Semnan University

Journal of Modeling in Engineering

Journal homepage: https://modelling.semnan.ac.ir/

ISSN: 2783-2538



Research Article

A movie Recommender System based on a hybrid intelligent optimization algorithm

Haleh Nakhaei Rad [a], Hessam Zandhessami [b*] and Abbas Toloie Eshlaghy [c]

[a] Ph.D. Candidate in Information Technology Management, Department of Information Technology Management, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran.

[b] Assistant Professor, Department of Industrial Management, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran.

[c] Professor, Department of Industrial Management, Faculty of Management and Economics, Science and Research Branch Islamic Azad University, Tehran, Iran.

UNCORRECTED PROOF

PAPER INFO

Paper history:

Received:
Revised:
Accepted:

Keywords:

Movie Recommender systems;

Collaborative filtering;

K-Nearest Neighbors (KNN);

Grey Wolf Optimizer algorithm;

Lion Optimization algorithm;

Differential Evolution algorithm;

Nelder-Mead method.

ABSTRACT

Watching movie is kind of entertainment in modern society and Video streaming platforms are drastically increased due to technological advancement and easy access of handheld devices in the recent years. Movie recommender systems are integrated into these platforms to help users discover suitable movies and series. In fact movie recommendation systems aim at suggesting what movie to watch without having to go through the long process of choosing from a large set of movies that is time consuming and confusing. Collaborative filtering which has excellent speed and robustness in recommendation, has been widely used in various online movie streaming platforms and it helps users to find the movies based on the movie experience of other users in efficient and effective way without wasting much time. In this paper is suggested a user-based collaborative filtering recommender system on Movielens dataset which weights of similarity function and K Nearest neighbors are adjusted with a new hybrid meta-heuristic algorithm (a combination of fuzzy Grey Wolf Optimizer algorithm, Lion Optimization algorithm, Differential Evolution algorithm and Nelder-Mead method) in the form of an optimization problem. The performance of proposed algorithm is considered in terms of MAE, Precision, Recall, F-measure and new proposed measure. The results shows that improvement in prediction accuracy and recommendation quality of recommender system.

DOI: https://doi.org/10.22075/jme.2024.31282.2495

© 2024 Published by Semnan University Press.
This is an open access article under the CC-BY 4.0 license.(https://creativecommons.org/licenses/by/4.0/)

*** Corresponding author.**
E-mail address: 0072828791@iau.ir

How to cite this article:

مقاله پژوهشی

سیستم توصیه‌گر فیلم

مبتنی بر الگوریتم بهینه‌سازی هوشمند ترکیبی

هاله نخعی راد[۱]، حسام زندحسامی[۲] * و عباس طلوعی اشلقی[۳]

اطلاعات مقاله

دریافت مقاله:
بازنگری مقاله:
پذیرش مقاله:

واژگان کلیدی:
سیستم توصیه‌گر فیلم،
پالایش مشارکتی،
k نزدیکترین همسایه،
الگوریتم گرگ خاکستری،
الگوریتم بهینه‌سازی شیر،
الگوریتم تکامل تفاضلی،
روش نلدرمید.

چکیده

تماشای فیلم یکی از سرگرمی‌های رایج در جامعه مدرن است و پلتفرم‌های پخش ویدئو به دلیل پیشرفت تکنولوژی و دسترسی آسان در سال‌های اخیر به شدت افزایش یافته‌اند. سیستم‌های توصیه‌گر فیلم در این پلتفرم‌ها ادغام شده‌اند تا به کاربران در کشف فیلم‌ها و سریال‌های مناسب کمک کنند. در واقع هدف سیستم‌های توصیه فیلم پیشنهاد فیلم موردعلاقه کاربران است، بدون اینکه مجبور به گذراندن فرآیند طولانی و گیج‌کننده انتخاب از میان مجموعه بزرگی از فیلم‌ها باشند.پالایش مشارکتی که سرعت و پایداری بسیار خوبی در توصیه دارد به طور گسترده در پلتفرم های مختلف پخش آنلاین فیلم مورد استفاده قرار گرفته است و به کاربران کمک می‌کند تا فیلم‌های مورد نظر خود را براساس تجربه تماشای فیلم کاربران دیگر به شیوه‌ای کارآمد و موثر و بدون اتلاف وقت زیاد، پیدا کنند. در این مقاله یک سیستم توصیه‌گر مبتنی بر پالایش مشارکتی مبتنی بر کاربر برای مجموعه داده موویلنز پیشنهاد شده است که وزن‌های تابع شباهت و مقدار بهینه K نزدیکترین همسایه توسط یک الگوریتم بهینه‌سازی هوشمند ترکیبی (ترکیبی از گرگ خاکستری فازی با الگوریتم‌های شیر، تکامل تفاضلی و جستجوی نلدرمید) در قالب یک مسئله بهینه‌سازی تنظیم شده است. عملکرد سیستم از لحاظ MAE، دقت، فراخوانی، معیار F و معیار جدید پیشنهادی اندازه‌گیری شد. نتایج نشان‌دهنده بهبود دقت پیش‌بینی و کیفیت توصیه سیستم توصیه‌گر است.

DOI: https://doi.org/10.22075/jme.2024.31282.2495

© 2024 Published by Semnan University Press.
This is an open access article under the CC-BY 4.0 license.(https://creativecommons.org/licenses/by/4.0/)

UNCORRECTED PROOF

* پست الکترونیک نویسنده مسئول:0072828791@iau.ir

۱. دانشجوی دکتری مدیریت فناوری اطلاعات، گروه مدیریت فناوری اطلاعات دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات،دانشگاه آزاد اسلامی، تهران،ایران.

۲. استادیار گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات ،دانشگاه آزاد اسلامی، تهران،ایران.

۳. استاد گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران،ایران.

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

۱- مقدمه

صنعت سرگرمی در حال رونق است و یادگیری ماشینی نقشی حیاتی در حوزه‌های فنی آن ایفا می‌کند. هر شرکت فعال در این صنعت از الگوریتم‌های توصیه برای ارائه‌ی محتوای معنادار به کاربران براساس ترجیحاتشان استفاده می‌کند، تا فروش خود را افزایش دهد و کاربرانش را حفظ کند[۱]. فیلم‌ها به عنوان یکی از محبوب‌ترین منابع سرگرمی، باعث شده‌اند پلتفرم‌های آنلاین پخش فیلم رشد چشمگیری داشته باشند و حجم زیادی محتوا در وب تولید شود. هر پلتفرم شامل محتوای گسترده‌ای از ژانرهای مختلف است، که طیف وسیعی از انتخاب‌ها را در اختیار کاربران قرار می‌دهد. این تنوع باعث می‌شود کاربران قادر به یافتن سریع و دقیق فیلم‌های مورد علاقه خود نباشند[۲] و ارائه‌دهندگان محتوا نیز برای متمایز کردن آثار خود از رقبا با چالش مواجه شوند[۳ و ۴]. در این میان، سیستم‌های توصیه‌گر فیلم نقش اساسی ایفا می‌کنند[۵]. زیرا این سیستم‌ها، فیلم‌هایی را پیشنهاد می‌دهند که احتمالاً مورد علاقه کاربران هستند، فرآیند یافتن فیلم‌ها را ساده‌تر می‌کنند، تجربه کاربری را بهینه می‌سازند و در نهایت به رشد صنعت فیلم کمک می‌کنند[۶].

