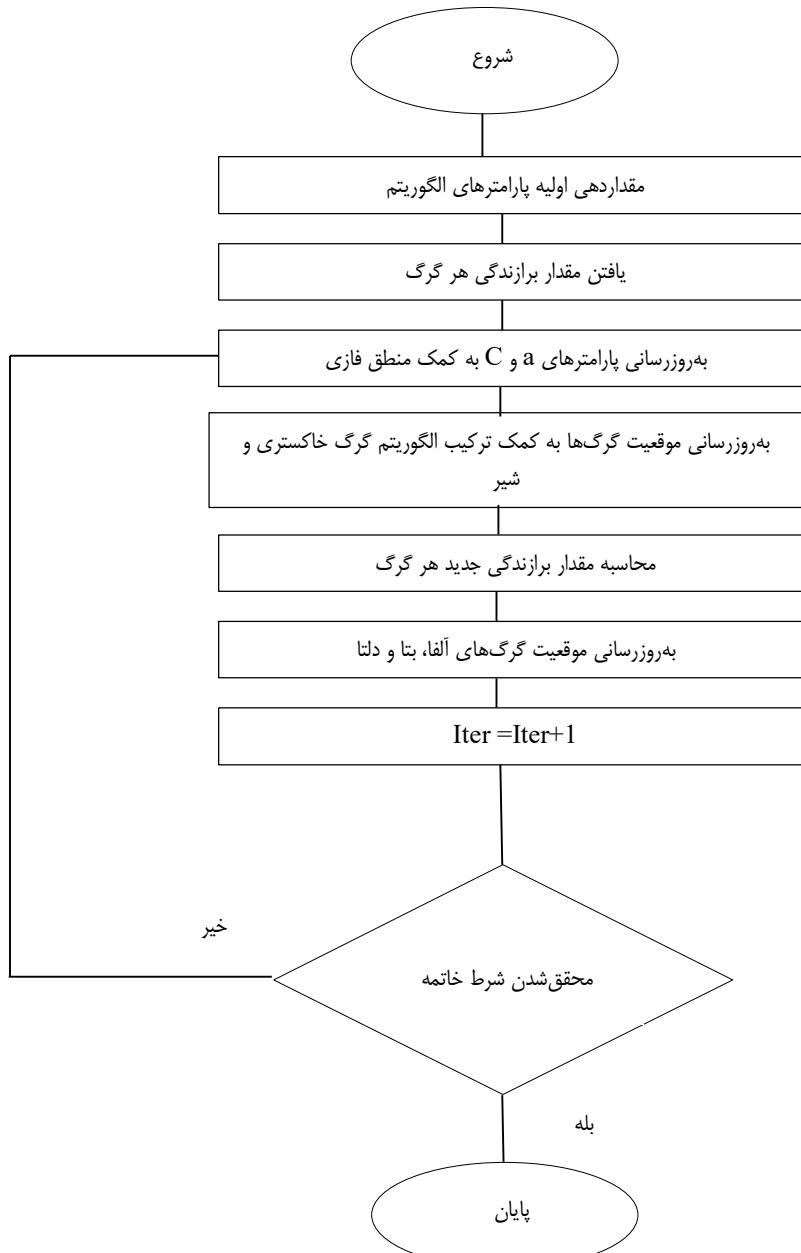
رابطه‌ی ۱۷، از الگوریتم علف هرز الهام گرفته شده؛ اما ضریب $1/0000$ از روی آزمایش با توجه به نوع مسئله که در اینجا سیستم توصیه‌گر است، تعیین شده است.

فلوچارت الگوریتم پیشنهادی در شکل ۶ نشان داده شده است.

حساسیت الگوریتم‌های بهینه‌سازی نسبت به پارامترهای خود اهمیت زیادی دارد. برای رفع مشکل حساس‌بودن الگوریتم نسبت به پارامترهای خود، در این پژوهش از منطق فازی استفاده شده است. به این صورت که این پارامترها به‌طور هوشمندانه به کمک منطق فازی تنظیم شده‌اند؛ بنابراین پارامترها با توجه به شرایط مسئله خود را تطبیق می‌دهند. الگوریتم گرگ خاکستری دو پارامتر a و C دارد که هر دوی این پارامترها به کمک منطق فازی تنظیم می‌شوند؛ بنابراین مشکل تنظیم پارامترهای آن به کمک منطق فازی حل می‌شود.

