

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 بهینه‌ساز گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر

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

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 به‌طور کلی به سه گروه مبتنی بر محتوا، مبتنی بر دانش و مبتنی بر پالایش مشارکتی و در بعضی موارد ترکیبی تقسیم می‌کنند. ایده اصلی پالایش مشارکتی این است که اگر کاربران علایق مشابه یا یکسان در گذشته داشته باشند و آن را به اشتراک 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 شباهت 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 موردپسند 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 به‌وجود آورده است. سیستم پیشنهاددهنده به فیلترکردن انبوه داده‌های تولیدشده توسط کاربران در اینترنت کمک می‌کند و به شناسایی علایق کاربر بر اساس سوابق و رفتار گذشته وی منجر می‌شود. یک سیستم توصیه‌گر، تکنیک متمایزی است که برای طبقه‌بندی «N» موردی که ممکن است موردتوجه 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. به‌طور معمول یک سیستم توصیه‌گر، یک تکنیک شخصی‌سازی است که با ارزیابی پروفایل شخص با بعضی از ویژگی‌های مرجع، به کاربران در پیدا کردن 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 متنوعی از پایش اطلاعات موجود در وب به‌منظور 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 به‌طور هدفمندتری به فروش برسانند؛ زیرا می‌تواند توجه افراد مشاهده‌گر در وبسایت را به محصولات موردعلاقه‌شان جلب کرده و آن‌ها را به خرید وادارد 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؛ در نتیجه سیستم توصیه گر خوب می تواند به فروش بیشتر محصولات کمک کند و از این نظر می توان آن را مکمل هوشمندی برای بازاریابی در نظر گرفت. در واقع یک سیستم توصیه گر مناسب به مدیران در ارائه محصولات سفارشی به مشتریان خود یاری می رساند و به عنوان ابزاری سودمند در مدیریت ارتباط با مشتری^۱ مطرح می شود. در این پژوهش، هدف بهبود سیستم توصیه گر برای توصیه محصولات مورد علاقه به کاربران مختلف است؛ به طوری که در نهایت این بهبود به ارتقای کیفیت فرآیند بازاریابی و مدیریت ارتباط با مشتریان منجر خواهد شد.

چندین مدل برای پیشنهاد در سیستم توصیه گر استفاده می شوند که بر پایه سه مدل اصلی هستند [۳۲]:

۱. مدل پالایش مشارکتی^۲: این مدل که بیشترین استفاده را در سیستم توصیه گر 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 عبارتند از: روش مبتنی بر همسایگی و روش مبتنی بر مدل. روش مبتنی بر همسایگی می تواند در دو حالت زیر تعریف شود: پالایش مشارکتی مبتنی بر کاربر^۳: به کمک تحلیل اطلاعات، استخراج داده ها و هدف قرار دادن فعالیت های کاربر، همسایه های کاربر با علاقه های مشابه مشخص می شوند؛ سپس به وسیله یافتن نزدیک ترین همسایه ها به کاربر مورد نظر، گزینه های کاربر را بر اساس این همسایه ها پیشنهاد می کند.

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

۲. سیستم توصیه گر مبتنی بر محتوا^۵: توصیه ها در سیستم های توصیه گر مبتنی بر محتوا به وسیله بیان ارتباط میان ویژگی های آیتم ها ایجاد می شود؛ به عبارت دیگر این سیستم ها اطلاعات مورد نیاز از کاربر را از طریق آیتم هایی که پیش از آن مشاهده کرده اند، جمع آوری می کنند. این سیستم ها تنوعی از آیتم های غیر معروف و معروف به وسیله استفاده از تکنیک های هوشمند مانند شبکه های عصبی پیشنهاد می دهند؛ همچنین برخی از این سیستم ها از پیوند بین آیتم ها برای یافتن قواعد وابستگی آیتم و آیتم های متجانس استفاده می کنند.

