Journal of Soft Computing and Information Technology (JSCIT)
Babol Noshirvani University of Technology, Babol, Iran
Journal Homepage: jscit.nit.ac.ir
DOI: 10.22034/jscit.2025.500498.2094
Volume 14, Number 4, Winter 2026, pp. 63-81
Received: 01/17/2025, Revised: 11/04/2025, Accepted: 11/10/2025

Improving Collaborative Filtering-based recommender system Using new hybrid meta-heuristic algorithm

Haleh Nakhaei Rad[1], Hessam Zandhessami [2*] and Abbas Toloie Eshlaghy[3]
1- Ph.D. Candidate, Department of Information Technology Management, SR.C., Islamic Azad University, Tehran, Iran.
2*- Associate Professor, Department of Industrial Management and Technology, SR.C., Islamic Azad University, Tehran, Iran.
3- Professor, Department of Industrial Management and Technology, SR.C., Islamic Azad University, Tehran, Iran.
[1] haleh.nakhaeirad@gmail.com, [2*] h.zandhessami@iau.ir and [3] toloie@iau.ac.ir

Corresponding author's address: Hessam Zandhessam, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University ,shodada Hesarak blvd, Daneshgah Square,Sattari Highway,Tehran, IRAN.

Abstract- Collaborative filtering (CF) is the most widely used recommendation technique because it relies on user interactions rather than specific user or item features. The neighborhood-based (memory-based) CF method predicts user preferences by measuring similarities between users or items and similarity weights have a noticeable effect on recommendation quality. Therefore in this study, the similarity calculation between users is formulated as an optimization problem, and a novel hybrid metaheuristic algorithm is proposed to improve its weights. This algorithm combines Grey Wolf Optimizer (GWO), Lion Optimization Algorithm (LOA), and Differential Evolution (DE) to determine the optimal similarity weights. The performance of the proposed algorithm is evaluated using Mean Absolute Error (MAE), Precision, Recall, and F-measure. The average MAE for the proposed algorithm, GWO and PSO are 0.4919, 0.5544, and 0.5578 respectively, indicating a significant reduction in MAE, and an improvement in prediction quality compared to baseline algorithms. Also, the evaluations using 175 nearest neighbors and varying numbers of recommendations demonstrate improvements in Precision, Recall and F-measure, reflecting enhanced recommendation quality. Finally, the proposed algorithm was assessed on a set of standard benchmark functions and compared with GWO and PSO algorithms, showing superior performance in minimizing.

Keywords: Collaborative Filtering Recommender Systems, Grey Wolf Optimizer Algorithm, Lion Optimization Algorithm, Differential Evolution Algorithm, Fuzzy Logic.

مجله علمی رایانش نرم و فناوری اطلاعات
دانشگاه صنعتی نوشیروانی بابل
صفحه مجله: jscit.nit.ac.ir
شناسه دیجیتال: 10.22034/jscit.2025.500498.2094
جلد ۱۴، شماره ۴، زمستان ۱۴۰۴، صفحه ۶۳-۸۱
دریافت: ۱۴۰۳/۱۰/۲۸، بازنگری: ۱۴۰۴/۰۸/۱۳، پذیرش: ۱۴۰۴/۰۸/۱۹

بهبود سیستم توصیه‌گر پالایش مشارکتی با استفاده از الگوریتم فراابتکاری ترکیبی جدید

هاله نخعی راد[۱]، حسام زندحسامی*[۲]، عباس طلوعی اشلقی[۳]
۱- دانشجوی دکتری گروه مدیریت فناوری اطلاعات، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
*۲- دانشیار گروه علمی مدیریت صنعتی و تکنولوژی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.
۳- استاد گروه علمی مدیریت صنعتی و تکنولوژی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

[1] haleh.nakhaeirad@gmail.com, [2*] h.zandhessami@iau.ir, [3] toloie@iau.ac.ir

* نشانی نویسنده مسئول: حسام زندحسامی، تهران - انتهای بزرگراه شهید ستاری - میدان دانشگاه - بلوار شهدای حصارک - دانشگاه آزاد اسلامی واحد علوم و تحقیقات- دانشکده مدیریت و اقتصاد

چکیده- پالایش مشارکتی (CF) پرکاربردترین رویکرد سیستم توصیه‌گر است زیرا به جای ویژگی‌های کاربر یا آیتم، بر تعاملات کاربر متکی است. روش CF مبتنی بر همسایگی (مبتنی بر حافظه) ترجیحات کاربر را برمبنای سنجش شباهت میان کاربران یا آیتم‌ها، پیش‌بینی می‌کند و وزن‌های شباهت تأثیر قابل‌توجهی بر کیفیت توصیه دارند. بنابراین در این مطالعه، محاسبه شباهت بین کاربران به عنوان یک مسئله بهینه‌سازی تعریف و یک الگوریتم فراابتکاری ترکیبی جدید برای بهبود وزن‌های آن پیشنهاد شده است. این الگوریتم، بهینه سازی گرگ خاکستری (GWO)، بهینه سازی شیر (LOA) و تکامل تفاضلی (DE) را برای تعیین وزن شباهت بهینه ترکیب می‌کند. عملکرد الگوریتم پیشنهادی با استفاده از میانگین خطای مطلق(MAE) و معیارهای دقت، فراخوانی و F ارزیابی شد. میانگین MAE برای الگوریتم پیشنهادی، گرگ خاکستری و توده ذرات به ترتیب برابر با ۰/۴۹۱۹، ۰/۵۵۴۴، ۰/۵۵۷۸ بوده که نشاندهنده کاهش قابل‌توجهی در MAE و بهبود کیفیت پیش‌بینی در مقایسه با الگوریتم‌های پایه است. همچنین ارزیابی‌ها با ۱۷۵ نزدیکترین همسایه و تعداد مختلف توصیه نیز افزایش معیارهای دقت، فراخوانی و F و در نتیجه بهبود کیفیت توصیه را نشان می‌دهد. در نهایت الگوریتم پیشنهادی توسط توابع محک ارزیابی و با الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات مقایسه شد و نتایج نشان داد الگوریتم پیشنهادی در کمینه‌سازی عملکرد بهتری دارد.

واژه‌های کلیدی: سیستم توصیه‌گر پالایش مشارکتی، الگوریتم بهینه‌سازی گرگ خاکستری، الگوریتم بهینه‌سازی شیر، الگوریتم تکامل تفاضلی، منطق فازی.

۱- مقدمه

روند روبه‌رشد استفاده از اینترنت، کاربران را با پدیده سرریز اطلاعات[۱] مواجه می‌نماید، به این معنا که حجم اطلاعات بیش از حد است، به گونه‌ای که کاربران در اطلاعات گم می‌شوند و نمی‌توانند به خوبی از داده‌ها استفاده کنند. سیستم‌های توصیه‌گر با سفارشی‌سازی اطلاعات برای کاربران مشکل فوق را تا حد زیادی حل کرده‌اند و آنها اکنون می‌توانند نیازها و ترجیحات خود را با استفاده از این سیستم‌ها شناسایی کنند و با سفارشی‌سازی

سرویس‌ها به اهداف و اولویت‌های خود با سرعت بیشتری دست یابند. طبق طبقه‌بندی کلاسیک سیستم‌های توصیه‌گر شامل چهار نوع مبتنی بر پالایش مشارکتی[۲]، مبتنی بر محتوا[۳]، مبتنی بر جمعیت‌شناختی[۴] و ترکیبی[۵] هستند [۱]. رویکرد پالایش مشارکتی اطلاعات را با این فرض که کاربر آیتمی را دوست دارد که سایر کاربران در گذشته دوست داشته‌اند، بازیابی می‌کند. به عبارت دیگر، با استفاده از شباهت‌های بین آیتم‌ها (مبتنی بر آیتم) یا بین کاربران (مبتنی بر کاربر) اطلاعات را برای کاربر هدف بازیابی و با توجه به نتایج به دست آمده توصیه‌هایی را ارائه می‌کند [۲]. در مقابل، رویکرد مبتنی بر محتوا به اطلاعات آیتم‌ها برای ارائه توصیه به کاربر وابسته بوده [۳] و رویکرد پالایش جمعیت‌شناختی بر این فرض استوار است که افراد با ویژگی‌های جمعیت‌شناختی مشترک (جنسیت، سن، کشور و غیره) ترجیحات مشترکی نیز خواهند داشت [۴]. رویکرد ترکیبی معمولا به صورت ترکیبی از دو رویکرد پالایش مشارکتی و مبتنی بر محتوا یا پالایش مشارکتی و پالایش جمعیت‌شناختی است [۵،۴].

این پژوهش به منظور بهبود عملکرد سیستم‌های توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی مبتنی بر کاربر در مقایسه با تحقیقات پیشین، انجام شده است که در قالب یک مسئله بهینه‌سازی مطرح می‌شود. الگوریتم‌های فراابتکاری به چهار دلیل اصلی سادگی[۶]، انعطاف پذیری[۷]، مکانیسم بدون مشتق[۸] و اجتناب از بهینه محلی[۹] به عنوان نامزدهایی برای حل مسائل چالش‌برانگیز بهینه‌سازی مدرن، بسیار رایج شده‌اند [۶]. همچنین در ادبیات مشاهده می‌شود که محققان به ترکیب الگوریتم‌های فراابتکاری مختلف با هدف ارائه عملکرد بهتر با استفاده از ویژگی‌های برتر این الگوریتم‌ها، پرداخته‌اند [۷]. زیرا محققان دریافته‌اند که ترکیبی ماهرانه از دو رویکرد فراابتکاری می‌تواند عملکرد الگوریتم‌ها را در هنگام برخورد با مسائل دنیای واقعی و مقیاس بزرگ بهبود بخشد [۸]. از طرفی دیگر مطالعات صورت گرفته در زمینه بهبود سیستم‌های توصیه‌گر، روش‌هایی با پیچیدگی محاسباتی و هزینه محاسباتی بالایی ارائه کرده‌اند [۱۱،۱۰،۹،۱] و یا اکثرا الگوریتم‌های فراابتکاری پایه را بررسی نموده‌اند که از نظر جستجوی محلی یا جستجوی سراسری یا هر دو ضعیف هستند [۱۴،۱۳،۱۲،۴]. به‌علاوه، مطالعاتی که الگوریتم‌های پایه را بهبود داده و یا الگوریتم‌های ترکیبی ارائه داده‌اند مشکلاتی در زمینه جستجوی محلی یا جستجوی سراسری و هوشمندشدن الگوریتم‌ها دارند [۱۷،۱۶،۱۵]. بنابراین با توجه به مطالب ذکر شده، در این مقاله یک الگوریتم فراابتکاری ترکیبی جدید جهت بهینه‌سازی عملکرد سیستم‌های توصیه‌گر پالایش مشارکتی ارائه می‌شود. این الگوریتم ترکیب الگوریتم گرگ خاکستری فازی با الگوریتم‌های شیر و تکامل تفاضلی است. نوآوری‌های اصلی پژوهش عبارتند از: ترکیب الگوریتم پایه با الگوریتم تکامل تفاضلی برای بهبود جستجوی سراسری و نیز پیشنهاد معادلاتی برای تنوع‌بخشی به حرکت گرگ‌ها و بهبود جستجوی محلی.

۲- پیشینه پژوهش

تحقیقات زیادی در زمینه سیستم‌های توصیه‌گر توسط محققان مختلف انجام شده است که در ادامه برخی از مطالعات مربوط به سیستم توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی (حافظه)، بررسی شده است. بوبادیلا و همکاران[۱۰] در سال ۲۰۱۱ یک سیستم توصیه‌گر با تابع شباهت جدید وزن‌دار به کمک الگوریتم ژنتیک ارائه دادند [۴]. حاتمی و پاشازاده در سال ۲۰۱۴ از الگوریتم بهینه‌سازی جستجوی فاخته در سیستم توصیه‌گر با تابع شباهت وزن‌دار استفاده کردند [۱۳]. روش ارائه شده توسط نیلاشی و همکاران[۱۱] در سال ۲۰۱۸ براساس پالایش مشارکتی و رویکردهای کاهش ابعاد در خصوص رفع مشکلات مقیاس‌پذیری و پراکندگی است و از تابع شباهت باینری استفاده شده است [۲]. در سال ۲۰۱۹ از الگوریتم‌های K-Means، KNN[۱۲] و ضریب همبستگی پیرسون[۱۳] توسط آهوجا و همکاران[۱۴] استفاده شده است [۱۸]. در مقاله محمدپور و همکاران در سال ۲۰۱۹ رویکرد تکاملی ترکیبی تک هدفی برای خوشه‌بندی آیتم‌ها در سیستم توصیه‌گر پالایش مشارکتی آفلاین پیشنهاد و از تابع شباهت پیرسون استفاده شده است [۱۷]. الحیجاوی و کیلانی[۱۵] در سال ۲۰۲۰ یک سیستم توصیه‌گر پالایش مشارکتی با الگوریتم ژنتیک وابسته به اطلاعات معنایی آیتم‌ها، اطلاعات مربوط به شباهت سطح رضایت میان کاربران، اطلاعات تاریخی رتبه‌دهی ارائه دادند [۱۴]. تابع شباهت پیرسون برای محاسبه شباهت در سیستم توصیه‌گرپالایش مشارکتی توسط لوگش و همکاران[۱۶] در ۲۰۲۰ به کاربرده شده است [۱۵]. لی[۱۷] در ۲۰۲۰ معیار جدیدی برای محاسبه شباهت برای پالایش مشارکتی مبتنی بر کاربر در سیستم‌های توصیه‌گر پیشنهاد داد که از آنتروپی اطلاعات رتبه‌بندی برای هر آیتم استفاده کرده و آن را در معیارهای شباهت مرسوم قرار می‌دهد [۱۹]. توحیدی و دادخواه پالایش مشارکتی مبتنی بر کاربر با استفاده از خوشه‌بندی K-Means بهبودیافته با الگوریتم بهینه‌سازی توده ذرات شتاب‌یافته و الگوریتم جنگل را در سال ۲۰۲۰ مطرح کردند [۲۰]. در سال ۲۰۲۰ وانگ و همکاران[۱۸] چارچوبی برای توصیه برچسب اجتماعی[۱۹] با استفاده از الگوریتم بهینه‌سازی شیر و رویکردهای پالایش مشارکتی پیشنهاد دادند

[۲۱]. ژانگ و همکاران[۲۰] در سال ۲۰۲۰ مکانیزم بهینه‌سازی پالایش مشارکتی دو مرحله‌ای براساس شباهت مبتنی بر اعتماد بین کاربران ارائه دادند [۲۲]. یک سیستم توصیه‌گر اجتماعی ترکیبی[۲۱] با استفاده از شبکه رمزگذار خودکار عمیق[۲۲] و داده های توییتر[۲۳] مربوط به تاثیر اجتماعی هر کاربر، توسط طهماسبی و همکاران در سال ۲۰۲۱ ارائه شد [۲۳]. هوآنگ و همکاران[۲۴] در سال ۲۰۲۳ از روش خوشه‌بندی K-Means و تابع شباهت وزن‌دار در سیستم توصیه‌گر پالایش مشارکتی استفاده کردند که مشکل پراکندگی داده[۲۵] را با کاهش فضای آیتم بهبود بخشیده است [۲۴]. تنوع و صحت سیستم توصیه‌گر پالایش مشارکتی مبتنی بر کاربر براساس روش هسته و بهینه‌سازی چندهدفه[۲۶] توسط ما و همکاران[۲۷] در ۲۰۲۳ بهبود داده شد [۲۵]. یوآن و همکاران[۲۸] در سال ۲۰۲۳ از مدل چندبعدی برای سیستم توصیه‌گر براساس طبقه‌بندی[۲۹] و آنتروپی[۳۰] به منظور بهبود کیفیت پیش‌بینی استفاده کردند [۲۶]. روشی جدید برای اندازه‌گیری شباهت فازی به نام FSM در سیستم‌های توصیه‌گر پالایش مشارکتی توسط شجاعی و صانعی در سال ۱۳۹۹ ارائه شده است. در روش پیشنهادی که از اعداد فازی برای بهبود دقت و کیفیت توصیه‌ها استفاده شده است، مقدار F و فراخوانی و دقت بهبود قابل‌توجهی یافته‌اند [۲۷].