با توجه به بهبود الگوریتم گرگ خاکستری به کمک منطق فازی و الگوریتم شیر، انتظار می‌رود که این الگوریتم بر روی کاهش قدر مطلق خطای میانگین مربوط به سیستم توصیه‌گر، در مقایسه با الگوریتم‌های مشابه مانند بهینه‌سازی توده ذرات و گرگ خاکستری معمولی، عملکرد بهتری داشته باشد. یکتابع شباهت وزن دار در سیستم توصیه‌گر در نظر گرفته شد. وزن‌های این تابع بر عملکرد این سیستم توصیه‌گر اثر می‌گذارند. تنظیم این وزن‌ها مشکل است که این یک مسئله با چندین بهینه محلی است؛ از این‌رو باید از یک الگوریتم بهینه‌سازی قدرتمند استفاده شود؛ بنابراین در این پژوهش از الگوریتم گرگ خاکستری فازی بهبودیافته ترکیب شده با شیر استفاده شده است. برای ارزیابی این روش، شبیه‌سازی‌ها ابتدا بر روی توابع محک و سپس بهمنظور تنظیم سیستم توصیه‌گر بر روی پایگاه داده موقوی لنز¹ انجام می‌شود. توابع محک Ackley و Sphere، Griewank، Rosenbrock، Rastrigin و Ackley برای مقایسه انتخاب شده‌اند.

1. MovieLens



شکل ۶۰ فلوچارت الگوریتم گرگ خاکستری فازی ترکیب شده با الگوریتم شیر پیشنهادی

معرفی دیتاست مورداد استفاده: برای داده‌های آزمایش از مجموعه لنز که یک دیتاست پژوهشی بر مبنای وب است، استفاده می‌شود. این دیتاست شامل ۱۰۰۰۰۰ امتیاز است که توسط ۹۴۳ کاربر به ۱۶۸۲ فیلم داده شده است (ماتریس آیتم - کاربر A از ۹۴۳ سطر و ۱۶۸۲ ستون تشکیل می‌شود). این امتیازدھی با ساختار 5-Fold به دو قسمت تقسیم می‌شود: ۸۰ درصد داده‌ها (۸۰۰۰۰ امتیاز) برای مجموعه آموزش و ۲۰ درصد داده‌ها (۲۰۰۰۰) برای مجموعه تست استفاده شده است. در روش پیشنهادی از ویژگی‌های فیلم‌ها استفاده شده است (با Att نشان داده شده‌اند) که عبارت‌اند از: ناشناخته؛ ماجراجویی؛ اکشن؛ پویانمایی؛ کودکانه؛ طنز؛ جنایی؛ مستند؛ غمناک و ...

۴. تحلیل داده‌ها و یافته‌های پژوهش

مقایسه بین الگوریتم پیشنهادی با الگوریتم گرگ خاکستری و بهینه‌سازی توده ذرات با درنظر گرفتن تعداد تکرار و اندازه جمعیت بهتری برابر با ۳۰ و ۴۰ انجام شده است. هر الگوریتم ۳۰ بار اجرا شده است که نتایج در جدول ۳، آورده شده‌اند.

جدول ۳. مقایسه الگوریتم بهینه‌ساز گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر پیشنهادی با الگوریتم بهینه‌ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات