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 به‌صراحت توسط وی تعیین شده است برای پیشنهاد آیت‌ها استفاده می‌کند. این سیستم را می‌توان در زمینه خاصی، مانند خرید خانه یا اقلام عتیقه، اجرا کرد. به این دلیل که تاریخچه کاربر/ آیت‌ها کافی در این زمینه‌ها وجود ندارد و اطلاعات در دسترس 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 آیت‌ها 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 فراابتکاری^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 فراابتکاری 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، به‌عنوان 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 فراابتکاری با وجود داشتن مزایای بسیار، در این زمینه چندان به‌کار گرفته نشده‌اند و در مطالعات معدود انجام‌شده بیشتر الگوریتم‌های فراابتکاری 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 هوشمندبودن، 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 فراابتکاری 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 به شدت احساس می‌شود؛ از این رو در این پژوهش، الگوریتمی از ترکیب الگوریتم گرگ خاکستری و الگوریتم شیر (هر دو جست‌وجوی محلی قوی دارند) ارائه شده است و از منطق فازی به منظور هوشمند کردن الگوریتم پیشنهادی و تنظیم پارامترهای آن برای تقویت جست‌وجوی سراسری و محلی استفاده شده است تا بتوان عملکرد سیستم توصیه گر را از طریق بهبود در پارامترهای دقت^۱، فراخوانی^۲ و معیار F^3 ارتقا داد.

۲. مبانی نظری و پیشینه پژوهش

الگوریتم‌های فراابتکاری، 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 فراابتکاری در حل مسئله سیستم توصیه گر 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 توصیه گر با استفاده از رویکردهای متاهوریستی 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 خوشه‌بندی c- میانگین فازی^۸ 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.

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

سینها و دانکالاکشمی^۱ (۲۰۱۹)، تجزیه و تحلیل مقایسه‌ای تعدادی از تکنیک‌های بهینه‌سازی که برای پیاده‌سازی سیستم توصیه‌کننده 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	تکنیک بهینه‌سازی	موضوع
[۳۶]	الگوریتم خفاش ^۲	این رویکرد فراابتکاری برای محاسبه وزن‌های مورد استفاده برای یافتن همسایه‌های بهتر استفاده می‌شود.
[۱۹]	الگوریتم فاخته ^۳	این رویکرد برای بهینه‌سازی نتایج به دست آمده از الگوریتم K-means استفاده می‌شود.
[۲۰]	بهینه‌ساز گرگ خاکستری ^۴	در این رویکرد از بهینه‌سازی گرگ خاکستری برای تصمیم‌گیری در مورد موقعیت‌های خوشه‌ها و نقاط خوشه‌بندی اولیه استفاده شده است.
[۳۳]	کلونی زنبور عسل ^۵	این رویکرد نتایج به دست آمده از الگوریتم K-means را بهینه می‌کند.
[۹]	بهینه‌سازی ازدحام ذرات ^۶	از این رویکرد برای به دست آوردن وزن ویژگی برای کاربر فعال استفاده می‌شود و از این رو در تصمیم‌گیری در مورد کاربر کمک می‌کند.
[۲۷]	الگوریتم جستجوی گرانشی ^۷	این رویکرد تنظیمات مربوط به وزن ویژگی‌ها را تنظیم می‌کند.
[۲]	الگوریتم علف هرز مهاجم ^۸	این الگوریتم در تصمیم‌گیری در مورد اولویت بهینه ویژگی‌های هر محصول کاربر برای مجموعه‌های مختلف کاربران کمک می‌کند.
[۳۰]	الگوریتم ژنتیک ^۹	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.

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. روش شناسی پژوهش

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

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 می توان در همه سیستم های توصیه گر به سادگی روی تکنیک های پالایش مشارکتی، مورد استفاده قرار داد. علت این واقعیت این است که روش ما تنها از رتبه دهی کاربران استفاده می کند که حداقل اطلاعات ممکن در هر سیستم توصیه گر است. سیستم پیشنهادی از دو فاز آموزش و آزمایش تشکیل شده است. در واقع بخشی از مجموعه داده شامل کاربران آموزشی و آیت های آموزشی به منظور به دست آوردن یکتا شباهت بهینه در فاز آموزش استفاده می شود. پس از به دست آوردن این تابع شباهت، آزمایش ها برای ارزیابی عملکرد شباهت به دست آمده با استفاده از کاربران آزمایشی و آیت های آزمایشی، یعنی کاربران و آیت هایی که در فاز آموزش استفاده نشده اند، انجام می شود.