نگوین[۳۱] در سال ۲۰۲۴، یک روش نوین تحت عنوان خوشه‌بندی الهام‌گرفته از زیست در پالایش مشارکتی معرفی نمود. این روش با بهره‌گیری از هوش ازدحامی به دنبال بهبود دقت توصیه‌ها در چارچوب پالایش مشارکتی مبتنی بر کاربر است. در این رویکرد با بهره‌گیری از هوش جمعی، دقت توصیه‌ها در چارچوب‌های پالایش مشارکتی مبتنی بر کاربر اصلاح شد. آزمایشات روی داده مووی‌لنز انجام شد [۲۸].

سیربیلادز و همکاران[۳۲] یک مدل تصمیم‌گیری چندمعیاره مبتنی بر فازی برای بهبود پیش‌بینی در سیستم‌های توصیه‌گر مبتنی بر پالایش مشارکتی ارائه کردند. براساس رویکرد آن‌ها، یک کلاس جدید از عملگرهای تجمیع ساخته شده است که نشان‌دهنده برخی از بسط‌های ترکیبی از عملگرهای میانگین وزنی مرتب، هندسی است. این عملگرهای ساخته‌شده در ارزیابی پیش‌بینی سیستم‌های توصیه‌گر فیلتر مشارکتی فازی استفاده شدند. معیارهای تشخیص متقارن جدید به عنوان برخی از بسط‌های معیارهای تشخیص برای این سیستم مبتنی بر فازی پیشنهاد شدند .داده‌های پروفایل کاربران توسط عملگرهای ساخته‌شده در معیار شباهت جدید تحت محیط زبانی تصویر تجمیع می‌شوند. رویکرد جدید توسعه‌یافته به صورت شماتیک به گونه‌ای توصیف شده است که می‌تواند در هر مدل فازی موجود تعبیه شود. مثالی برای نشان‌دادن نتایج ارائه شده است، که در آن نرم‌افزار طراحی شده برای تجمیع داده‌های پروفایل برای مقایسه شباهت، استفاده از عملگرهای تجمیع کلاسیک جدید و شناخته شده را فراهم می‌کند [۲۹]. یک مطالعه مروری مربوط به روش پالایش مشارکتی با استفاده از یادگیری ماشین و هوش تجاری توسط ابراهیم و همکاران[۳۳] در سال ۲۰۲۵ انجام شد. آن‌ها از ترکیب یادگیری تقویتی و عمیق برای بهبود قابلیت اطمینان پیشنهادات و پاسخگویی به ترجیحات کاربر در سیستم توصیه‌گر استفاده نمودند. علاوه بر آن یک چارچوب جامع برای تجزیه و تحلیل مجموعه داده‌های بزرگ با استفاده از ابزارهای پالایش مشارکتی و هوش تجاری ارائه شد که منجر به بینش‌های عملی در مورد رفتار مشتری، روندهای بازار و عملکرد محصول می‌شود. این ادغام نه تنها فرآیند پیشنهاد را بهبود می‌بخشد، بلکه یک تجربه خرید جالب‌تر و دلپذیرتر را برای کاربران ایجاد می‌کند. در نهایت این مطالعه بر اهمیت تحقیقات مداوم در سیستم‌های توصیه شخصی‌سازی‌شده به منظور بهره‌برداری کامل از فناوری تجارت الکترونیک آینده تأکید کرده است [۳۰]. یک سیستم توصیه‌گر پیشرفته با ترکیب پالایش مشارکتی و تحلیل شبکه‌های اجتماعی به‌منظور افزایش تعامل کاربران توسط سانتوش و همکاران[۳۴] معرفی شد. فیلترینگ مشارکتی با مشکل شروع سرد دست و پنجه نرم می‌کند و رویکردهای مبتنی بر اجتماع ممکن است ترجیحات فردی را نادیده بگیرند. این مقاله یک سیستم توصیه‌گر پیشرفته را معرفی می‌کند که به طور یکپارچه فیلترینگ مشارکتی و تجزیه و تحلیل رسانه‌های اجتماعی را برای ارائه پیشنهادهای شخصی‌سازی‌شده در زمان واقعی ادغام می‌کند. نوآوری در اختصاص وزن‌های مناسب به توصیه‌ها براساس پالایش مشارکتی و تأثیر اجتماعی است که رویکردی جامع و دقیق به پیشنهادهای شخصی‌سازی‌شده ارائه می‌دهد. این روش شامل تعریف اهداف، جمع‌آوری و پیش‌پردازش داده‌ها، پیاده‌سازی سیستم توصیه‌گر ترکیبی، ترکیب رویکردهای شخصی‌سازی و پیاده‌سازی یک موتور در زمان واقعی است. ارزیابی شامل معیارهای کلیدی مانند دقت، صحت، فراخوانی و تعامل کاربر است [۳۱]. بالاموروگان و همکاران[۳۵] یک سیستم توصیه‌گر ترکیبی با هدف بهبود دقت پیش‌بینی و کاهش مشکل شروع سرد در سیستم‌های توصیه‌گر سنتی معرفی کردند. این مدل در پایتون پیاده‌سازی شده و با استفاده از کاوش داده، پردازش، و تجزیه‌وتحلیل بصری، داده‌های موجود را بررسی کرده و مقادیر ازدست‌رفته را با روش KNN جایگزین می‌کند. همچنین، با ایجاد ویژگی‌های مهندسی‌شده، دقت مدل‌های یادگیری ماشین بهبود یافته است. در این تحقیق،

روش‌های مبتنی بر محتوا و پالایش مشارکتی ترکیب شدند. آزمایشات بر روی مجموعه داده نرخ‌گذاری تولید والمرات انجام شد. نتایج نشان دادند که رضایت کاربران با این سیستم توصیه‌گر افزایش یافته و موجب رشد فروش شده است [۳۲]. یک روش مبتنی بر پردازش زبان طبیعی (NLP) و یادگیری ماشین برای حل مشکل شروع سرد در سیستم‌های توصیه‌گر مبتنی بر پالایش مشارکتی توسط میشرا و همکاران[۳۶] ارائه شده است. این مطالعه با تحلیل بازخوردهای کاربران از طریق پردازش زبان طبیعی و ترکیب آن با مدل‌های یادگیری نظارت‌شده و نظارت‌نشده، مشکل کمبود داده‌های اولیه کاربران جدید را برطرف می‌کند. روش پیشنهادی با استفاده از مجموعه داده‌های استاندارد مانند مووی‌لنز، آمازون ریویوز، آی‌ام‌دی‌بی و نتفلیکس پرایز ارزیابی و عملکرد آن با مدل‌های جنگل تصادفی، نایو بیز و رگرسیون لجستیک بررسی شد. همچنین، استفاده از حریم خصوصی تفاضلی توزیع‌شده باعث بهینه‌سازی عملکرد سیستم شده است. این مطالعه نشان می‌دهد که ترکیب NLP با پالایش مشارکتی می‌تواند کیفیت توصیه‌ها را بهبود و شخصی‌سازی را افزایش دهد [۳۳]. بیسول و همکاران[۳۷] یک سیستم توصیه‌گر فیلم پیشرفته با ترکیب پالایش مشارکتی عصبی و تحلیل احساسات برای بهبود دقت و شخصی‌سازی توصیه‌ها در سال ۲۰۲۵ ارائه دادند. این روش با تحلیل نظرات کاربران و تشخیص قطبیت احساسی[۳۸] آن‌ها، دقت پیشنهادها را افزایش داده و مشکلاتی مانند شروع سرد، پراکندگی داده و درک معنایی محدود را کاهش می‌دهد. برخلاف روش‌های سنتی که در مواجهه با تنوع داده و دقت توصیه‌ها دچار مشکل هستند، این سیستم از یادگیری عمیق در پالایش مشارکتی عصبی برای شناسایی الگوهای پنهان در رفتار کاربران استفاده می‌کند. ارزیابی با معیارهای RMSE، MSE و MAE نشان می‌دهد که روش پیشنهادی از پالایش سنتی دقیق‌تر و مقیاس‌پذیرتر است [۳۴].

مهم‌ترین بخش سیستم‌های توصیه‌گر پالایش مشارکتی تابع شباهتی است که برای تعیین شباهت بین هر جفت کاربر استفاده می‌شود و وزن‌های این تابع تأثیر قابل‌توجهی بر کیفیت سیستم توصیه‌گر دارد [۵]. در تحقیقات صورت گرفته در زمینه سیستم‌های توصیه‌گر پالایش مشارکتی یا از توابع شباهت سنتی نظیر پیرسون و کسینوسی استفاده شده یا به اثر وزن در توابع شباهت توجه نشده است [۱۵،۱۷،۱۸،۲۰،۲۱،۲۲،۲۳،۲۵]. توابع شباهت سنتی نظیر پیرسون و کسینوسی پیچیدگی و هزینه محاسباتی بالایی دارند. زیرا محاسبات مربوط به امتیازات داده شده توسط کل کاربران به صورت مجموع و جذر آن‌ها در نظر گرفته شده است. همچنین شباهت بین دو کاربر را با اهمیت یکسان به همه آیتم‌ها ارزیابی می‌کنند که همیشه نتایج خوبی به همراه ندارد [۳۶]. برای غلبه بر این مشکل در این مقاله تابع شباهت ارائه شده توسط بوبادیلا و همکاران در سال ۲۰۱۱ مورد استفاده قرار می‌گیرد [۴]. این تابع شباهت بهتر از توابع شباهت سنتی عمل می‌کند. زیرا اثر وزن و اهمیت امتیاز کاربران به آیتم‌ها را در نظر می‌گیرد، به‌طوری‌که با تنظیم وزن‌ها می‌توان به دقت بیشتر دست یافت [۴]. بنابراین در مقاله حاضر مقدار بهینه وزن‌های تابع شباهت پیشنهادی در قالب یک مسئله بهینه‌سازی توسط یک الگوریتم فراابتکاری جدید تنظیم می‌شود تا همسایگی دقیق‌تری برای کاربر فعال بدست آید. در تحقیق گذشته از الگوریتم گرگ خاکستری فازی ترکیب‌شده با شیر در سیستم توصیه‌گر برای این منظور استفاده شد [۳۶]. در این مقاله، الگوریتم گرگ خاکستری فازی ترکیب‌شده با الگوریتم شیر و تکامل تفاضلی در قالب یک الگوریتم فراابتکاری ترکیبی جدید ارائه می‌شود.

۳- روش‌شناسی پژوهش

پژوهش از حیث هدف، کاربردی و از حیث روش، مدلسازی است. در ادامه سیستم توصیه‌گر پیشنهادی مورد بررسی قرار می‌گیرد.

۳-۱- سیستم توصیه‌گر پیشنهادی

مراحل پیش‌بینی به کمک سیستم توصیه‌گر پیشنهادی به صورت زیر است.

ابتدا شباهت بین زوج کاربران با استفاده از تابع شباهت وزن‌دار ارائه شده توسط بوبادیلا و همکاران محاسبه می‌شود [۴].

$$\mathrm{sim_w(a,u)} = \frac{1}{\mathrm{M-m+1}} \sum_{\mathrm{i=0}}^{\mathrm{M-m}} \mathrm{W^{(i)} V_{a,u}^{(i)}} \qquad (۱)$$

رابطه (۱)، نشان‌دهنده شباهت و در واقع همان میانگین وزن‌دار شده است که با استناد به مقاله‌ی بوبادیلا و همکاران در سال ۲۰۱۱ استفاده شده است [۴]. 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 $\mathrm{a,u}$ است که به صورت $\mathrm{V_{a,u}} = \left(\mathrm{v_{a,u}^{(0)}}, \dots, \mathrm{v_{a,u}^{(M-m)}}\right)$ تعریف می‌شود و تعداد عناصر آن برابر تعداد رتبه‌های امکان‌پذیری است که یک کاربر می‌تواند روی یک آیتم ایجاد کند. هر عنصر $\mathrm{v_{a,u}^{(i)}}$ از بردار $\mathrm{V_{a,u}}$ به صورت کسر $\frac{\mathrm{A}}{\mathrm{B}}$ تعریف می‌شود که در آن B بیان‌گر تعداد آیتم‌های رتبه‌بندی شده توسط هر دو کاربر (یعنی $\mathrm{r_a^{(j)}} \neq 0 \,, \mathrm{r_u^{(j)}} \neq 0$) و

A بیان‌گر تعداد آیتم‌های رتبه‌بندی شده توسط هر دو کاربر است با این شرط که تفاضل مطلق رتبه‌بندی‌های کاربر a وکاربر u برابر i باشد ($|r_a^j - r_u^j| = i$). W بردار وزن و هم‌اندازه با بردار V و نشان‌دهنده اهمیت هرعنصر $V_{a,u}$ در محاسبه شباهت میان دو کاربر است. در مقاله‌ی مرجع وزن در بازه [۱,۱-] قرار گرفته است. وزن ۱+ نشان‌دهنده شباهت بسیار مثبت و وزن ۱- نشان‌دهنده شباهت بسیار منفی است [۴] در این مقاله محدوده وزن‌ها به صورت [۲,۲-] در نظر گرفته شده است.

سپس نزدیک‌ترین همسایه‌ها براساس الگوریتم KNN که رایج‌ترین رویکرد برای محاسبه همسایگی در سیستم‌های توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی است، انتخاب می‌شوند [۳۷].

برای پیش‌بینی رتبه کاربر هدف به یک آیتم خاص از رابطه تجمیع وزنی تعدیل شده[۳۹] /انحراف از میانگین[۴۰] استفاده می‌شود [۳۸].

$$P_a^i = \bar{r}_a + \frac{\sum_{u \in U_i \cap S(a)} sim(a,u).(r_{u,i} - \bar{r}_u)}{\sum_{u \in U_i \cap S(a)} |sim(a,u)|} \quad (۲)$$

در این رابطه $U_i \cap S(a)$ مجموعه‌ای از k نزدیکترین همسایه کاربر a را نشان می‌دهد که آیتم i را رتبه‌بندی کرده‌اند، $r_{u,i}$ رتبه واقعی داده شده توسط همسایه u برای مورد i است و $\bar{r}_a$ و $\bar{r}_u$ میانگین رتبه‌های هر کاربر (a کاربر هدف و u کاربر همسایه) که براساس سابقه رتبه‌بندی آنها محاسبه می‌شود. $r_{u,i}$ رتبه کاربر همسایه u برای آیتم i و $sim(a,u)$ شباهت میان کاربر هدفa و کاربر همسایه u است.