Ackley	Griewank	Rastrigin	Rosenbrock	Sphere	معیار ارزیابی	نام الگوریتم بهینه‌سازی
-۰/۱۴۹۹	-۰/۰۵۱۸	۳/۲۳۵۳	-۰/۰۵۵۵	۳/۳۱۹۷ e-۰۴	Mean	بهینه‌ساز گرگ
-۰/۲۲۶۳	-۰/۱۶۶۱	-۰/۰۲۱۰	-۰/۰۱۶۱	-۰/۰۰۱۲۷۹۴	Min	خاکستری
-۰/۰۸۶۹	-۰/۱۷۷۱	۱۳/۳۱۱۷	-۰/۱۲۱۴	-۰/۰۰۵۸۸۲	Max	
-۰/۰۵۸۷	-۰/۰۲۲۸	۳/۲۶۳۴	-۰/۶۷۱۰	۳/۳۱۹۷ e-۰۴	Mean	
-۰/۰۲۱	-۰/۰۱۰۱	-۰/۹۴۸۳	-۰/۰۲۱۰	-۰/۰۰۴۸۰۲۷	Min	بهینه‌سازی توده ذرات
-۰/۰۷۵۷	-۰/۰۳	۵/۴۴۰۱	۳/۲۳۵۲	۵/۸۸۲۰ e-۰۴	Max	
-۰/۰۴۲۱	-۰/۰۱۵۰	-۰/۱۳۷۲	۶/۸۰۶۳ e-۰۴	۵/۰۳۱۶ e-۰۶	Mean	الگوریتم بهینه‌ساز
-۰/۰۱۹۰	-۰/۰۲۵۱	۴/۰۷۳۷ e-۰۷	۲/۹۰۲۶ e-۰۵	۱/۴۸۹۱ e-۰۷	Min	گرگ خاکستری فازی
-۰/۰۷۲۷	-۰/۰۰۷۴	-۰/۶۶	-۰/۰۰۳۲	-۰/۰۰۵۸۸۲	Max	غنی‌شده با الگوریتم
						بهینه‌سازی شیر

1. Unknown
2. Adventure
3. Action
4. Animation
5. Children's
6. Comedy
7. Crime
8. Documentary
9. Drama

با توجه به جدول ۳، الگوریتم بهینه‌ساز گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر پیشنهادی از نظر معیارهای بدترین، بهترین و میانگین بهتر از الگوریتم‌های دیگر عمل کرده است. از نظر میانگین، بهترین مقدار به دست آمده بهوسیله الگوریتم پیشنهادی برای توابع محک Sphere مقدار $e^{-0.6}$ / ۰.۳۱۶ شده است؛ در حالی که الگوریتم بهینه ساز گرگ خاکستری برابر با $e^{-0.4}$ / ۰.۳۱۹۷ و الگوریتم بهینه‌سازی توده ذرات برابر با $e^{-0.27}$ / ۰.۴۰۲۷ شده است؛ اما برای تابع پیچیده‌تر Ackley بهترین مقدار میانگین به دست آمده از الگوریتم پیشنهادی برابر با $e^{-0.421}$ / ۰.۰۴۲۱ به دست آمده است؛ در حالی که این مقدار برای الگوریتم بهینه ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات به ترتیب برابر با $e^{-0.587}$ / ۰.۱۴۹۹ و $e^{-0.587}$ / ۰.۰۵۸۷ شده است. برای توابع دیگر نیز مشاهده می‌شود که الگوریتم پیشنهادی در کمینه‌سازی موفق‌تر از دو الگوریتم بهینه ساز گرگ خاکستری و بهینه‌سازی توده ذرات از نظر میانگین، بهترین و بدترین جواب به دست آمده عمل کرده است.

نتایج مقایسه‌ای میان معیارهای فراخوانی، دقت، و معیار F با $K=175$ در جدول ۴، نشان داده شده است.

جدول ۴. مقایسه معیارهای فراخوانی، دقت، و معیار F با $K=175$

معیار ^۳ F	فراخوانی ^۱	دقت ^۲	معیار F
۰/۱۶۸۷	۰/۹۷۶۱	۰/۱۰۱۷	بهینه ساز گرگ خاکستری
۰/۱۷۰۱	۰/۹۸۰۴	۰/۱۰۲۹	بهینه‌سازی توده ذرات
۰/۱۷۰۶	۰/۹۸۵۲	۰/۱۰۳۲	الگوریتم بهینه‌ساز گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر

هر چه معیارهای فراخوانی، دقت و معیار F بزرگ‌تر باشند، الگوریتم بهتر عمل کرده است. با توجه به جدول ۴، الگوریتم بهینه‌ساز گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر پیشنهادی توانسته است که مقدار فراخوانی برابر با 10.32 / ۰.۰ به دست آورد؛ در حالی که دو الگوریتم بهینه ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات به ترتیب مقادیری برابر با 10.17 / ۰.۰ و 10.29 / ۰.۰ به دست آوردند. از نظر معیار دقت مشاهده می‌شود که الگوریتم پیشنهادی مقدار 9.852 / ۰.۰ به دست آورده است؛ در حالی که الگوریتم بهینه ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات به ترتیب مقادیری برابر با 9.761 / ۰.۰ و 12.06 / ۰.۰ به دست آورده‌اند. معیار F به دست آمده به کمک روش پیشنهادی برابر با 9.804 / ۰.۰ به دست آورده‌اند. در حالی که این معیار توسط الگوریتم‌های بهینه ساز گرگ خاکستری و بهینه‌سازی شده است؛

۱ . Recall

2. precession

3 . F-measure

توده ذرات به ترتیب برابر با $1687/0$ و $1701/0$ شده است. از نظر این سه معیار مشاهده می‌شود که روش پیشنهادی مقادیر بزرگتری به دست آورده است؛ بنابراین عملکرد و کارایی بهتری در مقایسه با دو الگوریتم الگوریتم بهینه ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات داشته است.

۵. نتیجه‌گیری و پیشنهادها

سیستم‌های توصیه‌گر، سیستم‌های هوشمندی هستند که در فضای اینترنت با شناسایی علائق و اولویت‌های هر کاربر، اطلاعات موجود را پایايش می‌کنند و پیشنهادهای مناسب و مرتبط را به کاربران ارائه می‌دهند. پرکاربردترین الگوریتم به کارفته در سیستم‌های توصیه‌گر، الگوریتم پایايش مشارکتی است. انتخاب صحیح معیار شباهت یک عامل حیاتی در پایايش مشارکتی است؛ زیرا دقت توصیه را به شدت تحت تأثیر قرار می‌دهد. در این پژوهش به منظور افزایش سرعت و کاهش محاسبات ناشی از یافتن نزدیک‌ترین همسایه‌ها به کاربر هدف، به ارائه تابع شباهت بهینه پرداخته شد. تابع شباهت بهینه از طریق یک ترکیب خطی ساده از مقادیر W و وزن‌ها W فرموله شده است. این مقادیر برای هر جفت از کاربران بر اساس اختلاف رتبه آیتم‌ها بین هر دو کاربر، محاسبه شده است و وزن‌های بهینه اعدادی در بازه $[1, -1]$ بوده و نشان‌دهنده اهمیت هر یک از عناصر بردار مقدار هستند. برای محاسبه شباهت میان دو کاربر از یک الگوریتم تکاملی ترکیبی گرگ خاکستری فازی بهبودداده شده با الگوریتم شیر استفاده شد. روش ارائه شده در این پژوهش این مزیت را دارد که می‌توان آن را در همه سیستم‌های توصیه‌گر به سادگی بر روی تکنیک‌های پایايش مشارکتی مورداستفاده قرارداد؛ چراکه این روش تنها از رتبه‌دهی کاربران استفاده می‌کند که حداقل اطلاعات ممکن در هر سیستم توصیه‌گر است.

هدف اصلی این پژوهش، ارائه سیستم پیشنهادهای برای سیستم‌های پایايش مشارکتی است که بر روی پیشنهاد آیتم متمرکز شده است تا به کاربر در انتخاب آیتم مناسب و مورد علاقه‌اش کمک کند. نتایج نشان می‌دهد سیستم پیشنهادی دارای صحت قابل قبول، سرعت بیشتر و کاهش زمان در ارائه پیشنهادها به کاربر است. با استفاده از تابع شباهت پیشنهادی، زمان ارائه پیشنهادها به کاربر از طریق محاسبه شباهت میان کاربران کاهش می‌یابد؛ همچنین محاسبات کمتری در مقایسه با توابع شباهت سنتی دارد.