الگوریتم نزدیک ترین همسایه ها^۱. یکی از متداول ترین الگوریتم های مورد استفاده در سیستم های توصیه گر پالایش مشارکتی، «الگوریتم k نزدیک ترین همسایه ها» است. در یک شبکه اجتماعی می توان یک همسایگی از کاربر مورد نظر را با علائق مشابه با آن کاربر تعیین کرد؛ به این ترتیب که همسایه ها را بر حسب شباهت آن ها با کاربر مورد نظر مرتب کرده و k همسایه بالاتر انتخاب می شود. در این پژوهش الگوریتم نزدیک ترین همسایه مبتنی بر کاربر مورد توجه قرار می گیرد [۵].

الگوریتم نزدیک ترین همسایه مبتنی بر کاربر. نخستین بار در پروژه گروپ لنز^۲ در سال ۱۹۹۴، اساس الگوریتم پالایش مشارکتی مبتنی بر کاربر پیشنهاد شد. این الگوریتم پالایش مشارکتی، «مبتنی بر کاربر» نامیده می شود 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 می شود. انتخاب صحیح معیار شباهت، یک فاکتور حیاتی در پالایش مشارکتی است، زیرا دقت توصیه را به شدت تحت تاثیر قرار می دهد. مسئله 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 i که کاربر هدف هنوز ندیده (رتبه‌بندی نکرده)، یک پیش‌بینی براساس رتبه‌بندی‌های کاربران همسایه روی آیت i محاسبه می‌شود.

نخستین گام توصیه، تعیین تابع شباهت بهینه پیشنهادی است. محاسبه شباهت میان هر دو کاربر a, u در دیتاست به صورت رابطه (۱) تعریف شده است، این فرمول‌بندی همان میانگین وزن‌دار شده است که با استناد به بوبادیللا و همکاران^۱ (۲۰۱۱) و حاتمی و پاشازاده^۲ (۲۰۱۴) استخراج شده است [۵، ۱۶]:

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

در رابطه ۱، M بالاترین رتبه و m پایین‌ترین رتبه تعریف‌شده در سیستم است که کاربر می‌تواند به هر یک از آیت‌ها 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 به‌عنوان 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 [۵]:

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

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

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

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

$$P_a^i = \bar{r}_a + \frac{\sum_{u \in U_i \cap S(a)} \text{sim}(a, u) \cdot (r_{u,i} - \bar{r}_u)}{\sum_{u \in U_i \cap S(a)} |\text{sim}(a, u)|} \quad \text{رابطه (۳)}$$

در صورتی که $U_i \cap S(a) = \emptyset$ باشد، پیش‌بینی رتبه‌بندی P_a^i برای کاربر هدف a روی آیت i را نمی‌توان محاسبه کرد. سیستم توصیه‌گر آیت‌هایی 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 مثبتی با کاربر فعال داشته و آیت موردنظر را رتبه‌بندی کرده باشند. اگر از تمامی همسایه‌ها برای محاسبه پیش‌بینی رتبه‌بندی استفاده شود، با توجه به زمان محاسبه موردنیاز، نه‌تنها 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 $U\{1, \dots, U\}$ و یک مجموعه از آیت‌ها $I\{1, \dots, I\}$ را در نظر خواهیم گرفت. کاربران، آیت‌ها را با مقادیری در یک محدوده گسسته $\{m, \dots, M\}$ که معمولاً نشان‌دهنده نارضایتی کامل کاربر در مورد آیت m و معمولاً نشانه رضایت کامل کاربر از یک آیت 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 به وسیله بردار $r_u = (r_u^{(1)}, r_u^{(2)}, \dots, r_u^{(I)})$ با اندازه I (تعداد آیت‌ها در مجموعه داده) ارائه می‌شود؛ به طوری که $r_u^{(i)}$ نشان‌دهنده رتبه‌ای است که کاربر u برای آیت i ایجاد کرده است. بدیهی است که یک کاربر ممکن است همه آیت‌ها را رتبه‌بندی نکند. عبارت $r_u^{(i)} = 0$ برای حالتی که کاربر u هنوز آیت i را رتبه نداده است، استفاده می‌شود [۵].