در نهایت، معیارهای ارزیابی میانگین خطای مطلق (MAE) [۳۹]، دقت، فراخوانی و معیار F [۴۰] برای مقایسه پیش‌بینی‌ها و توصیه‌های به دست آمده با رتبه‌بندی واقعی کاربر استفاده می‌شوند. هرچه پیش‌بینی‌ها و توصیه‌ها دقیق‌تر باشد، کیفیت الگوریتم پیشنهادی بهتر است.

با توجه به رابطه (۱) بردار بهینه W بدلیل اینکه تابع شباهت بهینه را ارائه می‌دهد، بر روی بهبود عملکرد سیستم توصیه‌گر تاثیرگذار است. بنابراین در قالب یک مسئله بهینه‌سازی تنظیم می‌شود. همانطور که ذکر شد، برای حل این مسئله از الگوریتم بهینه‌سازی گرگ خاکستری فازی ترکیب‌شده با الگوریتم بهینه‌سازی شیر و تکامل تفاضلی استفاده می‌شود. از میان کلیه‌ی بردارهای W تولید شده توسط الگوریتم پیشنهادی، برداری که تابع هدف یعنی میانگین خطای مطلق(MAE) را کمینه کند، انتخاب می‌شود. در این الگوریتم موقعیت گرگ‌ها معادل با پارامتر وزن (بردار W) هستند. در ادامه الگوریتم فرااابتکاری ترکیبی پیشنهادی بررسی می‌شود.

۳-۲- الگوریتم فرااابتکاری ترکیبی پیشنهادی (IFGWOLOADE)

مراحل طراحی الگوریتم فرااابتکاری ترکیبی پیشنهادی (IFGWOLOADE) به شرح زیر است.

۳-۲-۱- انتخاب الگوریتم پایه

با توجه به برتری الگوریتم‌های بهینه‌سازی فرااابتکاری هوش ازدحامی در حل مسائل بهینه‌سازی و از آنجایی که مساله تعیین وزن‌های بهینه یک مساله پیوسته است، الگوریتم بهینه‌ساز گرگ خاکستری ارائه شده توسط میرجلیلی و همکاران در سال ۲۰۱۴ به عنوان الگوریتم پایه انتخاب شد. میرجلیلی و همکاران در مطالعه خود عملکرد این الگوریتم را از نظر اکتشاف، استخراج، اجتناب از بهینه محلی و همگرایی توسط بیست و نه تابع آزمایش مورد ارزیابی قرار دادند و نتایج نشان داد که الگوریتم بهینه‌ساز گرگ خاکستری قادر به ارائه نتایج بسیار رقابتی در مقایسه با الگوریتم‌های فرااابتکاری شناخته شده از قبیل بهینه‌سازی توده ذرات[۴۱] (به عنوان رویکرد مبتنی بر هوش ازدحامی)، الگوریتم جستجوی گرانشی[۴۲] (به عنوان یک الگوریتم مبتنی بر فیزیک)، الگوریتم های تکامل تفاضلی[۴۳] برنامه‌ریزی سریع تکاملی[۴۴] و استراتژی تکامل[۴۵] (به عنوان الگوریتم‌های تکاملی) است.

۳-۲-۲- فازی‌سازی

با وجود اینکه الگوریتم‌های بهینه‌سازی فرااابتکاری یک انتخاب محبوب برای حل مسائل پیچیده بهینه‌سازی هستند اما مشکل تنظیم پارامتر دارند. از این رو بسیاری از محققان از منطق فازی برای تنظیم پارامترها و دستیابی به نتایج و هم‌گرایی بهتر نسبت به الگوریتم‌های اصلی استفاده کرده‌اند [۴۱]. در خصوص الگوریتم بهینه‌ساز گرگ خاکستری، رودریگز و همکاران[۴۶] (۲۰۱۷) مشخص کردند، بهترین عملکرد الگوریتم زمانی است که از منطق فازی در الگوریتم استفاده شود. همچنین پارامترهای a و C به عنوان پارامترهای اصلی الگوریتم که بیشترین تأثیر را در عملکرد الگوریتم دارند، به عنوان کاندید تنظیم پویا معرفی شدند. در الگوریتم پایه گرگ خاکستری پارامتر a نقش مهمی در تعادل میان جستجوی سراسری و جستجوی محلی دارد و به صورت خطی از ۲ به صفر کاهش می‌یابد. زیرا در ابتدای شروع الگوریتم به دلیل دور بودن از نقطه بهینه و نیاز به جستجوی سراسری مقدار a بزرگ و در انتهای اجرای الگوریتم به علت نیاز به جستجوی محلی a کوچک انتخاب می‌شود. اما مقدار پارامتر C در الگوریتم گرگ خاکستری به صورت تصادفی تغییر می‌کند.

رودریگز و همکاران سیستم استنتاج فازی برای پارامتر a طراحی کردند به شرح زیر: یک ورودی (تکرار) و یک خروجی (پارامتر a) و سه تابع عضویت مثلثی (کم، متوسط، زیاد)، الگوریتم استنتاج ممدانی و فاززدایی مرکز ثقل که در نهایت مشخص شد که پارامتر a زمانی عملکرد بهتری دارد که قوانین فازی در حال کاهش باشند [۴۲]. در الگوریتم پیشنهادی مشابه پارامتر a، پارامتر C نیز با استفاده از منطق فازی به صورت پویا تنظیم می‌شود. در شکل ۱ الی ۳ توابع عضویت نشان داده شده‌اند.

قواعد فازی در جدول ۱ نشان داده شده‌اند.

جدول ۱. قواعد فازی برای تنظیم پارامترهای a و C

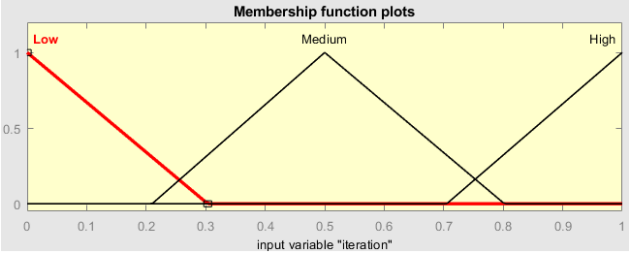
1. If (iteration is Low) then (a is High) (C is High)
2. If (iteration is Medium) then (a is Medium) (C is Medium)
3. If (iteration is High) then (a is Low) (C is Low)

با توجه به جدول ۱ به کمک قواعد فازی ۱ الی ۳، پارامترهای a و C به طور هوشمند تنظیم می‌شوند بطوریکه در تکرارهای ابتدایی نقش اکتشاف و در تکرارهای پایانی استخراج پررنگ است که در نتیجه به تعادل میان جستجوی سراسری و محلی کمک می‌نماید.

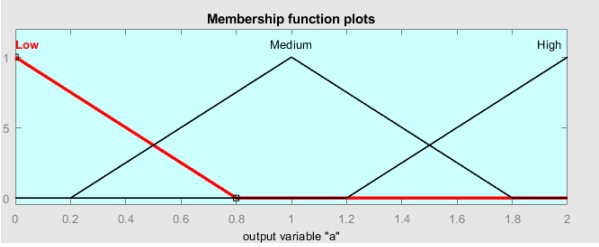
۳-۲-۳- بهبود جستجوی محلی

در این مرحله با هدف بهبود جستجوی محلی، الگوریتم بهینه‌سازی شیر با الگوریتم پیشنهادی ترکیب می‌شود. با توجه به اینکه الگوریتم بهینه‌سازی گرگ خاکستری و بخشی از الگوریتم بهینه‌سازی شیر، الهام گرفته از رفتار شکار است، لذا ترکیب رویکرد شکار این دو الگوریتم در یک الگوریتم موجب تنوع حرکتی عامل‌های جستجو و بهبود جستجوی محلی می‌شود. به بیانی دیگر به ازای احتمال ۰٫۵ درصد به‌روزرسانی موقعیت گرگ‌های امگا نسبت به گرگ‌های آلفا، بتا و دلتا (X_1، X_2 و X_3) توسط رابطه‌ی (۳) (معادلات اصلی الگوریتم گرگ خاکستری) [۶] و در غیراینصورت توسط رابطه‌ی (۵) (معادلات مربوط به فرآیند شکار الگوریتم شیر) انجام می‌شود [۴۳].

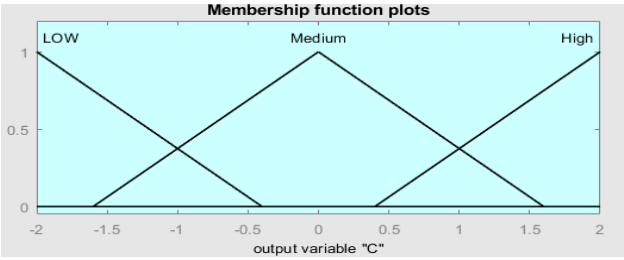
$$\begin{cases} D_\alpha = |C_1 X_\alpha(t) - X(t)| \\ X_1 = X_\alpha - A_1 D_\alpha \end{cases}$$
$$\begin{cases} D_\beta = |C_2 X_\beta(t) - X(t)| \\ X_2 = X_\beta - A_2 D_\beta \end{cases} \quad (۳)$$
$$\begin{cases} D_\delta = |C_3 X_\delta(t) - X(t)| \\ X_3 = X_\delta - A_3 D_\delta \end{cases}$$



شکل۱.توابع عضویت فازی مربوط به ورودی تکرار



شکل ۲. توابع عضویت مربوط به خروجی a



شکل۳. توابع عضویت مربوط به خروجی C

در رابطه (۳)، t نشان‌دهنده تکرار فعلی است وضرایب A_1، A_2 و A_3 براساس a فازی طبق رابطه (۴) تنظیم می‌شوند.

$$A = 2a(t)(rand) - a(t) \quad (۴)$$

$$\begin{aligned} X_1 &= X_\alpha(t) + (rand)(PI_1)\big(X_\alpha(t) - X(t)\big) \\ X_2 &= X_\beta(t) + (rand)(PI_2)\big(X_\beta(t) - X(t)\big) \\ X_3 &= X_\delta(t) + (rand)(PI_3)\big(X_\delta(t) - X(t)\big) \end{aligned} \quad (۵)$$

در رابطه (۵)، موقعیت گرگ‌های آلفا، بتا و دلتا نشان‌دهنده موقعیت شکاری هستند که توسط گرگ‌ها تاکنون یافته شده، عبارت X(t) نیز موقعیت گرگ شکارچی است که به شکار حمله می‌کند و PI نرخ بهبود برازندگی است که به صورت زیر محاسبه می‌شود:

$$PI_1 = \frac{|f(X(t)) - f(X_\alpha(t))|}{f(X_\alpha)}$$
$$PI_2 = \frac{|f(X(t)) - f(X_\beta(t))|}{f(X_\beta)} \quad (۶)$$
$$PI_3 = \frac{|f(X(t)) - f(X_\delta(t))|}{f(X_\delta)}$$

در رابطه (۶) f برازندگی است.

رابطه (۵) براساس معادله شکار الگوریتم شیر نوشته شده است. در این رابطه، گرگ‌ها در معادله اول با توجه به نرخ بهبود برازندگی به سمت گرگ آلفا یعنی بهترین موقعیت و در معادله دوم و سوم نیز به ترتیب به سمت گرگ‌های بتا و دلتا حرکت می‌کنند. با توجه به اینکه در این سه معادله گرگ‌ها به سمت بهترین سه گرگ می‌روند، این حرکت بیشتر به بهبود توانایی جستجوی محلی الگوریتم کمک می‌کند.

در ادامه برای تنوع‌بخشی به حرکت گرگ‌ها در الگوریتم پیشنهادی معادلات زیر برای تعیین موقعیت بعدی آنها پیشنهاد شده است:

$$
\begin{aligned}
&R_4 = rand \\
&if\ \ R_4 > 0.2 \\
&\quad X(t+1) = \frac{X_1 + X_2 + X_3}{3} \\
&elseif\ \ R_4 > 0.1 \\
&\quad X(t+1) = X(t) + 2a(R_5)\big(X_\alpha(t) - X(t)\big) \\
&elseif\ \ it < (MaxIt/2) \\
&\quad X(t+1) = \frac{X_1 + X_2 + X_3}{3} + 4a * randn \\
&\text{else} \\
&\quad X(t+1) = \frac{X_1 + X_2}{2} + (0.1)a * randn \\
&\text{end}
\end{aligned}
\qquad (۷)
$$

رابطه‌ی (۷) به‌روزرسانی موقعیت‌ها مبتنی بر بهترین سه گرگ است که در آن X_1 ، X_2 و X_3 نشان‌دهنده موقعیت گرگ‌های امگا نسبت به گرگ‌های آلفا، بتا و دلتا می‌باشند و $X_{(t+1)}$ موقعیت جدید یک گرگ امگا است که باید به سمت جاییکه رهبران دسته نشان می‌دهند، حرکت کند [۴۲].

همانطور که مشاهده می‌شود موقعیت بعدی گرگ‌ها با احتمال ۰/۸ توسط معادله اصلی الگوریتم گرگ خاکستری، با احتمال ۰/۱ به کمک موقعیت قبلی آنها و یک حرکت تصادفی به سمت گرگ آلفا (این معادله از الگوریتم بهینه سازی توده ذرات[۴۷] ملهم شده است) و با احتمال ۰/۱ و اگر در نصف تکرار اولیه باشیم، به کمک مجموع معادله اصلی گرگ خاکستری با یک عدد تصادفی بزرگ (این عبارت به جستجوی سراسری کمک می‌کند) و در غیر اینصورت اگر در نیمه تکرار نهایی باشیم، از مجموع میانگین موقعیت‌های X_1 و X_2 با یک عدد تصادفی کوچک (این معادله به جستجوی محلی کمک می‌کند زیرا جستجو حول موقعیت‌های گرگ آلفا و بتا انجام شده است) بدست می‌آید که این دو معادله از الگوریتم بهینه‌سازی علف هرز مهاجم[۴۸] الهام گرفته شده‌اند.