با توجه به نمودارهای نتایج تجربی بهبودهای زیادی را می‌توان در کیفیت توصیه (دقت و فراخوانی) و کارایی توصیه (زمان اجرا) مشاهده کرد. با توجه به نتایج کسب شده می‌توان الگوریتم پیشنهادی را در محاسبه شباهت روش پایايش مشارکتی مبتنی بر آیتم به کار برد. ترکیب روش بالا با سیستم‌های توصیه‌گر مبتنی بر اعتماد نیز می‌تواند زمینه‌ای جدید برای پژوهش‌های

آتی باشد؛ همچنین می‌توان بر روی روش‌های پیش‌پردازش داده‌ها به صورت آفلاین کار کرد تا تأثیر بسزایی در فرآیند تولید توصیه داشته باشند. فاز آفلاین را می‌توان به کمک الگوریتم‌های یادگیری ماشین جدید بهبود داد. یکی دیگر از موضوع‌هایی که می‌تواند مورد توجه پژوهشگران قرار گیرد، پژوهش درباره روش‌هایی است که بازدهی مناسبی برای کاربران جدید (کاربرانی که تازهوارد سیستم شده‌اند و به آیتمی رأی نداده‌اند) داشته باشد.

منابع

1. Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE transactions on knowledge and data engineering*, 17(6), 734-749.
2. Alhijawi, B., & Kilani, Y. (2016). Using genetic algorithms for measuring the similarity values between users in collaborative filtering recommender systems. In *2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS)* (pp. 1-6). IEEE.
3. Beni, G., & Wang, J. (1993). Swarm intelligence in cellular robotic systems. In *Robots and biological systems: towards a new bionics?* (pp. 703-712). Springer, Berlin, Heidelberg.
4. Bhaidani A. S. (2008). *Recommender System Algorithms*. B.Sc thesis, Department of Mechanical and Industrial Engineering.
5. Bobadilla, J., Ortega, F., Hernando, A., & Alcalá, J. (2011). Improving collaborative filtering recommender system results and performance using genetic algorithms. *Knowledge-based systems*, 24(8), 1310-1316.
6. Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-based systems*, 46, 109-132.
7. Can, Ü., & Alataş, B. (2015). Physics based metaheuristic algorithms for global optimization.
8. Bonabeau, E., Dorigo, M., Marco, D. D. R. D. F., Theraulaz, G., & Théraulaz, G. (1999). *Swarm intelligence: from natural to artificial systems* (No. 1). Oxford university press.
9. Choudhary, V., Mullick, D., & Nagpal, S. (2017). Gravitational search algorithm in recommendation systems. *International Conference on Swarm Intelligence* (pp. 597-607). Springer, Cham.
10. Deng, S., Huang, L., Xu, G., Wu, X., & Wu, Z. (2016). On deep learning for trust-aware recommendations in social networks. *IEEE transactions on neural networks and learning systems*, 28(5), 1164-1177.
11. Dixit, V. S., & Jain, P. (2019). Weighted Percentile-Based Context-Aware Recommender System. In *Applications of Artificial Intelligence Techniques in Engineering* (pp. 377-388). Springer, Singapore.
12. Dorigo, M., Birattari, M., & Stutzle, T. (2006). Ant colony optimization. *IEEE computational intelligence magazine*, 1(4), 28-39.
13. Faraji Amiri, M., & Behnamian, J. (2020). The basic genetic simulation algorithm for solving the workshop flow scheduling problem by considering the energy cost under uncertainty conditions. *The Journal of Industrial Management Perspective*, 10(2), 9-32 (In Persian).
14. Feng, C., Liang, J., Song, P., & Wang, Z. (2020). A fusion collaborative filtering method for sparse data in recommender systems. *Information Sciences*, 521, 365-379.
15. Gholami, H., Mehdizadeh, I., Naderi, B. (2018). Mathematical modeling and colonial competition algorithm for the workshop flow assembly line problem. *The Journal of Industrial Management Perspectives*, 8 (1), 93-111. (In Persian).
16. Hatami, M., & Pashazadeh, S. (2014). Improving results and performance of collaborative filtering-based recommender systems using cuckoo optimization algorithm. *International Journal of Computer Applications*, 88(16), 46-51.