محاسبه بردارهای مقادیر (V). به منظور مقایسه دو بردار r_u و r_a که در واقع رتبه‌های داده‌شده به آیت‌ها 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 آیت 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 آیت‌های رتبه‌بندی‌شده توسط هر دو کاربر (یعنی $r_a^{(i)} \neq 0, r_u^{(i)} \neq 0$) و

A نشان‌دهنده تعداد آیت‌های رتبه‌بندی شده توسط هر دو کاربر است؛ با این شرط که تفاضل مطلق رتبه‌بندی‌های کاربر a و کاربر u برابر i باشد $(|r_a^i - r_u^i| = i)$. [۵].
اجرای یک مثال. فرض می‌شود که $m=1$ و $M=5$ (مجموعه امکان‌پذیر رتبه‌ها $\{1, \dots, 5\}$ است)، ۹ آیت موجود است $i=9$ و دو کاربر وجود دارند که رتبه‌بندی‌هایشان به وسیله 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 آیت رتبه‌بندی شده توسط دو کاربر وجود دارد. در عنصر $v_{1,2}^{(0)}$ ، صورت تعداد آیت‌هایی که رتبه دو کاربر به آن‌ها یکسان بوده (اختلاف مطلق آن‌ها صفر است) و مخرج تعداد کل آیت‌های رتبه‌بندی شده توسط هر دو کاربر، را نشان می‌دهد. در مثال $v_{1,2}^{(0)} = \frac{1}{5}$ به این دلیل که فقط یکی از آیت‌ها (آیت اول) با رتبه مشابه ۴ توسط دو کاربر رتبه‌دهی شده است $(|r_1^{(1)} - r_2^{(1)}| = 0)$. به همین ترتیب در $v_{1,2}^{(M-m)}$ ، صورت تعداد آیت‌هایی که دو کاربر کاملاً متفاوت رتبه‌دهی کرده‌اند و مخرج تعداد کل آیت‌های رتبه‌بندی شده توسط هر دو کاربر را نشان می‌دهد. در مثال $v_{1,2}^{(M-m)} = v_{1,2}^{(4)} = \frac{0}{5} = 0$ چراکه هیچ دو آیت رتبه‌بندی شده‌ای با مقادیر ۱ و ۵ توسط کاربران ۱ و ۲ وجود ندارند. در مثال بالا، $v_{1,2}^{(2)} = \frac{2}{5}$ به این دلیل که دقیقاً دو آیت (آیت ۲ و آیت ۹) وجود دارند که $|r_1^{(2)} - r_2^{(2)}| = 2$. [۵].

طبق تابع شباهت به‌ازای هر بردار V یک بردار W با همان اندازه باید تعریف شود که هر عنصر $w^{(i)}$ نشان‌دهنده اهمیت عنصر $v_{a,u}^{(i)}$ در محاسبه شباهت 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 در نظر گرفتن یک بردار نمونه $W = (1, 0.5, 0, -0.5, -1)$ به صورت زیر تشریح کرد:

$w^{(0)} = 1$ ، آیت‌هایی که مشابه هم رتبه‌دهی شدند را در محاسبه شباهت بسیار مثبت ارزیابی می‌کند.
 $w^{(1)} = 0.5$ ، آیت‌هایی را که اختلاف بین رتبه‌های آن‌ها ۱ است را با یک مقدار متوسط مثبت ارزیابی می‌کند.

$w^{(2)} = 0$ ، آیت‌هایی را که اختلاف رتبه‌دهی دو کاربر به آن‌ها ۲ است را در محاسبه شباهت در نظر نمی‌گیرد.