در زمینه فیلم، الگوریتم‌های توصیه عبارتند از: پالایش مشارکتی، مبتنی بر محتوا و ترکیبی[۶].

در حال حاضر پالایش مشارکتی متداولترین تکنیک مورد مطالعه و مورد استفاده در سیستم‌های توصیه‌گر است [۷ و ۸ و ۹ و ۱۰ و ۱۱]. مطالعات نشان می‌دهد که این رویکرد در ارائه توصیه‌های شخصی مؤثر است و نقش مهمی در کاهش تأثیر منفی پدیده "سربار اطلاعات[1]" در وب‌سایت‌هایی دارد که کاربران امکان امتیازدهی براساس ترجیحات خود را دارند. با توجه به اینکه وب‌سایت‌های توصیه فیلم شناخته‌شده‌ترین وب‌سایت‌ها در این زمینه هستند[۷]، از این رو به پالایش مشارکتی طور گسترده در پلتفرم‌های مختلف پخش آنلاین فیلم به کار گرفته شده است[۱۲].

روش‌های پالایش مشارکتی را می‌توان به دو دسته اصلی تقسیم کرد: مبتنی بر همسایگی و مبتنی بر مدل. در پالایش مشارکتی مبتنی بر همسایگی (مبتنی بر حافظه یا اکتشافی[۹])، رتبه‌بندی‌های کاربر-آیتم ذخیره شده در سیستم، مستقیماً برای پیش‌بینی رتبه آیتم‌های جدید استفاده می‌شوند. این رویکرد که از اولین رویکردهای پالایش مشارکتی است، همچنان محبوب است، زیرا علاوه بر سادگی[2] توصیف، پیاده‌سازی و درک الگوریتم، چندین مزیت مهم دارد که عبارتند از توجیه‌پذیری[3]، کارایی[4] محاسباتی و فضایی و نیز پایداری[5] در محیط آنلاینی که کاربران و آیتم‌های جدید به طور مداوم اضافه می‌شوند[۱۳].

سیستم‌های توصیه‌گر مبتنی بر همسایگی بر این اصل استوارند که کاربران مشابه آیتم‌های مشابه را ترجیح می‌دهند و آیتم‌های مشابه توسط کاربران مشابه پسندیده می‌شوند[۱۳]. بر این اساس، این رویکردها به دو نوع مبتنی بر کاربر[6] و مبتنی بر آیتم[7] تقسیم می‌شوند. سیستم‌های کاربرمحور، شباهت بین کاربران را محاسبه می‌کنند (کاربران مشابه به عنوان همسایه‌های کاربر شناخته می‌شوند و یک همسایگی کاربر را تشکیل می‌دهند) تا آیتم‌هایی را که کاربران همفکر پسندیده‌اند، توصیه کنند. از سوی دیگر، سیستم‌های آیتم‌محور، ترجیح کاربر نسبت به یک آیتم را براساس آیتم‌های مشابهی که کاربر پیش‌تر پسندیده است، پیش‌بینی می‌کنند(اصطلاح همسایگی آیتم برای مجموعه ای از آیتم‌های مشابه به‌کار می‌رود)[۹]. انتخاب بین رویکرد کاربرمحور و آیتم‌محور به فراوانی و میزان تغییر در کاربران و آیتم‌ها بستگی دارد. در کاربردهایی که فهرست آیتم‌ها به طور مداوم تغییر می‌کند، مانند توصیه فیلم، روش‌های مبتنی بر کاربر معمولا پایدارتر هستند[۱۳]. بنابراین در این مقاله سیستم توصیه‌گر پالایش مشارکتی مبتنی بر حافظه کاربرمحور به

[1] . Information Overload

[2] . Simplicity

[3] . Justifiability

[4] . Efficiency

[5] . Stability

[6] . user-based

[7] . item-based

UNCORRECTED PROOF

عنوان سیستم توصیه‌گر فیلم انتخاب شد، زیرا این مدل سیستم توصیه‌گر، قادر است آیتم‌هایی که تحلیل محتوای آنها با رایانه دشوار است، مانند فیلم‌ها، را به راحتی فیلتر کند، تجربه دیگران را به اشتراک گذارد و فیلم‌ها را براساس کیفیت‌شان ارزیابی کند. علاوه بر این توانایی ارائه توصیه‌های غیرمترقبه[1] را دارد، بدین ترتیب می‌تواند فیلم‌هایی را به کاربر پیشنهاد دهد که پیش از آن توجهی به آنها نداشته است [۱۴ و ۱۵] .

با توجه به اینکه اجزای مختلف سیستم توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی، شامل محاسبه وزن‌های شباهت و انتخاب نزدیک‌ترین همسایه‌ها، تأثیر قابل‌توجهی بر کیفیت توصیه‌ها دارند[۱۳]، می‌بایست در قالب یک مسئله بهینه‌سازی بررسی شوند.

الگوریتم‌های فراابتکاری به دلیل چهار ویژگی اصلی، یعنی سادگی[2]، انعطاف‌پذیری[3]، مکانیسم بدون مشتق[4]، و اجتناب از بهینه محلی[5] به عنوان رویکردهایی موثر برای حل مسائل بهینه‌سازی مدرن، مورد توجه گسترده قرار گرفته‌اند[۱۶ و ۱۷]. قضیه **"ناهار مجانی نداریم"**[6] به طور منطقی ثابت کرد که هیچ فراابتکاری وجود ندارد که برای حل همه مسائل بهینه‌سازی مناسب باشد و باعث شد که این زمینه تحقیقات باز بماند و محققان الگوریتم‌های فراابتکاری جدید پیشنهاد دهند[۱۸] به طوری که مطالعات اخیر نشان می‌دهد که پژوهشگران به ترکیب الگوریتم‌های فراابتکاری گرایش پیدا کرده‌اند[۱۹]. زیرا دریافتند که ترکیبی هوشمندانه از دو الگوریتم فراابتکاری می‌تواند عملکرد آنها را در مواجهه با مسائل واقعی و مقیاس بزرگ بهبود دهد[۲۰].