17. Herlocker, J., Konstan, J. A., & Riedl, J. (2002). An empirical analysis of design choices in neighborhood-based collaborative filtering algorithms. *Information retrieval*, 5(4), 287-310.
18. Islamia, A., & Azimi, P. (2019). Solving the problem of routing electric vehicles by considering the volume limit of the vehicle using the simulated annealing algorithm. *The Journal of Industrial Management Perspective*, 9(4), 165-188.(In Persian).
19. Katarya, R., & Verma, O. P. (2017). An effective collaborative movie recommender system with cuckoo search. *Egyptian Informatics Journal*, 18(2), 105-112.
20. Katarya, R., & Verma, O. P. (2018). Recommender system with grey wolf optimizer and FCM. *Neural Computing and Applications*, 30(5), 1679-1687.
21. Katarya, R. (2018). Movie recommender system with metaheuristic artificial bee. *Neural Computing and Applications*, 30(6), 1983-1990.
22. Kennedy, J., & Eberhart, R. (1995). Particle swarms optimization. *IEEE International Conference on Neural Networks*, vol. 4.
23. Kumar, M.S. & Jayagopal, P. (2019). Hybrid Model for Movie Recommendation System Using Fireflies and Fuzzy C-Means. *International Journal of Web Portals*, 11, 1-13.
24. Logesh, R., Subramaniyaswamy, V., Malathi, D., Sivaramakrishnan, N., & Vijayakumar, V. (2020). Enhancing recommendation stability of collaborative filtering recommender system through bio-inspired clustering ensemble method. *Neural Computing and Applications*, 32(7), 2141-2164.
25. Maier, H. R., Kapelan, Z., Kasprzyk, J., Kollat, J., Matott, L. S., Cunha, M. C., & Ostfeld, A. (2014). Evolutionary algorithms and other metaheuristics in water resources: Current status, research challenges and future directions. *Environmental Modelling & Software*, 62, 271-299.
26. Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.
27. Rad, H.S., & Lucas, C. (2007). A recommender system based on invasive weed optimization algorithm. *IEEE Congress on Evol. Comput., Singapore* 4297–4304.
28. Resnick, P., & Varian, H. R. (1997). Recommender systems. *Communications of the ACM*, 40(3), 56-58.
29. Rodríguez, L., Castillo, O., & Soria, J. (2016). A study of parameter dynamic adaptation with fuzzy logic for the grey wolf optimizer algorithm. In *Mexican International Conference on Artificial Intelligence* (pp. 228-238). Springer, Cham.
30. Sarwt, M., Levandoski, J.J., Eldawy, A., & Mokbel, MF. (2012). LARS*: An Efficient and Scalable Location- Aware Recommender System. *Trans. Knowl. Data Eng.*, 26(6), 1384–1399.
31. Sinha, B. B., & Dhanalakshmi, R. (2019), Evolution of recommender paradigm optimization over time (In Press), *Journal of King Saud University – Computer and Information Sciences*
32. Tohidi, N., & Dadkhah, C. (2020). Improving the performance of video collaborative filtering recommender systems using optimization algorithm. *International Journal of Nonlinear Analysis and Applications*, 11(1), 483-95.

33. Ujjin, S., & Bentley, P. J. (2003). Particle swarm optimization recommender system. In Proceedings of the 2003 IEEE Swarm Intelligence Symposium. SIS'03 (Cat. No. 03EX706) (pp. 124-131). IEEE.
34. Vimala, S. V., & Vivekanandan, K. (2019). A Kullback–Leibler divergence-based fuzzy C-means clustering for enhancing the potential of an movie recommendation system. *SN Applied Sciences*, 1(7), 1-11.
35. Wang, T., Manogaran, G., & Wang, M. (2019). Framework for social tag recommendation using Lion Optimization Algorithm and collaborative filtering techniques. *Cluster Computing*, 23(3), 2009-2019.
36. Yadav, S., Vikesh, Shreyam & Nagpal, S. (2018). An improved collaborative filtering based recommender system using bat algorithm. *Procedia computer science*, 132, 1795-1803.
37. Yang, X. S., & Karamanoglu, M. (2013). Swarm intelligence and bio-inspired computation: an overview. In *Swarm intelligence and bio-inspired computation* (pp. 3-23). Elsevier.
38. Yazdani, M. & Jolai, F. (2015). Lion Optimization Algorithm (LOA): A Nature-Inspired Metaheuristic Algorithm. *Journal of Computational Design and Engineering*, 4. 10.1016/j.jcde.2015.06.003.