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

$w^{(4)} = -1$ ، آیت‌هایی که متضاد هم رتبه‌دهی شدند را در محاسبه شباهت بسیار منفی ارزیابی می‌کند.

به این ترتیب می‌توان به‌طور منطقی انتظار داشت که تابع شباهت 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 شباهت 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 فراابتکاری به اندازه کافی قدرتمند برای حل این مسئله نیاز است؛ از این‌رو در این پژوهش، یک الگوریتم بهینه‌سازی فراابتکاری 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 ارائه‌هنگام 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 جست‌وجوی سراسری و محلی را برعهده دارد به کمک قواعد فازی تنظیم می‌شود؛ همچنین پارامتر C این الگوریتم نیز به‌عنوان خروجی دیگر سیستم فازی تنظیم شده است که به بهبود در جست‌وجوی سراسری و محلی الگوریتم کمک می‌کند. برای بهبود در جست‌وجوی 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 یافته‌شده 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 [۲، ۲۲، ۱۲]. 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 انتها به کمک برخی 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

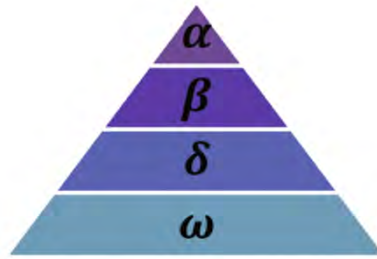
- بر اساس فیزیک (برگرفته شده از قوانین فیزیکی) [۷]: الگوریتم بهینه‌سازی فروپاشی بزرگ بیگ - بنگ^۴، الگوریتم جست‌وجوی گرانشی^۵ و الگوریتم بهینه‌سازی واکنش‌گر شیمیایی مصنوعی^۶

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

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 داده‌شده در این پژوهش در ادامه توضیح داده خواهند 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 سلسله مراتب گرگ خاکستری [۲۹]

سلسله مراتب 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].

سلسله مراتب اجتماعی. به منظور مدل‌سازی ریاضی سلسله مراتب اجتماعی گرگ‌ها وقتی که الگوریتم بهینه ساز گرگ خاکستری^۱ طراحی می‌شود، برازنده‌ترین جواب به‌عنوان 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. به منظور مدل‌سازی ریاضی رفتار احاطه کردن شکار معادلات زیر پیشنهاد شده است:

$$D = |CX_p(t) - X(t)| \quad \text{رابطه (۶)}$$

$$X(t+1) = X_p(t) - AD \quad \text{رابطه (۷)}$$

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:

$$A = 2a(t)r_1 - a(t) \quad \text{رابطه (۸)}$$

$$C = 2r_2 \quad \text{رابطه (۹)}$$

1. Grey Wolf Optimizer (GWO)

ضریب a در هر تکرار به‌طور 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 به‌وسیله گرگ آلفا هدایت می‌شود. به‌منظور 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 به‌دست‌آمده 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:

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

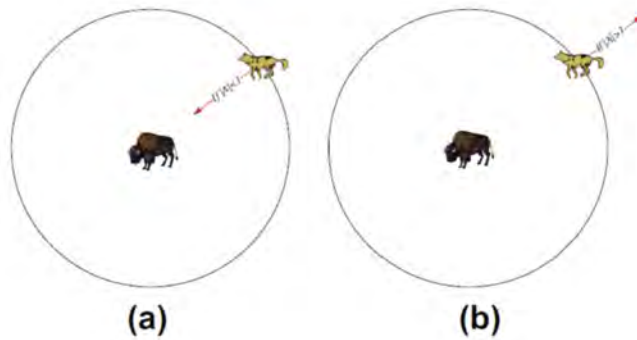
$$D_\beta = |C_2 X_\beta - X(t)|, X_2 = X_\beta - A_2 D_\beta \quad \text{رابطه (۱۱)}$$

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

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

معادله ۱۳، نشان‌دهنده به‌روزرسانی 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 جست‌وجو دارد.



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).