براساس مطالب ذکر شده و با توجه به اهمیت انتخاب الگوریتم فراابتکاری مناسب برای حل مسائل بهینه‌سازی و نیز محبوبیت تحقیقات الگوریتمی در حوزه‌ی سیستم‌های توصیه‌گر[۲۱]، ارائه‌ی یک الگوریتم بهینه‌سازی هوشمند ترکیبی جدید جهت بهینه‌سازی عملکرد سیستم‌های توصیه‌گر پالایش مشارکتی ضروری است. این الگوریتم ترکیب الگوریتم گرگ خاکستری فازی با الگوریتم‌های شیر، تکامل تفاضلی و نلدرمید است. نوآوری‌های اصلی تحقیق عبارتند از: ارائه یک تابع هزینه تک هدفه جدید به منظور بهبود در نتایج کلی بدست آمده از الگوریتم و نیز تنظیم پارامتر K نزدیکترین همسایه توسط الگوریتم بهینه‌سازی هوشمند ترکیبی پیشنهادی در قالب یک مسئله بهینه‌سازی با هدف بهبود عملکرد سیستم توصیه‌گر.

۲- مبانی نظری و پیشینه تحقیق

تحقیقات زیادی در زمینه سیستم‌های توصیه‌گر فیلم توسط محققان انجام شده است. فرتادو و سینگ در ۲۰۲۰ از یک مدل یادگیری ماشین برای سیستم توصیه‌گر فیلم استفاده نمودند [۲۲] آن ها از هر دو روش پالایش مشارکتی و مبتنی بر محتوا استفاده نمودند. با اجباری کردن رتبه بندی ، پراکندگی را بهبود بخشیدند و مشکل خصوصی سازی بیش از حد[7] را با استفاده از تکنیک های مشارکتی مبتنی بر همسایگی حل نمودند. لاوانیا و همکاران در ۲۰۲۱ یک بررسی جامع برای سیستم‌های توصیه‌گر فیلم ارائه دادند. هدف آن‌ها بررسی تحقیقات، تجمیع و طبقه‌بندی ساختاری تمام اشکالات موجود در رایج‌ترین و محبوب‌ترین سیستم‌های توصیه فیلم تجاری بود [۲۳]. نخلی و همکاران در ۲۰۱۹ یک سیستم توصیه‌گر فیلم براساس رویکرد درصد مشاهده برای یافتن فیلم‌های مرتبط به مشتریان پیشنهاد کردند. آن‌ها از یک معیار نظر ضمنی[8] برای بهبود عملکرد سیستم توصیه گر استفاده و بر روی بهبود دقت توصیه گر تاکید نمودند[۲۴]. تاکر و همکاران در ۲۰۲۰ یک مطالعه جامع در مورد سیستم‌های توصیه‌گر فیلم مبتنی بر پالایش مشارکتی ارائه دادند . آن‌ها رویکردهای مختلف پالایش مشارکتی بکار رفته در

[1] . serendipitous recommendations

[2] . simplicity

[3] . flexibility

[4] derivation- free mechanism

[5] . local optima avoidance

[6] . No Free Lunch (NFL) theorem

[7] . over-specialization

[8] . an Implicit Opinion Measure (IOM)

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

UNCORRECTED PROOF

سیستم توصیه‌گر فیلم را مورد بررسی قرار دادند. علاوه بر این، بسیاری از مطالعات اخیر را به صورت عمیق تشریح کردند و در نهایت، چالش‌های مختلف در مورد سیستم-های توصیه‌گر فیلم و پیشرفت‌های احتمالی آینده در این زمینه را مورد بحث قرار دادند[۲۵].تحلیل سیستم توصیه‌کننده فیلم مبتنی بر احساس با استفاده از ویژگی‌های احساس فازی در [۲۶]توسط ساراسوات و همکاران انجام شد. تاکید آن‌ها برای بهبود سیستم توصیه گر مبتنی بر آیتم به کمک استخراج احساسات مختلف کاربران بوده است. لی و همکاران در سال ۲۰۲۲ بهبود سیستم توصیه‌گر فیلم مبتنی بر گراف با استفاده از تجربه سینمایی را ارائه دادند. در این مقاله از اطلاعات مربوط به احساسات و عواطف همراه با رتبه‌بندی کاربران برای بهبود سیستم توصیه‌گر فیلم استفاده شد[۲۷]. سلوم و راجامانتری در ۲۰۲۱ سیستم‌های توصیه‌گر فیلم با استفاده از پالایش مشارکتی را پیاده‌سازی و ارزیابی کردند. آنها از فاکتورسازی ماتریسی و فیلتر مشارکتی مبتنی بر کاربر با تابع تشابه کسینوس در مجموعه داده مووی لنز استفاده نمودند [۲۸]. انوار و اوما در ۲۰۲۱ رویکردهای سیستم توصیه‌گر و توصیه فیلم با استفاده از فیلتر مشارکتی را به‌طور جامع مطالعه نمودند [۲۹]. در این مقاله توصیه‌گر فیلم مبتنی بر پالایش مشارکتی و تجزیه مقادیر منفرد بهبود یافته[1] پیشنهاد شده است که میزان خطای کمتری دارد و بر مشکلات شروع سرد[2] و پراکندگی داده‌ها[3] غلبه می‌کند. طهماسبی و همکاران در ۲۰۲۰ یک سیستم توصیه‌کننده فیلم اجتماعی مبتنی بر شبکه رمزگذار خودکار عمیق با استفاده از داده‌های توییتر پیشنهاد نمودند آنها از فیلتر مشارکتی و مبتنی بر محتوا و همچنین نفوذ اجتماعی کاربران استفاده نمودند[۳۰]. در این مرجع نویسندگان به کمک یک پایگاه داده ترکیبی، پراکندگی داده را کاهش داده و اطلاعات مورد نیاز برای دستیابی به دقت بالاتر برای سیستم توصیه گر فراهم نمودند. یک مدل از توضیحات اجتماعی برای یک سیستم توصیه فیلم محاوره‌ای بوسیله‌ی پکون و همکاران در ۲۰۱۹ پیشنهاد شد [۳۱].