۳-۲-۴- بهبود جستجوی سراسری

در الگوریتم طراحی شده تا این مرحله، نیمی از تکرارها به اکتشاف و نیمی دیگر به استخراج اختصاص داده شده است. بنابراین اگر در نیمه اول تکرارها که اکتشاف وجود دارد جواب بهینه سراسری پیدا نشود، در نیمه دوم هم امکان رسیدن به جواب بهینه سراسری وجود ندارد و در نتیجه ممکن است الگوریتم در بهینه محلی گیر کند. روش‌های مختلفی در مقالات برای فرار از بهینه محلی توسط نویسندگان مورد توجه قرار گرفته است. با توجه به کارهای انجام شده، از جمله روش‌هایی که برای مقابله با این مشکل استفاده شده، می‌توان به آشوب و پرواز لوی برای تنوع‌بخشیدن و نیز استراتژی جهش الگوریتم تکامل تفاضلی اشاره کرد. با استناد به مقاله فو و همکاران[۴۹] در سال ۲۰۲۴ در خصوص الگوریتم پرندگان منشی[۵۰]، می‌توان بیان کرد که یکی از الگوریتم‌هایی که به سادگی در بهینه محلی به دام نمی‌افتد الگوریتم تکامل تفاضلی است [۴۴]. همچنین در مقاله وی و یو[۵۱] در سال ۲۰۱۸ از الگوریتم تکامل تفاضلی برای بهبود الگوریتم جستجوی فاخته به منظور جلوگیری از به دام افتادن در بهینه محلی استفاده شده است [۴۵]. با توجه به اینکه الگوریتم تکامل تفاضلی در موقعیت‌یابی مینیمم سراسری خوب است یعنی به دلیل عملگر جهش[۵۲]، قادر به کشف فضای جدید است [۸]، بنابراین از آن در الگوریتم پیشنهادی به منظور بهبود توانایی جستجوی سراسری الگوریتم استفاده می‌شود. به کمک عملگرهای جهش رابطه‌ی (۸) و تقاطع دو جمله‌ای[۵۳] رابطه‌ی (۹) در تکامل تفاضلی، جهش و تقاطع حول موقعیت فعلی گرگ‌ها اتفاق می‌افتد.

$$Y = a + \beta(b - c) \qquad (۸)$$

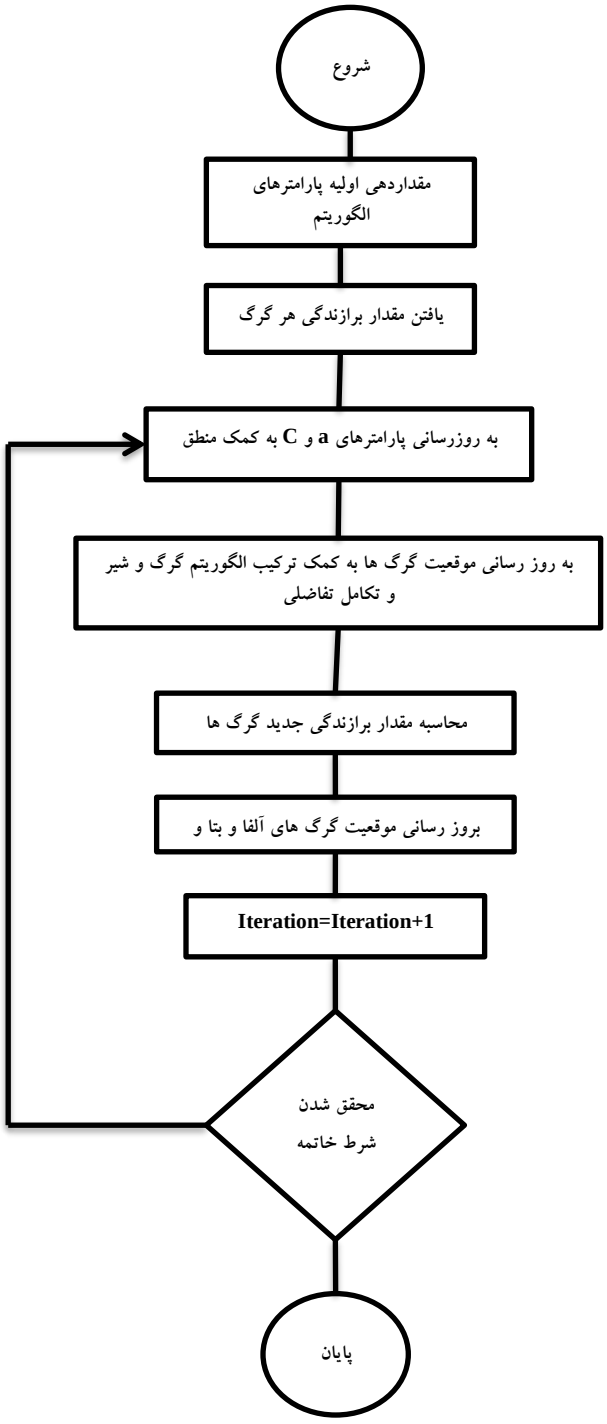
که در آن a، b و c نشان‌دهنده سه موقعیت انتخاب شده به صورت تصادفی است. عبارت β نشان‌دهنده‌ی یک عدد تصادفی با توزیع یکنواخت است.

$$z_j = \begin{cases} y_j; & r_j \le p_{CR}\ or\ j = randi([1\ n]) \\ x_j; & otherwise \end{cases} \qquad (۹)$$

در معادله (۹)، j یک بعد تصادفی انتخاب شده از مقدار ابعاد کلی مسئله n است. عبارت $randi([1\ n])$ یک عدد تصادفی انتخاب شده در بازه [1,n] است و برای این اعمال شده است که حداقل یک پارامتر برای ساخت بردار موقعیت z از y در نظر گرفته شود. عبارت p_{CR} احتمال تقاطع است که برابر با ۰/۴ در نظر گرفته شده است. اگر شرط اول برقرار شود موقعیت جدید برای بعد j انتخاب می‌شود و در غیر اینصورت موقعیت برای بعد j تغییر نمی‌کند.

فلوچارت الگوریتم پیشنهادی در شکل ۴ نشان داده شده است.

در بخش مقداردهی اولیه الگوریتم پارامترهای ثابت آن شامل اندازه جمعیت، تعداد تکرار مقداردهی می‌شوند. پارامتر a و C مربوط به الگوریتم گرگ خاکستری به کمک قواعد فازی تنظیم می‌شود.



شکل ۴. فلوچارت الگوریتم فراابتکاری ترکیبی پیشنهادی

۴- یافته‌های پژوهش

در این بخش نتایج مربوط به ارزیابی الگوریتم ترکیبی پیشنهادی بر مبنای توابع محک و نیز عملکرد سیستم توصیه‌گر براساس میانگین خطای مطلق و معیارهای دقت[۵۴]، فراخوانی[۵۵] و F[۵۶] آورده شده است.

مجموعه‌داده مووی‌لنز[۵۷] که یکی از محبوب‌ترین مجموعه داده‌های مورد استفاده برای توصیه به ویژه در رویکرد پالایش مشارکتی است، در این پژوهش مورد بررسی قرار گرفته است. این مجموعه‌داده شامل ۱۰۰۰۰۰ امتیاز است که توسط ۹۴۳ کاربر به ۱۶۸۲ فیلم داده شده است. کاربران ترجیحات خود را برای فیلم‌ها در قالب رتبه‌بندی پنج ستاره‌ای مشخص می‌کنند [۴]. امتیاز کاربران با ساختار 5-Fold، (u1, u2,… u5)، به دو قسمت تقسیم شده به طوری که ٪۸۰ داده‌ها (۸۰۰۰۰ امتیاز) برای مجموعه آموزش، و ٪۲۰ داده‌ها (۲۰۰۰۰) جهت مجموعه آزمایش درنظرگرفته شده و روش اعتبارسنجی متقابل 5-Fold استفاده شده است. لازم به ذکر است که در این مقاله برای ارزیابی از تمام فولدها استفاده شده ولی فولدهای اول و پنجم به دلخواه بیشتر مورد بررسی قرار گرفته اند.

۴-۱- ارزیابی توابع محک

توابع محک معروف آکلی[۵۸]، گریوانک[۵۹] ، رَستریگِن[۶۰]، روزنبروک[۶۱] و اِسفیر (کُره)[۶۲] و ۲۵ تابع محک دیگر برای ارزیابی الگوریتم پیشنهادی در نظر گرفته شده‌اند بطوریکه توابع newf1 الی newf6 از CEC2022 و توابع newf7 الی newf10 از CEC 2013 انتخاب شده‌اند.

نتایج مقایسه میان الگوریتم پیشنهادی با الگوریتم گرگ خاکستری و بهینه‌سازی توده ذرات و نیز الگوریتم گرگ خاکستری فازی ترکیب‌شده با شیر [۳۶] در جدول ۲الف – ۲ه آورده شده است. برای تمام الگوریتم‌ها پارامترهای اصلی شامل اندازه جمعیت، تعداد تکرار و تعداد اجراها به ترتیب برابر با ۵۰۰، ۲۰۰ و ۵۰ در نظر گرفته شده است. براساس تحقیقات اخیر مقالات مشابه [۴۴، ۴۶-۵۱] اندازه ابعاد مسئله ۱۰۰ فرض شده و تنها تابع Drop با دو بعد مورد بررسی قرار گرفته است. زیرا خود این تابع دو بعدی است و نمی‌توان ابعاد آن را افزایش داد. برای توابع محک Hybrid1، Hybrid2، Hybrid3 و تابع Katsura به دلیل پیچیدگی زیاد، ۲۰ بعد انتخاب شده است.

به علت ابعاد بالای مسئله، محدوده جستجو برای توابع محک به جز تابع محک Schwefel به صورت [-۵,۵] در نظر گرفته شده

است. برای تابع Schwefel بازه جستجو در محدوده [۴۰۰,۵۰۰] است. داده‌های جدول ۲، مقدار میانگین به ازای کل اجراها (Mean)، بهترین مقدار (Min) و بدترین مقدار (Max) را نشان می‌دهند.

طبق جدول ۲-الف، بهترین مقدار میانگین تابع اِسفیر توسط الگوریتم پیشنهادی برابر با ۱/۵۹۴۱e-۰۷ است در حالیکه به‌ازای الگوریتم‌های گرگ خاکستری، توده ذرات و گرگ خاکستری فازی غنی شده با الگوریتم بهینه‌سازی شیر [۳۶] به ترتیب مقادیر ۱۰/۷۸۵، ۰/۰۱۸۴۰۵ و ۱/۰۵۷e-۰۵ به‌دست آمده است. همچنین برای تابع پیچیده‌تر آکلی، میانگین به‌ازای الگوریتم پیشنهادی برابر با ۱/۰۱۵۳۵ است، در حالیکه این مقدار توسط الگوریتم‌های مقایسه‌ای به ترتیب ۲/۵۷۷۸ و ۱/۲۹۸۵ و ۱/۰۸۰۴ شده است. برای سایر توابع نیز، الگوریتم پیشنهادی در کمینه‌سازی از نظر میانگین، مینیمم و ماکزیمم از سه الگوریتم دیگر، عملکرد بهتری داشته است.

جدول ۲.الف. مقایسه الگوریتم پیشنهادی با سایر الگوریتم‌ها براساس توابع محک Sphere،Rosenbrock،Rastrigin،Griewank،Ackley

الگوریتم		تابع محک				
		Sphere	Rosenbrock	Rastrigin	Griewank	Ackley
گرگ خاکستری	Mean	۱۰/۷۸۵	۲۷۳۸/۶	۵۵۰/۰۶	۰/۴۹۸۵۴	۲/۵۷۷۸
	Min	۷/۰۹۳۵	۱۸۶۱/۸	۳۶۴/۹	۰/۲۸۵۷۵	۱/۲۰۹۵
	Max	۱۵/۲۸۷	۴۳۳۷/۲	۹۵۲/۱۴	۰/۵۶۱۵۹	۳/۶۴۲۳
توده ذرات	Mean	۰/۰۱۸۴۰۵	۳۲/۳۳۱	۶۰۵/۵۸	۰/۰۰۱۰۴۹	۱/۲۹۸۵
	Min	۰/ ۰۰۶۵۵۷	۲/۰۱۹۹	۵۰۳/۳۷	۰/۰۰۰۱۸۶۷	۰/۴۷۶۹
	Max	۰/ ۰۳۹۶	۱۰۰/۷۸	۶۹۵/۳۳	۰/۰۷۸۸	۲/۴۰۴
گرگ خاکستری فازی غنی شده با شیر[۳۶]	Mean	۱/۰۵۷e-۰۵	۱۸/۳۴۱	۴۷۱/۹۹	۰/۰۰۰۷۹۳۸۳	۱/۰۸۰۴
	Min	۹/۴۶۷۳e-۰۶	۰/ ۰۰۶۸۰۰۲	۳۳۴/۳۱	۲/۴۵۵۵e-۰۷	۰/۳۹۵۴
	Max	۱/۱۲۵۹e-۰۵	۲۰/۰۵۶	۵۲۱/۳۳	۰/۰۱۹۶۹	۲/۲۴۰۲
گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی	**Mean**	**۱/۵۹۴۱e-۰۷**	**۷/۹۴۷۵**	**۱۷۹/۱۹**	**۰/۰۰۰۵۹**	**۱/۰۱۵۳۵**
	Min	**۱/۴۳۱۴e-۰۷**	**۶/۵۰۲۴e-۰۵**	**۱۱۹/۴**	**۳/۰۲۷e-۰۹**	**۰/۳۰۱۲**
	Max	**۱/۸۲۳۷e-۰۷**	**۱۰/۳۲۵**	**۲۶۹/۶۳**	**۰/۰۱۲۳۲۱**	**۱/۹۶۴**

جدول ۲. ب. مقایسه الگوریتم پیشنهادی با سایر الگوریتم‌ها براساس توابع محک Happycatfcn،Katsura،Elliptic،Discus،BentCigar

الگوریتم		تابع محک				
		Bent Cigar	Discus	Elliptic	Katsura	Happycatfcn
گرگ خاکستری	Mean	۱/۱۸۹۵ e+۰۷	۵۴۸/۰۸	۱/۳۸۳ e+۰۶	۲۳۵/۶۱	۰/۳۴۰۷۹
	Min	۷/۹۰۱۸ e+۰۶	۵۰۳/۷۸	۱/۰۹۶۲ e+۰۶	۱۹/۷۸۷	۰/۲۴۲۵۸
	Max	۱/۴۶۹۱ e+۰۷	۶۲۹/۵۳	۱/۸۶۲۸۸ e+۰۶	۱۰۸۶/۹	۰/۳۹۹
توده ذرات	Mean	۱۵۵۷۷	۰/۱۳۷۶	۴۷۲/۸۳	۰/۲۷۷۸	۰/۴۲۳۰۶
	Min	۵۴۰۴/۲	۰/۱۲۵۲۴۹	۳۴۲/۰۵	۰/۰۳۰۶	۰/۳۴۸۱۱
	Max	۲۷۳۹۱	۰/۲۴۷۸	۶۹۳/۲	۰/۴۳۵	۰/۵۱۷۸
گرگ خاکستری فازی غنی شده با شیر[۳۶]	Mean	۲۴/۱۵	۰/۰۴۹	۴۲۲	۰/۰۱۶۷	۰/۳۰۹۰۴
	Min	۱۲/۷۷۷	۰/۰۰۹۸۷۶	۲۹۱	۰/۰۰۸۳۲	۰/۱۹۳
	Max	۳۶/۲۹۲	۰/۱۶۵۶	۴۹۷	۰/۰۶۵۱	۰/۳۳۷
گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی	**Mean**	**۱۲/۳۶۹**	**۰/۰۲۳۹۴۱**	**۲۹۵/۲۹**	**۰/۰۱۱۸۹**	**۰/۱۵۳**
	Min	**۰/۲۴۶۳۱**	**۰/۰۰۸۵۴۶۷**	**۱۸۵/۵**	**۰/۰۰۴۵۹۹۱**	**۰/۱۰۵۱**
	Max	**۳۳/۴۹۸**	**۰/۰۲۹۵**	**۴۰۳/۸۸**	**۰/۰۲۶۰۹۳**	**۰/۲۰۲**