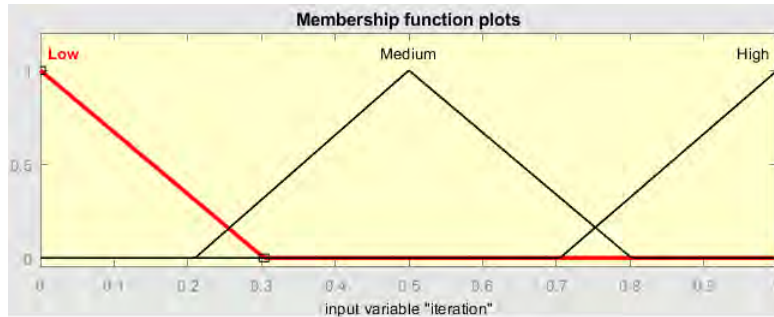
به‌علاوه ضریب C همچنین اکتشاف در الگوریتم را نشان می‌دهد؛ زیرا یک حرکت تصادفی از یک گرگ خاکستری در جست‌وجو برای شکار نشان داده است و اگر موقعیت بعدی نزدیک به شکار باشد، به‌طور غیرمستقیم استخراج انجام می‌دهد [۲۶].

الگوریتم بهینه‌سازی گرگ خاکستری فازی ترکیب‌شده 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.

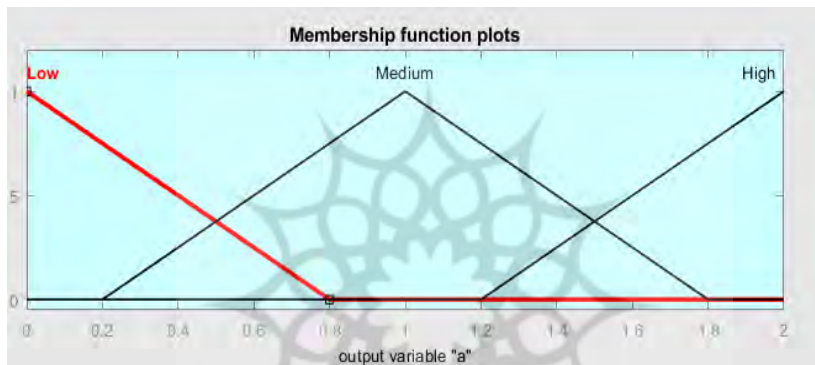
طراحی سیستم استنتاج فازی برای بهبود الگوریتم گرگ خاکستری. از آنجاکه تنظیم پارامترهای الگوریتم‌های بهینه‌سازی در شرایط مختلف مشکل است، در اینجا از قوانین فازی استفاده می‌شود. در واقع استفاده از منطق فازی به دلیل رفع حساسیت نسبت به پارامترهای الگوریتم است؛ به این صورت که پارامترهای اصلی گرگ خاکستری که شامل a و C است، به کمک قوانین فازی تنظیم می‌شوند؛ به‌طوری این پارامترها خود را بر طبق شرایط مسئله تغییر می‌دهند؛ بنابراین مشکل تنظیم پارامترهای الگوریتم اصلی نیز رفع می‌شود. در نهایت با توجه به اینکه پارامترهای a و C به‌طور 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 نرمال‌شده و خروجی‌های این سیستم پارامتر a و C

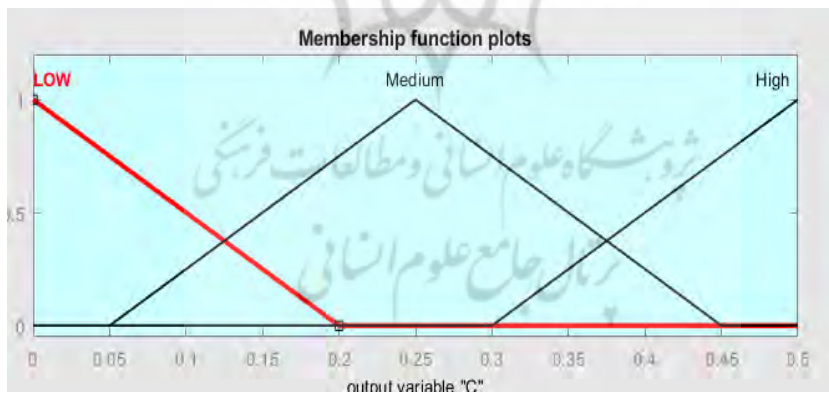
است. برای هر ورودی و هر خروجی سه تابع عضویت فازی (کم، متوسط و زیاد) نوع ممدانی تقسیم‌بندی می‌شوند که دارای نوع غیرفازی مرکز ثقل است و تمام توابع عضویت مثلثی هستند که توابع عضویت در شکل‌های ۳ تا ۵، قرار می‌گیرند.