تاکید آن‌ها بر روی بهبود کیفیت درک شده سیستم و تعامل به کمک توضیحات اجتماعی است. سینگ و همکاران در ۲۰۲۰ سیستم توصیه فیلم با استفاده از شباهت کسینوس وKNN ارائه دادند. در رویکرد آن‌ها توصیه‌های کلی بر اساس محبوبیت فیلم و/یا ژانر به هر کاربر ارائه شدند [۳۲]. هدف آن‌ها کاهش پیچیدگی مدل سیستم توصیه گر است. ردی و همکاران در ۲۰۱۹ سیستم توصیه فیلم مبتنی بر محتوا با استفاده از همبستگی ژانر در [۳۳] ارائه نمودند. تاکید آن‌ها ایجاد یک سیستم توصیه گر بر اساس ژانر فیلم بر روی مجموعه داده مووی لنز است. گوپتا و همکاران در ۲۰۲۰ سیستم توصیه فیلم با استفاده از فیلتر مشارکتی پیشنهاد نمودند. آن‌ها برای اثبات اثربخشی،از الگوریتم‌های K-NN و فیلتر مشارکتی برای تمرکز بر افزایش دقت نتایج در مقایسه با فیلتر مبتنی بر محتوا استفاده کردند. رویکرد استفاده شده در [۳۴] مبتنی بر شباهت کسینوس با استفاده از K نزدیکترین همسایه با کمک یک تکنیک فیلتر مشارکتی است که معایب فیلتر مبتنی بر محتوا را برطرف می کند. ژانگ و همکاران در ۲۰۲۰ یک نمونه اولیه و ارزیابی عملی از سیستم توصیه فیلم زمان واقعی شخصی سازی شده ارائه دادند. روش آن‌ها توانسته است که پیچیدگی زمانی را تا حد امکان کاهش دهد[۳۵]. لانگ و همکاران در ۲۰۲۱ سیستم توصیه فیلم برای اهداف آموزشی براساس ماشین فاکتورسازی میدانی پیشنهاد نمودند [۳۶].در الگوریتم پالایش مشارکتی آن‌ها، داده‌های ویژگی کاربر و آیتم به‌عنوان یک بردار ویژگی با ارزش واقعی بیان می‌شود و از مقدار رتبه‌بندی کاربر برای آیتم به عنوان برچسب کلاس استفاده می‌شود. تاکید آنها بر کاهش پراکندگی داده‌های ووردی است. چادهاری و همکاران در ۲۰۲۱ یک سیستم توصیه‌گر مبتنی بر اعتماد چندوجهی با رویکردهای یادگیری ماشین برای توصیه فیلم پیشنهاد نمودند [۳۷]. در این مرجع، مدل توصیه مبتنی بر محبوبیت برای حل مشکل کاربر سرد که به طور معمول در فیلتریتگ مشارکتی رخ می دهد استفاده شده است. تاکید نویسندگان در [۳۷] توسعه مدل پیشنهادی با استفاده از تکنیک‌های مختلف یادگیری ماشین و سپس استفاده از فیلتر مبتنی بر اعتماد برای توصیه با دقت بیشتر است. آهوجا و همکاران در ۲۰۱۹ یک سیستم پیشنهاد فیلم با

[1] . singular value decomposition plus-plus (SVD++)

[2] . cold-start

[3] . data sparsity

UNCORRECTED PROOF

استفاده از خوشه بندی K میانگین و K نزدیکترین همسایه در [۳۸] ارائه نمودند. تاکید آن‌ها کاهش معیار جذر میانگین مربعات خطا[1] است. بهالسه و تاخور در ۲۰۲۱ یک الگوریتم سیستم توصیه فیلم با استفاده از پالایش مشارکتی ارائه دادند، که هدف آن حذف مشکل پراکندگی از طریق یک رویکرد فیلتر مشارکتی تجزیه مقادیر منفرد و تشابه کسینوس است که در یک سیستم توصیه فیلم مبتنی بر وب اعمال می شود. آنها مدل را با یک فرم فاکتورسازی که تعداد پارامترهای مدل را با پیچیدگی کنترل‌شده، کاهش می‌دهد، ارتقا دادند. [۳۹]. دربان و ولی پور در ۲۰۲۲ یک سیستم توصیه ترکیبی مبتنی بر گراف با کاربرد توصیه فیلم در [۴۰] پیشنهاد نمودند. این مقاله یک روش سیستم توصیه‌کننده را با استفاده از یک مدل مبتنی بر گراف همراه با شباهت رتبه‌بندی‌های کاربران در ترکیب با اطلاعات جمعیت شناختی و موقعیت مکانی آنها ارائه می‌کند. ردی و همکاران در ۲۰۲۰ تجزیه و تحلیل سیستم‌های توصیه‌گر فیلم را با و بدون در نظر گرفتن فیلم های دارای امتیاز پایین در [۴۱] مطالعه نمودند و مشخص شد که فیلم-های دارای رتبه پایین در پیش‌بینی فیلم مفید نیستند. شارما و یاداو در ۲۰۲۰ یک سیستم توصیه فیلم با استفاده از پالایش مشارکتی مبتنی بر آیتم را پیشنهاد نمودند [۴۲]. نویسندگان در این مرجع بر روی علایق شخص کاربران تمرکز نمودند. هدف آن‌ها بهبود دقت توصیه به کمک اطلاعات گرفته شده از بررسی‌های پشیین کاربران در مورد فیلم‌ها است.چن و تانگ در ۲۰۱۹ یک مطالعه تطبیقی درباره ترکیب تجزیه مقادیر منفرد با تکنیک فیلتر مشارکتی مبتنی بر کاربر برای یک سیستم توصیه فیلم انجام دادند در این مطالعه، ابتدا الگوریتم سنتی فیلتر مشارکتی مبتنی بر کاربر به عنوان خط مبنا توصیف و سپس از تکنیک‌های مختلفی از جمله تجزیه مقادیر منفرد، شباهت کسینوس و همبستگی پیرسون برای بررسی و مقایسه عملکرد یک سیستم توصیه فیلم مقیاس کوچک استفاده شده است. نتایج تجربی این مطالعه نشان می‌دهد که فیلتر مشارکتی مبتنی بر کاربر که از تجزیه مقادیر منفرد و همبستگی پیرسون استفاده می‌کند بهتر از یک فیلتر مشارکتی مبتنی بر کاربر سنتی عمل می‌کند[۴۳]. کومار و پرابهو در ۲۰۲۰ یک سیستم توصیه‌گر فیلم مشارکتی ترکیبی با استفاده از خوشه‌بندی K-means با بهینه‌سازی کلونی مورچه‌ها بر روی مجموعه داده مووی لنز ارائه دادند [۴۴]. آن‌ها بر روی بهبود خوشه بندی به کمک الگوریتم کلونی مورچگان تمرکز نمودند. یک سیستم پیشنهاد فیلم براساس پالایش مشارکتی با استفاده از آپاچی اسپارک در [۴۵] توسط الجونید و منجایا بررسی شد. آن‌ها بر انتخاب پارامترهایی از الگوریتم حداقل مربعات متناوب[2] تمرکز نمودند که می‌تواند بر عملکرد ساختار یک سیستم توصیه‌گر مقاوم تأثیر بگذارد.