جدول ۲. ج. مقایسه الگوریتم پیشنهادی با سایر الگوریتم‌ها براساس توابع محک Zhakharov،Schwefel،Drop،EF8F2_func،HGBat

الگوریتم		تابع محک				
		HGBat	EF8F2_func	Drop	Schwefel	Zhakharov
گرگ‌خاکستری	Mean	۹/۹۶۳۷	۲۶۰/۳۱	۰/۰۲۵۵	۱۴۴/۵۳	۹۲/۲۶۸
	Min	۱/۱۴۲	۱۴۵/۴۸	۲/۲۸۱۴ e-۰۷	۱۱۸/۶۳	۸۳/۳۵۶
	Max	۴۳/۲۲۴	۴۸۴/۸	۰/۱۶۷	۱۷۴/۱۱	۱۰۰/۹۱
توده‌ذرات	Mean	۱/۳۹۸۴	۱۵۲/۱۸	۰/۰۱۷۵	۰/۳۵۶۲۹	۱۴۱/۵۶
	Min	۰/۷۹۴	۴۶/۸۲۳	۱/۱۶۴ e-۰۸	۰/۱۰۷۳۱	۸۹/۹۹۴
	Max	۳/۳۸۶۵۸	۴۶۷/۸۷۴	۰/۰۸۴۲	۰/۶۸۷۳۱	۲۰۷/۶۲
گرگ‌خاکستری‌فازی غنی‌شده‌باشیر[۳۶]	Mean	۰/۳۹۴	۱۴۰/۲۵	۰/۰۱۵۳	۱/۷۸ e-۰۴	۲۴/۸۴۱
	Min	۰/۲۵۳	۳۵/۱۲	۳/۵۴۲۵ e-۱۱	۵/۲۱ e-۰۵	۱۵/۴۱۵
	Max	۰/۳۹۴	۳۹۶/۲۵	۰/۰۷۲۴	۷/۱۳۲ e-۰۴	۳۶/۹۲۱
گرگ‌خاکستری‌فازی ترکیب‌شده‌باشیر و تکامل تفاضلی	**Mean**	**۰/۳۴۳۳**	**۱۳۱/۷۲**	**۰/۰۱۲۷**	**۲/۰۷ e-۰۸**	**۱۷/۹۴۱**
	Min	**۰/۲۱۲۸۹**	**۲۷/۱۲**	**۷/۷۳۱۶ e-۱۳**	**۱/۷۳۳۹ e-۰۸**	**۷/۲۷۲**
	Max	**۰/۳۷۲**	**۳۷۵/۸**	**۰/۰۶۳۷**	**۲/۵۲۸ e-۰۸**	**۲۸/۹۸۶**

جدول ۲. د. مقایسه الگوریتم پیشنهادی با سایر الگوریتم‌ها براساس توابع محک camel3،beale،Hybrid3،Hybrid2،Hybrid1

الگوریتم		تابع محک				
		Hybrid1	Hybrid2	Hybrid3	beale	camel3
گرگ‌خاکستری	Mean	۲/۲۰۸۳ e+۰۶	۰/۲۶۴۵۱	۳/۳۰۱۸ e+۰۵	۳/۱۸۷۳ e-۰۸	۱/۵۵۱۱ e-۰۷
	Min	۱/۲۵۲۵ e+۰۶	۰/۰۵۲۷	۲/۱۳۳۲ e+۰۵	۴/۰۶۳۸ e-۰۹	۳/۲۲۵۵ e-۰۸
	Max	۳/۶۹۹۲ e+۰۶	۰/۶۶۲۸۹	۴/۰۷۵۸ e+۰۵	۷/۹۳۸۳ e-۰۸	۳/۹۰۶ e-۰۷
توده‌ذرات	Mean	۳/۰۶۸۷ e+۰۴	۱/۱۲۶۶ e-۰۴	۴/۰۹۹۸ e+۰۳	۳/۰۹۲۴ e-۰۶	۴/۱۰۴۸ e-۰۸
	Min	۹/۷۷۶۷ e+۰۳	۷/۴۸۵۱ e-۰۶	۹/۱۱۳۳ e+۰۲	۲/۲۹۳۷ e-۰۷	۱/۵۵۸ e-۰۹
	Max	۵/۹۸۶۵ e+۰۵	۲/۲۵۷۱ e-۰۳	۹/۰۶۶۷ e+۰۴	۱/۲۲۰۵ e-۰۵	۱/۲۹۲۲ e-۰۷
گرگ‌خاکستری‌فازی غنی‌شده‌باشیر[۳۶]	Mean	۱۴۴/۹	۴/۴۱ e-۰۵	۱۴۷/۲	۲/۴۷۶ e-۰۹	۱/۳۵ e-۱۲
	Min	۲۶۹/۴	۳/۱۹۷۵ e-۰۶	۵/۵۳۸	۲/۹۰ e-۱۱	۹/۹۴ e-۱۳
	Max	۳۹۱/ ۶۹	۵/۴۸ e-۰۴	۲۸۸/۴۳	۱/۱۴۹۳ e-۰۸	۳/۷۱۸ e-۱۲
گرگ‌خاکستری‌فازی ترکیب‌شده‌باشیر و تکامل تفاضلی	**Mean**	**۲۷/۹۶۴**	**۵/۲۱۲۱ e-۰۷**	**۸/۷۲۴۷**	**۲/۰۳۹۵ e-۱۳**	**۹/۰۲۷۹ e-۱۴**
	Min	**۷/۳۷۲۱**	**۳/۲۹۹۸ e-۰۷**	**۰/۳۸۱**	**۴/۲۲۸۱ e-۱۴**	**۱/۴۷۰۲ e-۱۴**
	Max	**۷۷/۷۰۴**	**۶/۹۴۸۵ e-۰۷**	**۲۷/۶۹۸**	**۴/۹۳۲۱ e-۱۳**	**۲/۷۵۹۳ e-۱۳**

جدول ۲. و. مقایسه الگوریتم پیشنهادی با سایر الگوریتم‌ها براساس توابع محک newF5،newF4،newF3،newF2،newF1

الگوریتم		تابع محک				
		newF1	newF2	newF3	newF4	newF5
گرگ خاکستری	Mean	۱۵۱/۲۵	۴۰۴۷۴	-۴۵۴/۶	۰/۰۷۱۹۵۲	۱/۲۵۷۸
	Min	۱۳۷/۹۴	۴۰۴۵۳	-۴۶۵	۰/۰۶۶۴۶	۰/۹۵۶۸۹
	Max	۱۶۰/۷۹	۴۰۵۱۰	-۴۴۵	۰/۰۸۳۷۷	۱/۴۱۸۶
توده ذرات	Mean	۱۳۱/۳۵	۴۰۴۱۲	-۴۹۱/۶	۰/۰۴۶۳	۰/۲۶۲
	Min	۱۰۳/۰۷	۴۰۴۰۸	-۴۹۵	۰/۰۲۲۳۵	۰/۱۹۳۲
	Max	۱۶۵/۹۲	۴۰۴۱۸	-۴۹۰	۰/۰۶۶۱	۰/۸۱۵
گرگ خاکستری فازی غنی شده با شیر[۳۶]	Mean	۱۲۵/۶۹	۴۰۳۸۸	-۴۹۹/۴	۰/۰۰۸۳۳	۰/۰۱۰۲
	Min	۱۰۲/۲۵	۴۰۳۸۳	-۵۰۰	۹/۷۷۸e-۰۶	۹/۹۷e-۰۶
	Max	۱۴۷/۵۸	۴۰۴۰۰	-۴۹۸	۰/۰۱۸۶۶	۰/۰۲۳۲
گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی	**Mean**	**۱۰۸/۷۴**	**۴۰۳۸۱**	**-۴۹۹/۸**	**۱/۲۷۴۲e-۰۷**	**۱/۴۳۵۱e-۰۷**
	Min	**۹۴/۲۲**	**۴۰۳۸۱**	**-۵۰۰**	**۱/۰۸۱۲e-۰۷**	**۱/۳۵۳۹e-۰۷**
	Max	**۱۲۸/۸۴**	**۴۰۳۸۱**	**-۴۹۹**	**۱/۴۷۲۱e-۰۷**	**۱/۵۳۵۷e-۰۷**

جدول ۲. ه. مقایسه الگوریتم پیشنهادی با سایر الگوریتم‌ها براساس توابع محک newF10، newF9، newF8، newF7،newF6

الگوریتم		تابع محک				
		newF6	newF7	newF8	newF9	newF10
گرگ خاکستری	Mean	۲۳/۸۳۸	۳۶/۴۹۳	۱۰۰/۹۵	۱۶۰/۹۱	۱/۶۶۲۵
	Min	۱۵/۸۴۵	۳۵/۹۸۲	۸۵/۴۴۷	۱۲۲/۴۸	۱/۳۵۱۴
	Max	۳۰/۸۷۱	۳۷/۱۳۹	۱۱۳/۱۹	۱۹۵/۳	۱/۸۳۶
توده ذرات	Mean	۱۲۴/۰۵	۳۴/۲۷	۸۰/۵۱۱	۰/۱۶۲۶	۱/۳۸
	Min	۹۳/۱۱۱	۳۴/۲۶۵	۷۰/۴۸۶	۰/۱۰۲۹	۰/۵۵۷
	Max	۱۷۴/۷۳	۳۴/۲۷۴	۹۳/۳۳۳	۰/۲۸۶	۳/۳۷
گرگ خاکستری فازی غنی شده با شیر[۳۶]	Mean	۲۱/۷۲	۳۴/۲۶۲	۷۵/۶۷	۰/۱۵۲	۰/۶۴
	Min	۱۳/۵۸	۳۴/۲۶۲	۶۸/۵۲	۰/۰۷۳۶	۰/۵۱
	Max	۲۸/۳۹	۳۴/۲۶۲	۸۷/۳۱	۰/۲۶۲	۰/۹۶
گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی	Mean	**۱۹/۸۱**	**۳۴/۲۶۲**	**۷۲/۸۲**	**۰/۰۰۱۲۶**	**۰/۴۴۱۹**
	Min	**۱۰/۰۲**	**۳۴/۲۶۲**	**۶۲/۸۸**	**۰/۰۰۱۲۵**	**۰/۲۵۹۷**
	Max	**۲۴/۵۶**	**۳۴/۲۶۲**	**۸۴/۳۵**	**۰/۰۰۱۲۸**	**۰/۷۳**

۴-۲- ارزیابی سیستم توصیه‌گر

در این بخش، نتایج مربوط به سیستم توصیه‌گر آورده شده است. از میان ۵ فولد موجود در پایگاه داده مووی‌لنز، فولدهای ۱ و ۵ به طور دلخواه برای ارزیابی تاثیرات تعداد توصیه و تعداد همسایگی بر معیارها انتخاب شده‌اند. مقایسه براساس میانگین خطای مطلق (MAE) نیز به‌ازای تمامی فولدها انجام شده است. میانگین MAE کل فولدها به منظور مقایسه عادلانه با تحقیقات مشابه، محاسبه و مقایسات صورت گرفته است. در ادامه نتایج این بخش ارائه شده است.

برای ارزیابی سیستم توصیه‌گر روی فولد u_5، ابتدا ماتریس v محاسبه و سپس همانطور که توضیح داده شد، یک بردار W به صورت مجهول به‌عنوان وزن در نظر گرفته شده است. در رابطه‌ی (۱) بازه‌ی اندیس سیگما از ۰ تا M-m تعریف شده است و چون m=1 (کمترین امتیاز ممکن) و M=5 (بیشترین امتیاز ممکن) است، عملگر سیگما پنج جمله را با یگدیگر جمع می‌کند و به همین دلیل ۵ وزن مورد نیاز است. برای الگوریتم پیشنهادی، محدوده بردار W متفاوت با کارهای مشابه، با هدف تضمین پوشش جامع محدوده‌ی موردنیاز جستجو به صورت زیر تعیین شده است:

$$WMin = [1 \;\; 0.2 \;\; -0.5 \;\; -1.5 \;\; -2]$$
$$WMax = [2 \;\; 1 \;\; 0.5 \;\; -0.5 \;\; -1] \quad (۱۰)$$

الگوریتم‌های بهینه‌سازی گرگ خاکستری، توده ذرات و گرگ خاکستری فازی ترکیب‌شده با شیر [۳۶]، با محدوده‌ی W متفاوتی مطابق با مقاله مرجع [۴] اجرا شده‌اند که عبارتند از:

$$WMin = [0.6 \;\; 0.2 \;\; -0.2 \;\; -0.6 \;\; -1]$$
$$WMax = [1 \;\; 0.6 \;\; 0.2 \;\; -0.2 \;\; -0.6] \quad (۱۱)$$

شبیه‌سازی‌ها با درنظرگرفتن k=175، اجرا شد. برای مسئله سیستم توصیه‌گر اندازه جمعیت و تعداد تکرار برابر با ۱۰ در نظر گرفته شد. زیرا زمان اجرا با اندازه تکرار و جمعیت بیشتر خیلی طولانی خواهد شد و با این تنظیمات می‌توان به جواب رسید. مقدار W بدست آمده برای الگوریتم پیشنهادی و الگوریتم‌های دیگر به صورت زیر است:

$$wIFGWOLIONDE = [1.0001 \;\; 0.6100 \;\; -0.4414 \;\; -1.400 \;\; -1.85]$$
$$wIFGWOLION = [0.6801 \;\; 0.5246 \;\; 0.1175 \;\; -0.3143 \;\; -0.9882]$$
$$wPSO = [0.7687 \;\; 0.3903 \;\; -0.1519 \;\; -0.4246 \;\; -0.8458]$$
$$wGWO = [0.6072 \;\; 0.4183 \;\; -0.1043 \;\; -0.5756 \;\; -0.929] \quad (۱۳)$$

در جدول ۳ مقدار تابع هزینه بدست‌آمده به ازای تمام الگوریتم‌ها آورده شده است و مشاهده می‌شود که میانگین خطای مطلق بدست آمده از الگوریتم پیشنهادی در مقایسه با سایر الگوریتم‌ها کمتر است.

جدول ۳- مقایسه معیار MAE الگوریتم پیشنهادی با الگوریتم‌های پایه(فولدu5)

الگوریتم	MAE
گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی	**۰/۴۸۷۸**
گرگ خاکستری فازی غنی شده با الگوریتم بهینه‌سازی شیر[۳۶]	۰/۴۹۱۶
گرگ خاکستری	۰/۵۴۹۵
توده ذرات	۰/۵۵۷۳

در جدول‌های ۴-۶ نتایج مقایسه میان الگوریتم پیشنهادی با الگوریتم‌های بهینه‌سازی گرگ خاکستری و توده ذرات براساس معیارهای دقت، فراخوانی و F با تعداد توصیه N و تعداد ۱۷۵ نزدیکترین همسایه (k=175) نشان داده شده است. با درنظرگرفتن اینکه الگوریتم پیشنهادی در سه معیار فراخوانی، دقت و F به ازای تمام Nها، مقادیر بزرگتری بدست آورده، می‌توان نتیجه گرفت که عملکرد بهتری در مقایسه با دو الگوریتم دیگر داشته است.