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 به‌ازای احتمال $0/5$ درصد به‌روزرسانی موقعیت گرگ‌ها توسط معادله‌های ۱۰ تا ۱۲، انجام شده و در غیر این صورت معادله ۱۴، اجرا می‌شود [۳۸].

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

در روابط بالا، PI نرخ بهبود برازندگی است که به‌صورت 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 $0/5$ اجرا می‌شود. در غیر این صورت اگر این احتمال بزرگ‌تر از $0/1$ باشد، یک حرکت به سمت بهترین گرگ با ضریب تصادفی rand با رابطه ۱۶ انجام می‌شود.

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

معادله ۱۶ از الگوریتم بهینه‌سازی 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 $0/1$ جست‌وجو پیرامون بهترین گرگ که گرگ آلفا است با ضریب تصادفی زیر انجام می‌شود:

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

رابطه‌ی ۱۷، از الگوریتم علف هرز الهام گرفته شده؛ اما ضریب $0/0001$ 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 حساس بودن 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. یک تابع شباهت وزن‌دار 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 این رو 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 مووی لنز^۱ انجام می‌شود. توابع محک Ackley و Sphere, Griewank, Rosenbrock, Rastrigin برای مقایسه انتخاب شده‌اند.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی



شکل ۶. فلوچارت الگوریتم گرگ خاکستری فازی ترکیب‌شده با الگوریتم شیر پیشنهادی

معرفی دیتاست مورد استفاده: برای داده‌های آزمایش از مووی‌لنز 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 امتیازدهی 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؛ کودکان؛ طنز؛ جنایی؛ مستند؛ غمناک؛ و

۴. تحلیل داده‌ها و یافته‌های پژوهش

مقایسه بین الگوریتم پیشنهادی با الگوریتم گرگ خاکستری و بهینه‌سازی توده ذرات با در نظر گرفتن تعداد تکرار و اندازه جمعیت به ترتیب 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

نام الگوریتم بهینه‌سازی	معیار ارزیابی	Sphere	Rosenbrock	Rastrigin	Griewank	Ackley
بهینه‌ساز گرگ خاکستری	Mean	$3/3197 e-04$	$0/0555$	$3/3353$	$0/0518$	$0/1499$
	Min	$0/0012794$	$0/0161$	$0/0210$	$0/1661$	$0/2263$
	Max	$0/005882$	$0/1214$	$13/3117$	$0/1771$	$0/0869$
بهینه‌سازی توده ذرات	Mean	$3/3197 e-04$	$0/6710$	$3/3634$	$0/0228$	$0/0587$
	Min	$0/004827$	$0/0210$	$0/9483$	$0/0101$	$0/021$
	Max	$5/8820 e-04$	$3/2352$	$5/4401$	$0/03$	$0/0757$
الگوریتم بهینه‌ساز گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر	Mean	$5/0316 e-06$	$6/8063 e-04$	$0/1372$	$0/0150$	$0/0421$
	Min	$1/4891 e-07$	$2/9026 e-05$	$4/0737 e-07$	$0/0251$	$0/0190$
	Max	$0/005882$	$0/0032$	$0/166$	$0/0074$	$0/0727$