با توجه به اینکه وزن‌های شباهت و نزدیک‌ترین همسایه‌ها بر کیفیت سیستم توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی تاثیرگذارند[۱۳]، بررسی مطالعات انجام شده در زمینه سیستم‌های توصیه‌گر پالایش مشارکتی، نشان داد که در برخی از مطالعات از توابع شباهت سنتی نظیر پیرسون و کسینوسی استفاده شده است که پیچیدگی و هزینه محاسباتی بالایی دارند و در برخی دیگر به اثر وزن در توابع شباهت توجه نشده است. بنابراین این توابع شباهت نمی‌توانند موجب بهبود عملکرد سیستم‌های توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی شوند [۲۳ و ۲۴ و ۲۶ و ۲۸ و ۳۲ و ۳۴ و ۳۵ و ۳۹ و ۴۰ و ۴۳ و ۴۶ و ۴۷ و ۴۸]. علاوه بر این در تعدادی از مطالعات مقدار k در الگوریتم KNN ثابت در نظر گرفته شده است که به دلیل اینکه کاربران مختلف ترجیحات و سطوح شباهت متفاوتی دارند، می‌تواند به توصیه‌های غیربهینه منجر شود[۳۲ و ۳۴ و ۳۹ و ۴۳]. در تحقیقات گذشته مقدار بهینه وزن‌های تابع شباهت توسط الگوریتم گرگ خاکستری فازی ترکیب‌شده با شیر [۴۹] و نیز یک الگوریتم فراابتکاری ترکیبی جدید [۵۰] تعیین شد. با توجه به شکاف تحقیقاتی ذکر شده در این مقاله مقدار بهینه وزن‌های تابع شباهت و نیز پارامتر k توسط یک الگوریتم بهینه‌سازی هوشمند ترکیبی جدید تنظیم می‌شود.

[1] .RMSE(Root Mean Squared Error)

[2] .ALS(Alternating Least Squares)

UNCORRECTED PROOF

۳- روش تحقیق

تحقیق از حیث هدف، کاربردی و از حیث روش، مدلسازی است. طراحی سیستم توصیه‌گر پیشنهادی در این تحقیق، به شرح ذیل می‌باشد.

۳-۱- مراحل اجرای سیستم توصیه‌گر پیشنهادی

مرحله اول: محاسبه شباهت

در طراحی سیستم توصیه‌گر از تابع شباهت ارائه شده توسط بوبادیلا و همکاران در سال ۲۰۱۱ استفاده شده است که به صورت یک ترکیب خطی ساده از مقادیر و وزن‌ها است. وجود وزن در این تابع نشاندهنده اهمیت امتیاز کاربران به آیتم‌ها است که با تنظیم آن می‌توان به دقت بیشتر دست یافت. همچنین این تابع شباهت منجر به میانگین خطای مطلق[1] کمتری در مقایسه با توابع شباهت سنتی و بهبود معیارهای دقت[2] و فراخوانی[3] به ازای هر تعداد توصیه می‌شود و نیز به دلیل سادگی فرمول آن در مقایسه با توابع شباهت کلاسیک، کاهش زمان پیش‌بینی و در نتیجه تسریع فرآیند توصیه را در پی دارد. براساس این تابع، شباهت میان هر دو کاربر a و u به صورت رابطه (۱) تعریف شده است[۷].

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

در رابطه (۱)، M بالاترین رتبه و m پایین‌ترین رتبه تعریف شده در سیستم است که کاربر می‌تواند به هر یک از آیتم‌ها بدهد، $V_{a,u}$ بردار مقادیر برای هر زوج کاربر a,u است که به صورت $V_{a,u}=\left(v_{a,u}^{(0)},\dots,v_{a,u}^{(M-m)}\right)$ تعریف می‌شود و تعداد عناصر آن برابر با تعداد رتبه‌های امکان‌پذیری است که یک کاربر می‌تواند به یک آیتم اختصاص دهد. هر عنصر $v_{a,u}^{(i)}$ از بردار $V_{a,u}$ به صورت کسر $\frac{A}{B}$ تعریف می‌شود که در آن B نشاندهنده تعداد آیتم‌های رتبه‌بندی شده توسط هر دو کاربر (یعنی $r_a^{(j)}\neq 0, r_u^{(j)}\neq 0$) و A تعداد آیتم‌های رتبه‌بندی شده توسط هر دو کاربر است، با این شرط که تفاضل مطلق رتبه‌بندی‌های کاربر a و کاربر u برابر i باشد $\left(\left|r_a^j-W\cdot r_u^j\right|=i\right)$ بردار وزن و هم اندازه با بردار V می‌باشد به طوری که وزن‌ها مجهول بوده و در قالب یک مسئله بهینه‌سازی تنظیم می‌شوند[۷].

مرحله دوم: یافتن k نزدیکترین همسایه

الگوریتم k نزدیکترین همسایه[4] رایج‌ترین تکنیک برای محاسبه همسایگی در سیستم‌های توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی است [۱۱ و ۱۳ و ۳۸ و ۵۱ و ۵۲]. بنابراین در طراحی سیستم توصیه‌گر پیشنهادی از الگوریتم k نزدیکترین همسایه مبتنی بر کاربر استفاده شده است. در این مرحله با توجه به شباهت بدست آمده، k نزدیکترین همسایه به کاربر انتخاب می‌شود.

$$S(a)=\{u|\mathrm{rank}(\mathrm{sim}(a,u))\le k\} \qquad (۲)$$

براساس رابطه (۲)، $S(a)$ شامل k شبیه‌ترین کاربران به کاربر فعال a است. تعیین مقدار ثابت برای پارامتر k قبل از فرآیند توصیه، ممکن است بهینه نباشد[۵۳]. از این رو مقدار k در قالب یک مسئله بهینه‌سازی تنظیم می‌شود.

مرحله سوم: پیش بینی رتبه‌ها

برای پیش‌بینی رتبه کاربر هدف به یک آیتم خاص از فرمول استاندارد پروژه گروپ‌لنز (تجمیع وزنی تعدیل شده[5] /انحراف از میانگین[6]) که در سال ۱۹۹۴ توسط رسنیک و همکاران ارائه شد، استفاده می‌شود[۵۴]. در این فرمول در عبارت اول میانگین امتیازات کاربر هدف و در عبارت دوم امتیازاتی که k نزدیکترین همسایه داده‌اند در نظر گرفته شده است، بدین صورت که با در نظر گرفتن میانگین امتیازات کاربر هدف و اثر k نزدیکترین همسایه، پیش‌بینی انجام می‌شود. این فرمول برای پیش‌بینی رتبه در سیستم‌های توصیه‌گر پالایش مشارکتی مبتنی بر همسایگی کاربرمحور که براساس الگوریتم KNN طراحی شده‌اند، قابل استفاده است[۵۴].

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

[1] .Mean Absolute Error (MAE)

[2] .Precision

[3] .Recall

[4] . K Nearest Neighbours (K-NN)

[5] . adjusted weighted aggregation

[6] . deviation-from-mean

UNCORRECTED PROOF

در این رابطه $U_i \cap S(a)$ مجموعه‌ای از k نزدیکترین همسایه کاربر a را نشان می دهد که آیتم i را رتبه‌بندی کرده‌اند، $\bar{r}_a$ و $\bar{r}_u$ میانگین رتبه‌های هر کاربر (a کاربر هدف و u کاربر همسایه است) که براساس سابقه رتبه‌بندی آنها محاسبه می‌شود. $r_{u,i}$ رتبه کاربر همسایه u برای آیتم i و $sim(a,u)$ شباهت کاربر هدف a و همسایه u است[۵۴].