جدول۴- مقایسه معیاردقت الگوریتم پیشنهادی و الگوریتم‌های پایه با k=175 (فولدu5)

	گرگ خاکستری	توده ذرات	گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی
	Precision	Precision	Precision
N=2	۰/۹۷۸۳	۰/۹۷۳	۰/۹۸۷۸
N=5	۰/۹۶۹۹	۰/۹۶۷۸	۰/۹۸۱۱
N=10	۰/۹۴۸۶	۰/۹۴۵۸	۰/۹۶۳۶
N=15	۰/۹۱۸۱	۰/۹۱۵۱	۰/۹۳۷۲
N=20	۰/۸۷۹۵	۰/۸۷۵۸	۰/۹۰۱۴
N=25	۰/۸۳۷۷	۰/۸۳۳۹	۰/۸۵۸۲
N=30	۰/۷۹۷۳	۰/۷۹۳۸	۰/۸۱۸۶
N=35	۰/۷۶۰۵	۰/۷۵۷۷	۰/۷۸۲۳
N=40	۰/۷۲۷۷	۰/۷۲۵۲	۰/۷۴۹۹
N=45	۰/۶۹۸۱	۰/۶۹۵۷	۰/۷۲۰۰
N=50	۰/۶۶۹۷	۰/۶۶۷۶	۰/۶۹۲۱
N=55	۰/۶۴۳۰	۰/۶۴۱۳	۰/۶۶۶۳
N=60	۰/۶۱۸۹	۰/۶۱۶۸	۰/۶۴۲۲
N=65	۰/۵۹۶۲	۰/۵۹۴۳	۰/۶۱۹۶
N=70	۰/۵۷۵۴	۰/۵۷۳۰	۰/۵۹۸۹
N=75	۰/۵۵۵۵	۰/۵۵۳۳	۰/۵۷۹۲
N=80	۰/۵۳۷۳	۰/۵۳۵۱	۰/۵۶۱۳
N=85	۰/۵۲۰۵	۰/۵۱۸۵	۰/۵۴۴۳
N=90	۰/۵۰۴۶	۰/۵۰۲۷	۰/۵۲۸۲
N=95	۰/۴۸۹۴	۰/۴۸۷۵	۰/۵۱۳۳
N=100	۰/۴۷۵۳	۰/۴۷۳۵	۰/۴۹۹۳

جدول۵- مقایسه معیارفراخوانی الگوریتم پیشنهادی و الگوریتم‌های پایه با k=175 (فولدu5)

	گرگ خاکستری	توده ذرات	گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی
	Recall	Recall	Recall
N=2	۰/۱۰۰۸	۰/۱۰۰۴	۰/۱۰۳۴
N=5	۰/۲۳۴۶	۰/۲۳۴۲	۰/۲۴۱۴
N=10	۰/۴۱۵۹	۰/۴۱۴۵	۰/۴۲۶۳
N=15	۰/۵۳۷۵	۰/۵۳۶۳	۰/۵۵۰۵
N=20	۰/۶۲۰۷	۰/۶۱۸۶	۰/۶۳۵۱
N=25	۰/۶۷۹۰	۰/۶۷۶۸	۰/۶۹۳۳
N=30	۰/۷۲۴۵	۰/۷۲۲۶	۰/۷۴۰۳
N=35	۰/۷۶۱۶	۰/۷۶۰۰	۰/۷۷۸۴
N=40	۰/۷۹۱۷	۰/۷۹۰۳	۰/۸۰۹۶
N=45	۰/۸۱۶۳	۰/۸۱۴۸	۰/۸۳۴۶
N=50	۰/۸۳۵۹	۰/۸۳۴۷	۰/۸۵۴۹
N=55	۰/۸۵۲۴	۰/۸۵۱۳	۰/۸۷۱۹
N=60	۰/۸۶۶۸	۰/۸۶۵۴	۰/۸۸۶۵

ادامه‌ی جدول ۵

	گرگ خاکستری	توده ذرات	گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی
N=65	۰/۸۷۹۲	۰/۸۷۸۰	**۰/۸۹۹۴**
N=70	۰/۸۸۹۸	۰/۸۸۸۴	**۰/۹۱۰۲**
N=75	۰/۸۹۹۰	۰/۸۹۷۸	**۰/۹۱۹۸**
N=80	۰/۹۰۷۵	۰/۹۰۶۳	**۰/۹۲۸۴**
N=85	۰/۹۱۵۱	۰/۹۱۴	**۰/۹۳۵۹**
N=90	۰/۹۲۱۵	۰/۹۲۰۶	**۰/۹۴۲۴**
N=95	۰/۹۲۶۹	۰/۹۲۶۱	**۰/۹۴۸۱**
N=100	۰/۹۳۱۹	۰/۹۳۱۰	**۰/۹۵۳۳**

جدول ۶- مقایسه معیار F الگوریتم پیشنهادی و الگوریتم‌های پایه با k=175 (فولدu5)

	گرگ خاکستری	توده ذرات	گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی
	F	**F**	**F**
N=2	۰/۱۶۷۷	۰/۱۶۷۱	**۰/۱۷۰۹**
N=5	۰/۳۳۴۸	۰/۳۳۴۱	**۰/۳۴۳۴**
N=10	۰/۵۰۵۹	۰/۵۰۴۱	**۰/۵۲۰۸**
N=15	۰/۵۹۶۳	۰/۵۹۴۴	**۰/۶۱۵۷**
N=20	۰/۶۴۲۳	۰/۶۳۹۵	**۰/۶۶۴۹**
N=25	۰/۶۶۲۹	۰/۶۶۰۰	**۰/۶۸۵۵**
N=30	۰/۶۷۱۲	۰/۶۶۸۵	**۰/۶۹۵۲**
N=35	۰/۶۷۲۸	۰/۶۷۰۶	**۰/۶۹۷۸**
N=40	۰/۶۷۰۳	۰/۶۶۸۳	**۰/۶۹۶۲**
N=45	۰/۶۶۴۹	۰/۶۶۳۰	**۰/۶۹۰۹**
N=50	۰/۶۵۶۷	۰/۶۵۵	**۰/۶۸۳۱**
N=55	۰/۶۴۶۹	۰/۶۴۵۵	**۰/۶۷۴۱**
N=60	۰/۶۳۷۰	۰/۶۳۵۲	**۰/۶۶۴۱**
N=65	۰/۶۲۶۴	۰/۶۲۴۸	**۰/۶۵۳۸**
N=70	۰/۶۱۵۷	۰/۶۱۳۸	**۰/۶۴۳۳**
N=75	۰/۶۰۴۸	۰/۶۰۳۰	**۰/۶۳۲۵**
N=80	۰/۵۹۴۲	۰/۵۹۲۴	**۰/۶۲۲۱**
N=85	۰/۵۳۸۹	۰/۵۸۲۲	**۰/۶۱۱۶**
N=90	۰/۵۷۳۶	۰/۵۷۲۰	**۰/۶۰۱۱**
N=95	۰/۵۶۳۲	۰/۵۶۱۶	**۰/۵۹۰۹**
N=100	۰/۵۵۳۲	۰/۵۵۱۷	**۰/۵۸۱۰**

سپس فولد ۱ (u1) مجموعه‌داده مووی‌لنز برای ارزیابی الگوریتم انتخاب شد و برای اینکه مشخص شود که W بدست آمده برای فولد u5، می‌تواند برای داده‌های دیگر نیز نتایج قابل قبولی ارائه دهد، از آن بر روی فولد u1 استفاده می‌شود.

در جدول ۷ مقدار تابع هزینه برای تمام الگوریتم‌ها، در حالت k=175 نشان داده شده است که طبق این جدول میانگین خطای مطلق بدست آمده از الگوریتم پیشنهادی در مقایسه با الگوریتم‌های گرگ خاکستری و توده ذرات کمتر است.

جدول ۷- مقایسه معیار MAE الگوریتم پیشنهادی با الگوریتم‌های پایه(فولد u1)

الگوریتم	MAE
گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی	**۰/۴۹۲۱**
گرگ خاکستری	۰/۵۵۱۲
توده ذرات	۰/۵۵۹۸

برای ارزیابی بیشتر، الگوریتم پیشنهادی ابتدا با الگوریتم‌های گرگ خاکستری و توده ذرات از نظرمعیار میانگین خطای مطلق به ازای

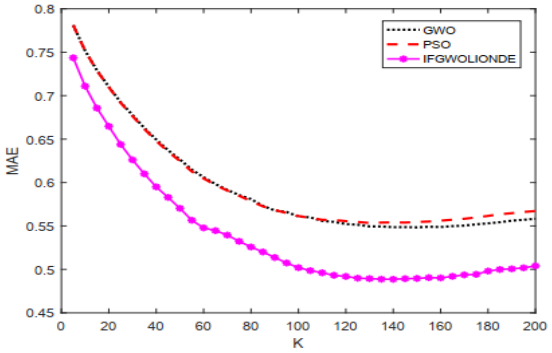
مقادیر مختلف k نزدیکترین همسایه و N=50 مقایسه می‌شود. نتایج در شکل ۵ نشان داده شده است.

در شکل ۵ مشاهده می‌شود که به ازای k برابر با ۵ الی ۲۰۰ مقادیر میانگین خطای مطلق بدست آمده از الگوریتم پیشنهادی در مقایسه با دو الگوریتم دیگر کمتر است. بنابراین الگوریتم پیشنهادی عملکرد بهتری داشته است.

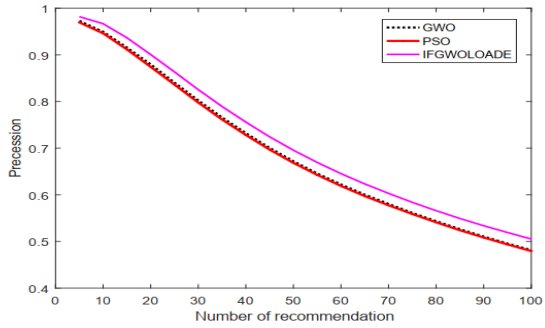
سپس با فرض k=175، با تغییر تعداد توصیه‌ها از ۵ الی ۱۰۰ منحنی‌های این سه معیار را با الگوریتم‌های مختلف بدست آورده‌ایم. نتایج در شکل‌های ۶ الی ۸ نشان داده شده‌اند.

به طور کلی از نتایج بدست آمده در شکل‌های ۶ الی ۸ می‌توان استنباط نمود الگوریتم پیشنهادی بهتر از دو الگوریتم گرگ خاکستری پایه و بهینه‌سازی توده ذرات عمل نموده است.

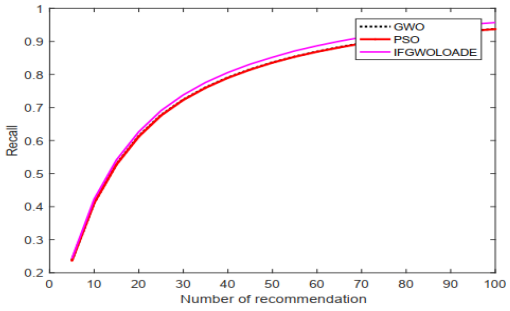
در ادامه مقدار MAE برای تمام فولدهای مجموعه‌داده مووی‌لنز به ازای k=175 و نیز میانگین MAE به ازای الگوریتم پیشنهادی و الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات محاسبه و نتایج در جدول ۸ آورده شده است.



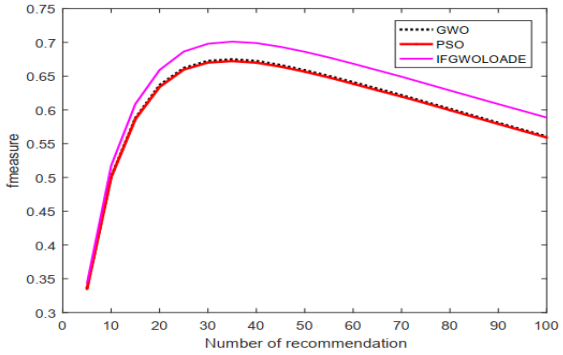
شکل ۵: معیار MAE بر حسب k نزدیکترین همسایه برای الگوریتم پیشنهادی و الگوریتم‌های پایه(فولد u1)



شکل ۶. معیار Precision برحسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه(فولد u1)



شکل ۷. معیار Recall بر حسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه(فولد u1)



شکل ۸. معیار F برحسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه(فولد u1)

از جدول ۸ مشاهده می‌شود که الگوریتم پیشنهادی IFGWOLOADE برای تمام فولدها در مقایسه با دو روش دیگر PSO و GWO مقدار MAE کمتری بدست آورده است. در نهایت با توجه به میانگین MAE بدست آمده از الگوریتم پیشنهادی مشخص می‌گردد که این الگوریتم از PSO و GWO عملکرد بهتری دارد.

جدول ۸- معیار MAE الگوریتم پیشنهادی برای فولدهای دیتاست مووی‌لنز

فولد	PSO	GWO	IFGWOLOADE
اول	۰/۵۵۹۸	۰/۵۵۱۲	۰/۴۹۲۱
دوم	۰/۵۶۵۴۳	۰/۵۶۵۳۸	۰/۴۹۴۵۷
سوم	۰/۵۵۴۳۳	۰/۵۵۳۹۷	۰/۴۹۳۴۲
چهارم	۰/۵۵۱۹۱	۰/۵۵۱۸۷	۰/۴۹۱۷۵
پنجم	۰/۵۵۷۳	۰/۵۴۹۵	۰/۴۸۷۸
میانگین	**۰/۵۵۷۸**	**۰/۵۵۴۴**	**۰/۴۹۱۹**

تحقیقات زیادی در زمینه سیستم‌های توصیه‌گر روی مجموعه داده مووی‌لنز انجام شده است. در جدول ۹ مقادیر MAE الگوریتم پیشنهادی و الگوریتم‌های ارائه شده در تعدادی از این تحقیقات آورده شده است.