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 به‌دست‌آمده به‌وسیله الگوریتم پیشنهادی برای توابع محک Sphere مقدار $e-06$ $5/0316$ شده است؛ درحالی‌که الگوریتم بهینه‌ساز گرگ خاکستری برابر با $e-04$ $3/3197$ و الگوریتم بهینه‌سازی توده ذرات برابر با $0/00048027$ شده است؛ اما برای تابع پیچیده‌تر Ackley بهترین مقدار میانگین به‌دست‌آمده از الگوریتم پیشنهادی برابر با $0/0421$ به‌دست آمده است؛ درحالی‌که این مقدار برای الگوریتم بهینه‌ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات به‌ترتیب برابر با $0/1499$ و $0/0587$ شده است. برای توابع دیگر نیز مشاهده می‌شود که الگوریتم پیشنهادی در کمینه‌سازی موفق‌تر از دو الگوریتم بهینه‌ساز گرگ خاکستری و بهینه‌سازی توده ذرات از نظر میانگین، بهترین و بدترین جواب به‌دست‌آمده 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 F^2	دقت ^۲	فراخوانی ^۱	
۰/۱۶۸۷	۰/۹۷۶۱	۰/۱۰۱۷	بهینه‌ساز 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 $0/1032$ به‌دست آورد؛ درحالی‌که دو الگوریتم بهینه‌ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات به‌ترتیب مقادیری برابر با $0/1017$ و $0/1029$ به‌دست آورده‌اند. از نظر معیار دقت مشاهده می‌شود که الگوریتم پیشنهادی مقدار $0/9852$ به‌دست آورده است؛ درحالی‌که الگوریتم بهینه‌ساز گرگ خاکستری و الگوریتم بهینه‌سازی توده ذرات به‌ترتیب مقادیری برابر با $0/9761$ و $0/9804$ به‌دست آورده‌اند. معیار F به‌دست‌آمده به کمک روش پیشنهادی برابر با $0/1706$ شده است؛ درحالی‌که این معیار توسط الگوریتم‌های بهینه‌ساز گرگ خاکستری و بهینه‌سازی

1 . Recall
2. precession
3 . F-measure

توده ذرات به‌ترتیب برابر با ۰/۱۶۸۷ و ۰/۱۷۰۱ شده است. از نظر این سه معیار مشاهده می‌شود که روش پیشنهادی مقادیر بزرگ‌تری به‌دست 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 علایق و اولویت‌های هر کاربر، اطلاعات موجود را پالایش می‌کنند و پیشنهادهای مناسب و مرتبط را به کاربران ارائه می‌دهند. پرکاربردترین الگوریتم به‌کاررفته در سیستم‌های توصیه‌گر، الگوریتم پالایش مشارکتی است. انتخاب صحیح معیار شباهت یک عامل حیاتی در پالایش مشارکتی است؛ زیرا دقت توصیه را به‌شدت تحت تأثیر قرار می‌دهد. در این پژوهش به‌منظور 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 V و وزن‌ها W فرموله شده است. این مقادیر برای هر جفت از کاربران بر اساس اختلاف رتبه آیت‌ها 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 بهبود داده‌شده با الگوریتم شیر استفاده شد. روش ارائه‌شده در این پژوهش این مزیت را دارد که می‌توان آن را در همه سیستم‌های توصیه‌گر به‌سادگی بر روی تکنیک‌های پالایش مشارکتی مورد استفاده قرار داد؛ چراکه این روش تنها از رتبه‌دهی کاربران استفاده می‌کند که حداقل اطلاعات ممکن در هر سیستم توصیه‌گر است.

هدف اصلی این پژوهش، ارائه سیستم پیشنهاددهنده‌ای برای سیستم‌های پالایش مشارکتی است که بر روی پیشنهاد آیت متمرکز شده است تا به کاربر در انتخاب آیت 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 کسب‌شده می‌توان الگوریتم پیشنهادی را در محاسبه شباهت روش پالایش مشارکتی مبتنی بر آیت به‌کار 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 به‌صورت 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., & Theraulaz, 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., Subramaniaswamy, V., Malathi, D., Sivaramkrishnan, 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.