مرحله چهارم: توصیه

سیستم توصیه‌گر آیتم‌هایی با بالاترین رتبه پیش‌بینی شده (P_a^i) را به کاربر هدف a پیشنهاد می‌دهد.

سپس معیارهای استاندارد و پیشنهادی برای مقایسه رتبه پیش‌بینی‌شده با رتبه واقعی کاربر و نیز ارزیابی توصیه‌ها، مورد استفاده قرار می‌گیرند که در ادامه بررسی می‌شوند.

۳-۲- معیارهای ارزیابی سیستم توصیه‌گر پیشنهادی

میانگین خطای مطلق[1]

میانگین خطای مطلق که به طور گسترده در سیستم‌های توصیه‌گر به منظور اندازه‌گیری تفاوت بین رتبه پیش‌بینی‌شده و رتبه واقعی به کار می‌رود [۵۵]، برای کاربر U به صورت زیر محاسبه می‌شود:

$$MAE(U) = \frac{\sum_{i \in I} |A_{u,i} - P_{u,i}|}{|I_u|} \quad (۴)$$

I_u : تعداد آیتم‌هایی که کاربر U به آن‌ها امتیاز داده است.

$P_{u,i}$ و $A_{u,i}$: رتبه‌های واقعی و پیش‌بینی شده کاربر U در داده‌های آزمایشی.

از رابطه (۵) برای محاسبه میانگین خطای مطلق برای تمام کاربران در پایگاه داده استفاده می‌شود.

$$MAE = \frac{\sum_{u=1}^{k} MAE(U)}{K} \quad (۵)$$

دقت[2] و فراخوانی[3]

این دو معیار به طور معمول برای ارزیابی اطلاعات در سیستم‌های توصیه‌گر استفاده می‌شوند[۵۶]. برای محاسبه این معیارها ابتدا باید معیارهای زیر را محاسبه کنید.

نرخ مثبت درست (T_P[4]): تعداد آیتم‌های موجود در لیست پیشنهادی که کاربر هدف به آنها علاقه‌مند بوده است.

نرخ مثبت نادرست (F_P[5]): تعداد آیتم‌های موجود در لیست پیشنهادی که کاربر هدف به آنها علاقه‌مند نبوده است.

نرخ منفی نادرست (F_N[6]): تعداد آیتم‌هایی که کاربر هدف به آنها علاقه‌مند بوده ولی سیستم پیشنهادی آن‌ها را توصیه نکرده است.

معیارهای صحت و فراخوانی به ترتیب براساس روابط (۶) و (۷) محاسبه می‌شوند:

$$Precision = \frac{T_P}{T_P + F_P} \quad (۶)$$

$$Recall = \frac{T_P}{T_P + F_N} \quad (۷)$$

معیار ارزیابی F[7]

با توجه به اینکه با افزایش تعداد پیشنهادات Recall افزایش و Precision کاهش می‌یابد، این دو معیار به صورت فرمول زیر با یکدیگر ترکیب و معیار F تعریف می‌شود[۵۶].

$$F = \frac{2 \times Precision \times Reacall}{Precision + Recall} \quad (۸)$$

معیار ارزیابی پیشنهادی

---

[1] . Mean Absolute Error (MAE)

[2] .Precision

[3] .Recall

[4] True positive

[5] False Positive

[6] False Negative

[7] .F-Measure

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

UNCORRECTED PROOF

معیار پیشنهادی عبارتست از مجموع میانگین خطای مطلق و معکوس معیارهای دقت، فراخوانی و F (به دلیل کمینه‌سازی تابع هزینه پیشنهادی، از معکوس معیارهای Precision، Recall و F استفاده شده است) که مطابق با رابطه (۹) تعریف می‌شود:

$$J = MAE + \frac{1}{Precision} + \frac{1}{Recall} + \frac{1}{F} \qquad (۹)$$

۱/۱. شبه کد سیستم توصیه‌گر پیشنهادی

با توجه به مراحل پیش‌بینی، شبه کد سیستم توصیه‌گر پیشنهادی به صورت زیر می‌باشد.

1. Load Movielens dataset
2. Calculate the score matrix h with size $r * c$
3. Calculate the v matrix
4. Calculate the similarities by the Similarity function $(sim_w(a,u))$ using the optimal w obtained through proposed algorithm
5. Find the optimal k obtained through proposed algorithm
6. Sort $sim_w(a,u)$ in Descending order and Obtain index for k users
7. Find K nearest neighbor to user a
8. Calculate the average of the rating made by user a and k nearest neighbor to user a
9. Calculate the prediction of user a for item i using adjusted weighted aggregation (deviation-from-mean)
10. Calculate MAE
11. Calculate Precision
12. Calculate Recall
13. Calculate F-measure
14. Calculate J

در این مقاله، به منظور تعیین بردار وزن بهینه تابع شباهت رابطه (۱) و مقدار بهینه k نزدیکترین همسایه، یک الگوریتم بهینه‌سازی هوشمند ترکیبی جدید ارائه می‌شود که در ادامه مورد بررسی قرار می‌گیرد.

۳-۳- الگوریتم بهینه‌سازی هوشمند ترکیبی پیشنهادی (IFGWOLOADENM)

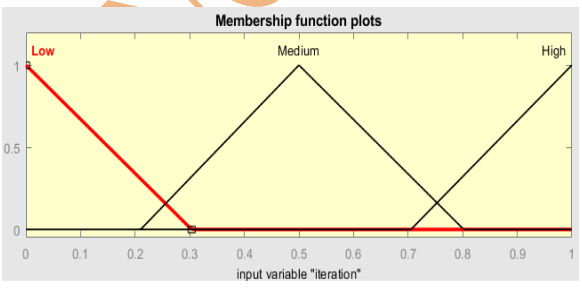
مراحل طراحی الگوریتم بهینه‌سازی هوشمند ترکیبی پیشنهادی (IFGWOLOADENM) به شرح زیر است.

مرحله اول: انتخاب الگوریتم پایه

با درنظرگرفتن برتری الگوریتم‌های بهینه‌سازی فراابتکاری هوش ازدحامی در حل مسائل بهینه‌سازی مدرن و با توجه به پیوسته بودن مسئله تعیین وزن‌های بهینه، الگوریتم بهینه‌ساز گرگ خاکستری ارائه شده توسط میرجلیلی و همکاران در سال ۲۰۱۴ به دلیل عملکرد خوب، سادگی اجرا، کمترین تعداد پارامتر برای تنظیم و نیز توانایی در حل مسائل واقعی، به عنوان الگوریتم پایه انتخاب شد[۱۷].