جدول ۹- مقایسه معیار MAE الگوریتم پیشنهادی با الگوریتم‌های تحقیقات مرتبط

الگوریتم	MAE
KLD-FCM-MRS[۵۲]	۰/۷
FunkSVD[۵۳]	۰/۷۲۱
OSA[۵۴]	۰/۶۶
Kmeans-APSO[۲۰]	۰/۶۸۶
Kmeans -FOA[۲۰]	۰/۶۷۲
FPMF[۵۵]	۰/۷۳۱۸
TFMF[۵۶]	۰/۷۰۸۴
UITrust_C[۲۶]	۰/۷۳۳
MBODBN[۵۷]	۰/۷۱۶
Co Clustering[۵۸]	۰/۷۴۶
Kmeans- Deep learning (DL) [۵۹]	۰/۸۷۴۱
Kmeans - LCGOA[۶۰]	۰/۷۳
IFGOWLOADE	**۰/۴۹۱۹**

براساس جدول ۹ از روش خوشه بندی C میانگین فازی مبتنی بر واگراییکولبک لیبلر[۶۳] (کِی‌اِل‌دی-اِف‌سی‌اِم) و تابع شباهت مجذور-کسینوسی[۶۴] بهبودیافته برای یافتن همسایگان کاربر هدف توسط ویمالا و ویوکاناندان استفاده شد. مقدار MAE بدست آمده در این مرجع برابر با ۰/۷ است [۵۲]. گزدر و هیدری از یک الگوریتم براساس رویکرد فاکتورسازی ماتریسی به نام فانک‌اِس‌وی‌دی[۶۵] با تابع شباهت نمایی برای بهبود سیستم توصیه‌گر فیلم پالایش مشارکتی استفاده کردند و مقدار MAE برابر با ۰/۷۲۱ بدست آمد [۵۳]. در مطالعه روحیت و همکاران از الگوریتم توقف بهینه[۶۶] برای بهبود سیستم توصیه‌گر استفاده شد و مقدار MAE برابر با ۰/۶۶ بدست آمد [۵۴]. در مطالعه توحیدی و دادخواه الگوریتم‌های بهینه‌سازی جنگل[۶۷] و بهینه‌سازی توده ذرات شتاب‌یافته[۶۸] به همراه الگوریتم خوشه‌بندی K-Means برای بهبود عملکرد سیستم توصیه‌گر پالایش مشارکتی مبتنی بر کاربر استفاده شد و مقادیر MAE برای دو الگوریتم ذکر شده به ترتیب ۰/۶۷۲ و ۰/۶۸۶ بدست آمد [۲۰]. در بررسی فنگ و همکاران روش فاکتورسازی ماتریسی با استفاده از معیار تشابه چندعاملی[۶۹]، برای بهبود سیستم توصیه‌گر بکار رفته است. مقدار MAE بدست آمده از این روش برابر با ۰/۷۳۱۸ است [۵۵]. روش فاکتورسازی ماتریسی با ویژگی‌های موقتی[۷۰] برای بهبود سیستم توصیه‌گر توسط بهارا و ناین استفاده شد که مقدار MAE این روش برابر با ۰/۷۰۸۴ است [۵۶]. یک مدل چند بعدی برای بهبود کیفیت توصیه براساس طبقه‌بندی و آنتروپی رتبه‌بندی‌های کاربر-آیتم از طریق یک فرآیند انتخاب k نزدیکترین همسایه مبتنی بر طبقه‌بندی توسط یوآن و همکاران پیشنهاد و مقدار MAE برابر با ۰/۷۳۳ حاصل شد [۲۶]. به‌منظور بهبود سیستم توصیه‌گر سریدهار و همکاران ترکیبی از بهینه‌سازی پروانه سلطنتی (اِم‌بی‌اُ[۷۱]) برای انتخاب ویژگی و شبکه باور عمیق (دی‌بی‌اِن[۷۲]) ارائه دادند که مقدار MAE برابر با ۰/۷۱۶ به‌دست آمد [۵۷]. سیستم توصیه‌گر با استفاده از تنظیم پارامتر همسایگی کاربر و فیلم از طریق هم‌خوشه‌بندی[۷۳] توسط آیرن و آگراوال ارائه شد که مقدار MAE آن برابر ۰/۷۴۶ است [۵۸]. سیئت و همکاران از مدل ترکیبی یادگیری عمیق برای حل مشکلات سیستم‌های توصیه‌گر مانند مقیاس‌پذیری و کمبود داده‌ها و نیز مشکل شروع سرد استفاده کردند که MAE بدست آمده برابر با ۰/۸۷۴۱ است [۵۹]. ژائو و همکاران یک روش توصیه مبتنی بر خوشه‌بندی را پیشنهاد دادند که یک الگوریتم بهینه‌سازی ملخ بهبودیافته[۷۴]، به نام LCGOA، را با الگوریتم میانگین ترکیب می‌کند. MAE حاصله از این روش برابر با ۰/۷۳ است [۶۰].

با توجه به مقادیر MAE الگوریتم‌های ارائه شده در تحقیقات مذکور و مقدار MAE الگوریتم IFGWOLOADE پیشنهادی که برابر با ۰/۴۹۱۹ است، مشخص می‌شود میانگین MAE الگوریتم ترکیبی پیشنهادی نسبت به الگوریتم‌های سایر تحقیقات کمتر است که نشان‌دهنده عملکرد خوب الگوریتم پیشنهادی است.

۵- بحث و نتیجه‌گیری

در سیستم توصیه‌گر پالایش مشارکتی به‌عنوان پرکاربردترین مدل سیستم‌های توصیه‌گر، معیار شباهت یک فاکتور مهم محسوب می‌شود [۵]، که در این مقاله از تابع شباهت بهینه‌ی ارائه شده توسط بوبادیلا و همکاران [۴] در طراحی سیستم توصیه‌گر استفاده شد که یک ترکیب خطی ساده از مقادیر(V) و وزن‌ها (W) است. این تابع شباهت برخلاف توابع شباهت سنتی، انعطاف‌پذیری بیشتری دارد زیرا با تنظیم وزن‌های آن می‌توان کیفیت پیش‌بینی، کیفیت توصیه‌ها و عملکرد سیستم توصیه‌گر پالایش مشارکتی را بهبود بخشید و سادگی رابطه آن نیز سبب تسریع فرآیند توصیه می‌شود. با توجه به محبوبیت تحقیقات الگوریتمی در زمینه سیستم‌های توصیه‌گر [۴۴]، برای تنظیم وزن‌های این تابع شباهت، ما در سال ۲۰۲۱ الگوریتم بهینه‌سازی گرگ خاکستری فازی ترکیب‌شده با الگوریتم‌های بهینه‌سازی شیر را طراحی کردیم که منجر به بهبود عملکرد سیستم توصیه‌گر

پالایش مشارکتی شد [۲۸] اما این الگوریتم هنوز مشکلاتی در زمینه جستجوی سراسری دارد. بنابراین در این مقاله الگوریتم تکامل تفاضلی به دلیل توانایی جستجوی سراسری آن، به منظور بهبود اکتشاف انتخاب شد و الگوریتم فراابتکاری گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی در قالب یک الگوریتم فراابتکاری ترکیبی جدید ارائه شد.

به منظور ارزیابی عملکرد الگوریتم پیشنهادی در سیستم توصیه‌گر، میانگین خطای مطلق به همراه معیارهای دقت، فراخوانی و F محاسبه شد و نتایج روی مجموعه‌داده مووی‌لنز نشان داد که به ازای k=175، میانگین خطای مطلق بدست آمده از الگوریتم پیشنهادی در مقایسه با الگوریتم‌های گرگ خاکستری، توده ذرات و گرگ خاکستری فازی ترکیب‌شده با الگوریتم بهینه‌سازی شیر [۳۵]،کمتر است که بیانگر بهبود کیفیت پیش‌بینی است. همچنین با تغییر در تعداد توصیه‌ها الگوریتم پیشنهادی توانسته است که در تمام حالات مقادیر بیشتری از نظر معیارهای دقت، فراخوانی و F در مقایسه با الگوریتم گرگ خاکستری و بهینه‌سازی توده ذرات بدست آورد که نشان‌دهنده بهبود کیفیت توصیه‌ها در سیستم توصیه‌گر است.

عملکرد الگوریتم پیشنهادی روی توابع محک نیز مورد بررسی قرار گرفت و نتایج نشان داد که الگوریتم پیشنهادی موفق‌تر از الگوریتم‌های بهینه‌سازی توده ذرات، گرگ خاکستری و گرگ خاکستری فازی ترکیب‌شده با الگوریتم شیر [۳۶] عمل می‌نماید. با توجه به مطالب ذکر شده می‌توان نتیجه گرفت که الگوریتم پیشنهادی موجب بهبود عملکرد سیستم توصیه‌گر پالایش مشارکتی مبتنی بر کاربر شده است.

با توجه به عملکرد خوب الگوریتم پیشنهادی در مجموعه‌داده مووی‌لنز، می‌توان این الگوریتم را در مجموعه‌داده‌های دیگر مانند نتفلیکس و فیلم افینیتی[۷۵] مورد ارزیابی قرار داد. همچنین گسترش دامنه سیستم توصیه‌گر پیشنهادی به سایر سرگرمی‌ها مانند برنامه‌های تلویزیونی، موسیقی و کتاب از جمله اقداماتی است که می‌توان در آینده انجام داد.

استفاده از یادگیری عمیق برای سیستم‌های توصیه‌گر مسیر جدیدی در توسعه این سیستم‌ها در سال‌های اخیر است. سیستم‌های توصیه‌گر ویدیوی ترکیبی که از شبکه‌های عصبی عمیق استفاده می‌کنند، اغلب هدفشان افزایش دقت توصیه‌ها با ترکیب ویژگی‌های محتوا و رتبه‌بندی کاربران است، بنابراین می‌توان از ترکیب الگوریتم پیشنهادی و شبکه عصبی یادگیری عمیق در سیستم توصیه‌گر برای مجموعه‌داده مووی‌لنز و مجموعه‌داده‌های دیگر، استفاده کرد.

سیستم توصیه‌گر ارائه شده در این مقاله تنها از امتیازات کاربران استفاده می‌کند بنابراین هنگامی که پراکندگی داده[۷۶] وجود دارد عملکرد مطلوبی ندارد و از مشکل شروع سرد[۷۷] نیز برخوردار است، لذا برای حل این مشکلات می‌توان علاوه بر رتبه‌بندی‌ها، از اطلاعات جمعیت‌شناختی کاربران یا اطلاعات آیتم‌ها یا پروفایل کاربران در شبکه‌های اجتماعی استفاده و روشی ترکیبی ارائه نمود و یا سیستم توصیه‌گر پیشنهادی را برای توصیه دامنه متقابل[۷۸] ارتقا داد.

مراجع

[1] S. Forouzandeh, K. Berahmand, and M. Rostami, "Presentation of a recommender system with ensemble learning and graph embedding: a case on MovieLens," *Multimedia Tools and Applications*, vol. 80, pp. 7805–7832, 2021, doi: 10.1007/s11042-020-09949-5.

[2] M. Nilashi, O. Ibrahim, and K. Bagherifard, "A recommender system based on collaborative filtering using ontology and dimensionality reduction techniques," *Expert Systems with Applications*, vol. 92, pp. 507–520, 2018, doi:10.1016/j.eswa.2017.09.058.

[3] D. Valcarce, A. Landin, J. Parapar, and Á. Barreiro, "Collaborative filtering embeddings for memory-based recommender systems," *Engineering Applications of Artificial Intelligence*, vol. 85, pp. 347–356, 2019, doi: 10.1016/j.engappai.2019.06.020.

[4] J. Bobadilla, F. Ortega, A. Hernando, and J. Alcalá, "Improving collaborative filtering recommender system results and performance using genetic algorithms," *Knowledge-Based Systems*, vol. 24, no. 8, pp. 1310–1316, 2011, doi: 10.1016/j.knosys.2011.06.005.

[5] X. Ning, C. Desrosiers, and G. Karypis, "A comprehensive survey of neighborhood-based recommendation methods," *in Recommender Systems Handbook*, F. Ricci, L. Rokach, and B. Shapira, Eds. Boston, MA: Springer, 2015, pp. 107–144. doi: 10.1007/978-1-4899-7637-6_2.

[6] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer," *Advances in Engineering Software*, vol. 69, pp. 46–61, 2014. doi: 10.1016/j.advengsoft.2013.12.007.

[7] A. Akkaya, C. Közkurt, and R. Durgut, "A study on meta-heuristic algorithms used for problem solving in recent years," *Pioneer and Contemporary Studies in Engineering*, pp. 328–353, 2023.

[8] X. Li and M. Yin, "Parameter estimation for chaotic systems by hybrid differential evolution algorithm and artificial bee colony algorithm," *Nonlinear Dynamics*, vol. 77, pp. 123–139, 2014. doi: 10.1007/s11071-014-1273-9.

[9] Y. Li, D. Wang, H. He, L. Jiao, and Y. Xue, "Mining intrinsic information by matrix factorization-based approaches for collaborative filtering in recommender systems," *Neurocomputing*, vol. 249, pp. 48–63, 2017. doi: 10.1016/j.neucom.2017.03.002.

[10] M. F. Aljunid and M. Dh, "An efficient deep learning approach for collaborative filtering recommender system," *Procedia Computer Science*, vol. 171, pp. 829–836, 2020. doi: 10.1016/j.procs.2020.04.090.

[11] F. Ortega, R. Lara-Cabrera, Á. González-Prieto, and J. Bobadilla, "Providing reliability in recommender systems through Bernoulli matrix factorization," *Information Sciences*, vol. 553, pp. 110–128, 2021. doi: 10.1016/j.ins.2020.12.001.

[12] A. Gupta, H. Shivhare and S. Sharma, "Recommender system using fuzzy c-means clustering and genetic algorithm based

weighted similarity measure," *2015 International Conference on Computer, Communication and Control (IC4)*, Indore, India, 2015, pp. 1-8, doi: 10.1109/IC4.2015.7375707.

[13] M. Hatami and S. Pashazadeh, "Improving results and performance of collaborative filtering-based recommender systems using cuckoo optimization algorithm," *International Journal of Computer Applications*, vol. 88, no. 16, pp. 1–8, 2014. doi: 10.5120/15440-3981.

[14] B. Alhijawi and Y. Kilani, "A collaborative filtering recommender system using genetic algorithm," *Information Processing & Management*, vol. 57, no. 6, p. 102310, 2020. doi: 10.1016/j.ipm.2020.102310.

[15] R. Logesh, V. Subramaniyaswamy, D. Malathi, N. Sivaramakrishnan, and V. Vijayakumar, "Enhancing recommendation stability of collaborative filtering recommender system through bio‐inspired clustering ensemble method," *Neural Computing & Applications*, vol. 32, pp. 2141–2164, 2020. doi:10.1007/s00521-018-3891-5

[16] C. Selvi and E. Sivasankar, "A novel optimization algorithm for recommender system using modified fuzzy c-means clustering approach," *Soft Computing*, vol. 23, no. 6, pp. 1901–1916, 2019. doi: 10.1007/s00500-017-2899-6.

[17] T. Mohammadpour, A. M. Bidgoli, R. Enayatifar, and H. H. S. Javadi, "Efficient clustering in collaborative filtering recommender system: Hybrid method based on genetic algorithm and gravitational emulation local search algorithm," *Genomics*, vol. 111, no. 6, pp. 1902–1912, 2019. doi: 10.1016/j.ygeno.2019.01.001.

[18] R. Ahuja, A. Solanki and A. Nayyar, "Movie Recommender System Using K-Means Clustering AND K-Nearest Neighbor," *2019 9th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, Noida, India, 2019, pp. 263-268, doi: 10.1109/CONFLUENCE.2019.8776969.

[19] S. Lee, "Using entropy for similarity measures in collaborative filtering," *Journal of Ambient Intelligence & Humanized Computing*, vol. 11, pp. 363–374, 2020. doi: 10.1007/s12652-019-01226-0.

[20] N. Tohidi and C. Dadkhah, "Improving the performance of video collaborative filtering recommender systems using optimization algorithm," *International Journal of Nonlinear Analysis and Applications*, vol. 11, no. 1, pp. 483–495, 2020, doi: 10.22075/IJNAA.2020.19127.2058.