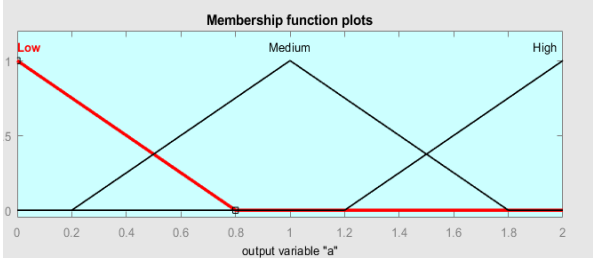
مرحله دوم: فازی‌سازی

براساس مطالعه رودریگز و همکاران در سال ۲۰۱۷ در خصوص بهبود عملکرد الگوریتم گرگ خاکستری با استفاده از منطق فازی[۵۷]، در این تحقیق پارامتر a و پارامتر C به عنوان پارامترهای اصلی الگوریتم [۵۷] با استفاده از منطق فازی به صورت پویا تنظیم شدند که به بهبود اکتشاف و استخراج الگوریتم گرگ خاکستری منجر شد. بدین منظور یک سیستم استنتاج فازی با ورودی تکرارهای نرمال شده الگوریتم و خروجی‌های a و C، برای ورودی و هر خروجی سه تابع عضویت مثلثی (کم ، متوسط و زیاد) نوع ممدانی و فاززدایی مرکز ثقل طراحی شد که در شکل ۱ الی ۳ توابع عضویت نشان داده شده‌اند.

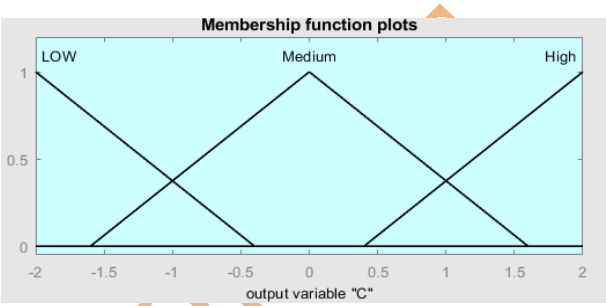


شکل۱- توابع عضویت ورودی تکرار

CORRECTED PROOF



شکل۲- توابع عضویت خروجی a



شکل ۳- توابع عضویت خروجی C

مرحله سوم: بهبود جستجوی محلی

در این مرحله به منظور افزایش تنوع حرکت گرگ‌ها از فرمول تعیین موقعیت جدید شکار الگوریتم بهینه‌سازی شیر در الگوریتم پیشنهادی استفاده شده است که بر بهبود جستجوی محلی (فرآیند استخراج) الگوریتم نیز تاثیر می‌گذارد[۵۸]. به این صورت که به احتمال ۰/۵ درصد موقعیت گرگ‌ها براساس رابطه (۱۰) (معادلات اصلی الگوریتم گرگ خاکستری)[۱۷] و درغیراینصورت طبق رابطه (۱۲) (معادلات مربوط به فرآیند شکار الگوریتم شیر)[۵۸] به‌روزرسانی می‌شود.

(۱۰)

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

در رابطه (۱۰)، t نشان‌دهنده تکرار فعلی است و ضرایب A_1 ، A_2 و A_3 براساس a فازی طبق رابطه (۱۱) تنظیم می‌شوند.

$$A = 2a(t)(rand) - a(t) \qquad (۱۱)$$

(۱۲)

$$X_1 = X_\alpha(t) + (rand)(PI_1)(X_\alpha(t) - X(t))$$
$$X_2 = X_\beta(t) + (rand)(PI_2)(X_\beta(t) - X(t))$$
$$X_3 = X_\delta(t) + (rand)(PI_3)(X_\delta(t) - X(t))$$

که در آن PI نرخ بهبود برازندگی هستند که از روابط زیر محاسبه می‌شود:

(۱۳)

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

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \qquad (۱۴)$$

رابطه (۱۴) به‌روزرسانی موقعیت گرگ‌ها مبتنی بر بهترین سه گرگ است، در واقع $X_{(t+1)}$ یک گرگ امگا است که باید به سمت جاییکه رهبران دسته (مرکز) نشان می‌دهند، حرکت کند.

مرحله چهارم: بهبود جستجوی سراسری

تا این مرحله از طراحی الگوریتم، نیمی از تکرارها به اکتشاف و نیمی دیگر به استخراج اختصاص داده شده است. در نتیجه ممکن است الگوریتم در بهینه محلی گیر کند. زیرا 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. بنابراین برای

UNCORRECTED PROOF

برطرف کردن این مشکل در این مرحله، با الگوریتم تکامل تفاضلی[1] ترکیب می‌شود که یک فراابتکاری ساده و کارآمد برای بهینه‌سازی سراسری در فضاهای پیوسته است و برای مینیمم‌سازی توابع پیوسته غیرخطی و مشتق‌ناپذیر ارائه شده است که سریعتر و با قطعیت بیشتری نسبت به سایر روشهای بهینه‌سازی سراسری همگرا می‌شود[۵۹] و نیز عملکرد برتری نسبت به استراتژی‌های تکامل[2] و الگوریتم‌های ژنتیک[3] دارد[۶۰]. الگوریتم تکامل تفاضلی به دلیل عملگر جهش[4]، قادر به اکتشاف فضای جدید است[۶۱] و به بهبود توانایی اکتشاف و جستجوی سراسری الگوریتم کمک می‌کند. در واقع به کمک عملگرهای جهش رابطه‌ی (۱۵) و تقاطع دو جمله‌ای[5] رابطه‌ی (۱۶) در تکامل تفاضلی، جهش و تقاطع حول موقعیت فعلی گرگ‌ها اتفاق می‌افتد.