[21] T. Wang, G. Manogaran, and M. Wang, "Framework for social tag recommendation using Lion Optimization Algorithm and collaborative filtering techniques," *Cluster Computing*, vol. 23, pp. 2009–2019, 2020. doi: 10.1007/s10586-019-02980-8.

[22] J. Zhang, Y. Wang, Z. Yuan and Q. Jin, "Personalized real-time movie recommendation system: Practical prototype and evaluation," in *Tsinghua Science and Technology*, vol. 25, no. 2, pp. 180-191, April 2020, doi: 10.26599/TST.2018.9010118.

[23] H. Tahmasebi, R. Ravanmehr, and R. Mohamadrezaei, "Social movie recommender system based on deep autoencoder network using Twitter data," *Neural Computing & Applications*, vol. 33, no. 5, pp. 1607–1623, 2021. doi: 10.1007/s00521-020-05085-1.

[24] J. Huang, Z. Jia, and P. Zuo, "Improved collaborative filtering personalized recommendation algorithm based on k‐means clustering and weighted similarity on the reduced item space," *Mathematical Modelling and Control*, vol. 3, no. 1, pp. 39–49, 2023. doi: 10.3934/mmc.2023004.

[25] T.-M. Ma, X. Wang, F.-C. Zhou, and S. Wang, "Research on diversity and accuracy of the recommendation system based on multi‐objective optimization," *Neural Computing & Applications*, vol. 35, pp. 5155–5163, 2023. doi: 10.1007/s00521-020-05438-w.

[26] Y. Yuan, L. Chen, and J. Yang, "A multidimensional model for recommendation systems based on classification and entropy," *Electronics*, vol. 12, no. 2, p. 402, Jan. 2023, doi: 10.3390/electronics12020402.

[۲۷] منصوره شجاعی و حسن صانعی فر, "ارائه یک معیار جدید اندازه‌گیری شباهت در سیستم‌های توصیه‌گر فازی," *مجله علمی رایانش نرم و فناوری اطلاعات*, دوره ۹، شماره ۲ ،صفحات ۱-۱۵,۱۳۹۹.

[28] L. V. Nguyen, "Advanced Clustering Techniques with Bio‐Inspired for Collaborative Filtering Recommendation Systems," *Vietnam Journal of Computer Science*, vol. 12, no. 01, pp. 21–36, Jul. 2024, doi: 10.1142/S2196888824400013.

[29] G. Sirbiladze, H. Garg, I. Khutsishvili, et al., "Associated Probabilities' Aggregations in Fuzzy Collaborative Filtering Recommender System Prediction," *Int. J. Fuzzy Syst*., vol. 27, pp. 204–236, 2025, doi:10.1007/s40815-024-01772-6.

[30] N. M. Ibrahim, S. M. Abiduzzaman, A. R. A. Raziff, and A. Shah, "A collaborative filtering approach using machine learning and business intelligence: A critical review," *International Journal on Perceptive and Cognitive Computing*, vol. 11, no. 1, pp. 41–49, 2025, doi: 10.31436/ijpcc.v11i1.501.

[31] K. Santosh, M. S. Kumar, M. Jahnavi, N. N. Reddy, B. Sireesha and B. K. Bala, "Creating an Advanced Recommendation System Integrating Collaborative Filtering and Social Media Analytics for Enhanced Customer Engagement," *2024 10th International Conference on Communication and Signal Processing (ICCSP)*, Melmaruvathur, India, 2024, pp. 1146-1151, doi: 10.1109/ICCSP60870.2024.10544247.

[32] G. B, K. Balamurugan, A. Balamurugan and A. Balamurugan, "Optimizing Recommendation Systems : A Hybrid Approach for Improved Accuracy," in 2024 Second International Conference on Inventive Computing and Informatics (ICICI), Bangalore, India, 2024, pp. 484-489, doi: 10.1109/ICICI62254.2024.00084.

[33] K. N. Mishra, A. Mishra, P. N. Barwal, and R. K. Lal, "Natural Language Processing and Machine Learning-Based Solution of Cold Start Problem Using Collaborative Filtering Approach," *Electronics*, vol. 13, no. 21, p. 4331, Nov. 2024, doi: 10.3390/electronics13214331.

[34] Q. Bsoul, F. Zawaideh, B. S. Alqadi, L. A. Almusfar, O. I. Khalaf, A. S. Alattas, M. Alali, and D. S. Abd Elminaam, "From user preferences to accurate predictions: Enhancing movie recommendation systems with neural collaborative filtering and sentiment analysis," *SN Computer Science*, vol. 6, no. 3, p. 257, 2025, doi: 10.1007/s42979-025-03742-7.

[35] S. Yadav and S. Nagpal, "An improved collaborative filtering based recommender system using bat algorithm," *Procedia Computer Science*, vol. 132, pp. 1795–1803, 2018, doi: 10.1016/j.procs.2018.05.155.

[۳۶] زهرا نخعی راد، حسام زندحسامی و عباس طلوعی اشلقی، "بهبود عملکرد و نتایج سیستم توصیه‌گر پالایش مشارکتی با استفاده از الگوریتم بهینه‌ساز گرگ خاکستری فازی غنی‌شده با الگوریتم بهینه‌سازی شیر" *چشم‌انداز مدیریت صنعتی*، دوره ۱۱،شماره۴،صفحات ۲۲۲-۱۹۷، ۱۴۰۰ . doi: 10.52547/JIMP.11.4.197

[37] R. Chen, Q. Hua, Y. -S. Chang, B. Wang, L. Zhang and X. Kong, "A Survey of Collaborative Filtering-Based Recommender Systems: From Traditional Methods to Hybrid Methods Based on Social Networks," in *IEEE Access*, vol. 6, pp. 64301-64320, 2018, doi: 10.1109/ACCESS.2018.2877208.

[38] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom, and J. Riedl, "GroupLens: An open architecture for collaborative filtering of netnews," in *Proc. 1994 ACM Conf. Computer Supported Cooperative Work (CSCW '94)*, New York, NY, USA, 1994, pp. 175–186, doi: 10.1145/192844.192905.

[39] W. Wang and Y. Lu, "Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding

model," *IOP Conf. Ser.: Mater. Sci. Eng*., vol. 324, no. 1, p. 012049, 2018, doi: 10.1088/1757-899X/324/1/012049.

[40] B. Rawat and S. K. Dwivedi, "Selecting appropriate metrics for evaluation of recommender systems," *International Journal of Information Technology and Computer Science (IJITCS)*, vol. 11, no. 1, pp. 14–23, 2019, doi: 10.5815/ijitcs.2019.01.02.

[41] F. Valdez, P. Melin, and O. Castillo, "A survey on nature‐inspired optimization algorithms with fuzzy logic for dynamic parameter adaptation," *Expert Systems with Applications*, vol. 41, pp. 6459–6466, 2014, doi: 10.1016/j.eswa.2014.04.015.

[42] L. Rodríguez, O. Castillo, and J. Soria, "A study of parameter dynamic adaptation with fuzzy logic for the Grey Wolf Optimizer algorithm," in *Advances in Computational Intelligence. MICAI 2016*, G. Sidorov and O. Herrera-Alcántara, Eds., vol. 10061, Cham: Springer, 2017, pp. 237–248, doi: 10.1007/978-3-319-62434-1_19.

[43] M. Yazdani and F. Jolai, "Lion Optimization Algorithm (LOA): A nature‐inspired metaheuristic algorithm," *Journal of Computational Design and Engineering*, vol. 3, no. 1, pp. 24–36, 2016, doi: 10.1016/j.jcde.2015.06.003.

[44] Y. Fu, D. Liu, J. Chen, et al., "Secretary bird optimization algorithm: a new metaheuristic for solving global optimization problems," *Artif. Intell. Rev*., vol. 57, article 123, 2024, doi: 10.1007/s10462-024-10729-y.

[45] J. Wei and Y. Yu, "An Effective Hybrid Cuckoo Search Algorithm for Unknown Parameters and Time Delays Estimation of Chaotic Systems," in *IEEE Access*, vol. 6, pp. 6560-6571, 2018, doi: 10.1109/ACCESS.2017.2738006.

[46] L. Abualigah, D. Yousri, M. A. Elaziz, A. A. Ewees, M. A. A. Al‐Qaness, and A. H. Gandomi, "Aquila Optimizer: A novel meta‐heuristic optimization algorithm," *Computers & Industrial Engineering*, vol. 157, art. 107250, 2021, doi: 10.1016/j.cie.2021.107250.

[47] M. H. Amiri, N. Mehrabi Hashjin, M. Montazeri, S. Mirjalili, and N. Khodadadi, "Hippopotamus optimization algorithm: a novel nature‐inspired optimization algorithm," *Scientific Reports*, vol. 14, art. 5032, 2024, doi: 10.1038/s41598‐024‐54910‐3.

[48] B. Abdollahzadeh, N. Khodadadi, S. Barshandeh, P. Trojovský, F. Soleimanian Gharehchopogh, E. M. El‐kenawy, L. Abualigah, and S. Mirjalili, "Puma optimizer (PO): a novel metaheuristic optimization algorithm and its application in machine learning," *Cluster Computing*, vol. 27, pp. 5235–5283, 2024, doi: 10.1007/s10586-023-04221-5.

[49] L. Abualigah, M. A. Elaziz, P. Sumari, Z. W. Geem, and A. H. Gandomi, "Reptile Search Algorithm (RSA): A nature‐inspired meta‐heuristic optimizer," *Expert Systems with Applications*, vol. 191, Art. no. 116158, Apr. 2022, doi: 10.1016/j.eswa.2021.116158.

[50] X. Zhao, X. Wang, H. Sun, L. Wang, and M. Ma, "A self-adaptive differential evolution algorithm with an external archive for unconstrained optimization problems," *Journal of Intelligent & Fuzzy Systems*, vol. 29, no. 5, pp. 2 193–2 204, 2015, doi: 10.3233/IFS-151695.

[51] S. Wang, W. Hu, I. Riego, and Y. Yu, "Improved surrogate-assisted whale optimization algorithm for fractional chaotic systems' parameters identification," *Engineering Applications of Artificial Intelligence*, vol. 110, p. 104685, 2022, doi: 10.1016/j.engappai.2022.104685.

[52] S. V. Vimala and K. Vivekanandan, "A Kullback–Leibler divergence‐based fuzzy C‐means clustering for enhancing the potential of a movie recommendation system," *SN Appl. Sci*., vol. 1, art. 698, 2019, doi: 10.1007/s42452-019-0708-9.

[53] A. Gazdar and L. Hidri, "A new similarity measure for collaborative filtering based recommender systems," *Knowledge‐Based Systems*, vol. 188, p. 105058, 2020, doi: 10.1016/j.knosys.2019.105058.

[54] S. Rohit, V. Sathish, T. Mehrotra and B. Das, "Applications of Optimal Stopping Algorithm for Social Graph Based Recommendation," *2019 IEEE Students Conference on Engineering and Systems (SCES)*, Allahabad, India, 2019, pp. 1-6, doi: 10.1109/SCES46477.2019.8977222.

[55] C. Feng, J. Liang, P. Song, and Z. Wang, "A fusion collaborative filtering method for sparse data in recommender systems," *Information Sciences*, vol. 521, pp. 365–379, 2020, doi: 10.1016/j.ins.2020.02.052.

[56] G. Behera and N. Nain, "Collaborative filtering with temporal features for movie recommendation system," *Procedia Computer Science*, vol. 218, pp. 1366–1373, 2023, doi: 10.1016/j.procs.2023.01.115.

[57] S. Sridhar, D. Dhanasekaran, and G. C. P. Latha, "Content‐Based Movie Recommendation System Using MBO with DBN," *Intell. Automat. Soft Comput*., vol. 35, no. 3, pp. 3241–3257, 2023, doi: 10.32604/iasc.2023.030361.

[58] S. Airen and J. Agrawal, "Movie recommender system using parameter tuning of user and movie neighbourhood via co‐clustering," *Procedia Computer Science*, vol. 218, pp. 1176–1183, 2023, doi: 10.1016/j.procs.2023.01.096.

[59] S. Siet, S. Peng, S. Ilkhomjon, M. Kang, and D. S. Park, "Enhancing Sequence Movie Recommendation System Using Deep Learning and KMeans," *Applied Sciences*, vol. 14, no. 6, p. 2505, 2024, doi: 10.3390/app14062505.

[60] Z. Zhao, Y. Xia, W. Xu, H. Yu, S. Yang, C. Chen, X. Yuan, X. Zhou, Q. Wang, and L. Gu, "Clustering‐based recommendation method with enhanced grasshopper optimisation algorithm," *CAAI Trans. Intell. Technol*., pp. 1–16, 2025, doi: 10.1049/cit2.12408.

پاورقی‌ها:

[1].Information overflow
[2].Collaborative Filtering (CF)-Based Rcommender System
[3].Content- Based Rcommender System
[4].Demographic-Based Rcommender System
[5].Hybrid Recommender System
[6].simplicity
[7].flexibility
[8].derivation- free mechanism
[9].local optima avoidance
[10].Bobadilla et al.
[11].Nilashi et al.
[12].KNN(k-nearest neighbors)
[13].Pearson Correlation Coefficient
[14].Ahuja et al.
[15].Alhijawi & Kilani
[16].Logesh et al.
[17].Lee
[18].Wang et al.
[19].social tag
[20].Zhang et al
[21].hybrid social recommender system
[22].deep autoencoder network
[23].Twitter
[24].Huang et al.
[25].data sparsity problem
[26].kernel method and multi-objective optimization (MO-KUCF)
[27].Ma et al.
[28].Yuan et al.
[29].classification
[30].entropy
[31].Nguyen
[32].Sirbiladze et al.

[۳۳].Ibrahim et al.
[۳۴].Santosh et al.
[۳۵].Balamurugan et al.
[۳۶].Mishra et al.
[۳۷].Bsoul et al.
[۳۸].sentiment polarity
[39].adjusted weighted aggregation
[۴۰].deviation-from-mean
[۴۱].Particle Swarm Optimization (PSO)
[42].Gravitational Search Algorithm(GSA)
[43].Differential Evolution(DE)
[۴۴].Fast Evolutionary Programing (FEP)
[45].Evolution Strategy (ES)
[46].Rodriguez et al.
[47].Particle Swarm Optimization(PSO)
[48].Invasive Weed Optimization(IWO)
[49].Fu et al.
[50].Secretary Bird Optimization Algorithm (SBOA)
[51].Wei and Yu
[52].Mutation
[53].binomial crossover
[54].Precision
[55].Recall
[56].F-Measure
[57].MovieLens
[58].Ackley
[59].Griewank
[60].Rastrigin
[۶۱].Rosenbrock
[62].Sphere
[63].Kullback–Leibler Divergence-based Fuzzy C-Means Clustering(KLD-FCM)
[64].sqrt-cosine
[65].FunkSVD
[66].Optimal Stopping Algorithm
[67].Forest Optimization (FOA)
[68].Accelerated Particle Swarm Optimization (APSO)
[69].multifactor similarity measure
[70].temporal effects
[71].Monarch Butterfly Optimization (MBO)
[72].Deep Belief Network (DBN)
[73].Co-Clustering
[74].enhanced Grasshopper Optimisation Algorithm (GOA)
[75].FilmAffinity
[76].Data Sparsity
[77].Cold Start
[78].Cross-domain recommendation (CDR)