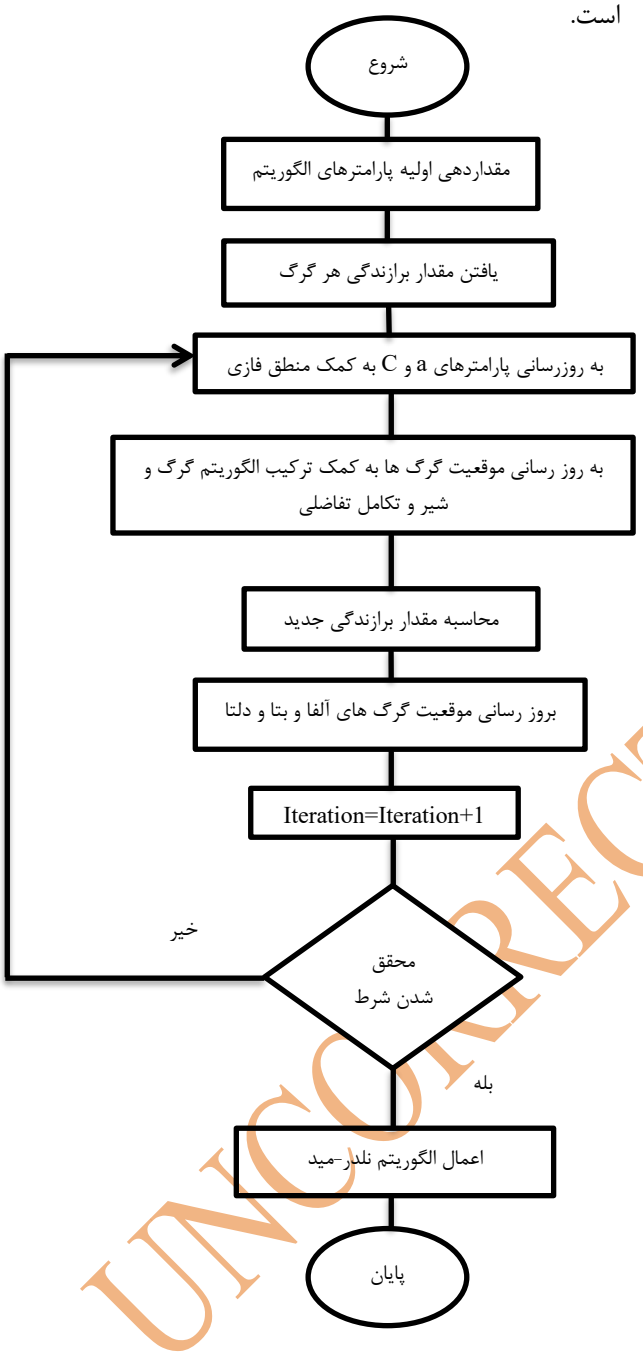
$$Y = a + \beta(b - c) \quad (۱۵)$$

$$z_j = \begin{cases} y_j; & r_j \le p_{CR} \text{ or } j = j_0 \\ x_j; & \text{otherwise} \end{cases} \quad (۱۶)$$

مرحله پنجم: بهبود جستجوی محلی

الگوریتم فراابتکاری ترکیبی طراحی شده تا این مرحله (گرگ خاکستری فازی ترکیب شده با الگوریتم بهینه‌سازی شیر و الگوریتم تکامل تفاضلی) به عنوان یک الگوریتم جستجوی تصادفی، نمی‌تواند همگرایی به راه‌حل بهینه سراسری را تضمین کند. بنابراین با الگوریتم نلدرمید (به عنوان یک الگوریتم جستجوی محلی در اطراف راه‌حل بهینه یافت شده)، به منظور رسیدن به راه‌حل بهینه سراسری، ترکیب و منجر به یک الگوریتم بهینه‌سازی هوشمند ترکیبی جدید می‌شود[۶۲].

از میان کلیه‌ی بردارهای W و مقدار k تولید شده به کمک الگوریتم بهینه‌سازی هوشمند ترکیبی پیشنهادی، برداری انتخاب می‌شود که تابع هزینه پیشنهادی رابطه (۹) را کمینه کند. در ادامه فلوچارت الگوریتم بهینه‌سازی هوشمند ترکیبی پیشنهادی در شکل ۴ نشان داده شده است.



شکل ۴- فلوچارت الگوریتم بهینه‌سازی هوشمند ترکیبی پیشنهادی

[1] . Differential Evolution (DE)

[2] . Evolution Strategies (ESs)

[3] . Genetic Algorithms (GAs)

[4] .Mutation

[5] .binomial crossover

UNCORRECTED PROOF

شبه کد الگوریتم پیشنهادی به صورت زیر می‌باشد.

Initialize the grey wolf population $X_i (i = 1,2, \dots, n)$

while (t < Max number of iterations)

Calculate the fitness of each search agent
X_α= the best search agent
$PI_1 = \frac{|f(X(t)) - f(X_\alpha(t))|}{f(X_\alpha)}$
X_β= the second best agent
$PI_2 = \frac{|f(X(t)) - f(X_\beta(t))|}{f(X_\beta)}$
X_δ = the third best search agent
$PI_3 = \frac{|f(X(t)) - f(X_\delta(t))|}{f(X_\delta)}$

Obtain Fuzzy outputs **a** and **C**
Update **A**

for each search agent

If a random number>0.5
Update the position of X_1 and X_2 and X_3 using the base equation of GWO

else
$X_1 = X_\alpha(t) + (rand)(PI_1)(X_\alpha(t) - X(t))$

$X_2 = X_\beta(t) + (rand)(PI_2)(X_\beta(t) - X(t))$

$X_3 = X_\delta(t) + (rand)(PI_3)(X_\delta(t) - X(t))$

$X(t+1) = \frac{X_1 + X_2 + X_3}{3}$
end for

DE Algorithm
Calculate a_1 , b_1 , c_1
Calculate β
mutation : $y = X_{a_1} + \beta(X_{b_1} - X_{c_1})$
binomial crossover for calculating the new positions X_2
Calculate the fitness of X_2 then update X_α , X_β , X_δ

$t = t + 1$
end while

Applying the nelder-mead using **fmincon function** with input of X_α

Calculate the fitness of new X_α then update X_α

return X_α

۴- تحلیل داده‌ها و یافته‌های پژوهش

در این بخش نتایج مربوط به ارزیابی سیستم توصیه‌گر و الگوریتم پیشنهادی آورده شده است.

۴-۱- ارزیابی سیستم توصیه‌گر

شبیه سازی روی فولد u5

برای ارزیابی اولیه، فولد شماره ۵ (u5) مورد استفاده قرار گرفت. در گام نخست، ماتریس v محاسبه شد و سپس یک بردار متغیر به صورت مجهول تعریف شد، به طوری که پنج پارامتر اول این بردار، به عنوان وزن‌ها و آخرین پارامتر، به عنوان تعداد همسایه‌ها (k) در نظر گرفته شد. محدوده بردار متغیر به صورت زیر تعیین شده است.

(۱۷)

$$\text{VarMin} = [1 \quad 0.5 \quad -0.5 \quad -2 \quad -3 \quad 10]$$
$$\text{VarMax} = [3 \quad 2 \quad 0.5 \quad -0.5 \quad -1 \quad 200]$$

تابع هزینه برای الگوریتم پیشنهادی طبق رابطه (۹) عبارتست از مجموع میانگین خطای مطلق و معکوس معیارهای دقت، فراخوانی و F که با این تابع هزینه پیشنهادی انتظار می‌رود که نتایج بهتری بدست آید. برای دو الگوریتم GWO و PSO تابع هزینه MAE است که به طور معمول برای ارزیابی سیستم توصیه‌گر استفاده می‌شود[۶۳].

تعداد کاربران همسایه برای الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات، برابر با مقدار ثابت ۱۰۰ است. همچنین بازه‌ی W برای این دو الگوریتم به صورت زیر در نظر گرفته شده است.

(۱۸)

$$\text{WMin} = [0.6 \quad 0.2 \quad -0.2 \quad -0.6 \quad -1]$$

UNCORRECTED PROOF

$$WMax = [\,1 \quad 0.6 \quad 0.2 \quad -0.2 \quad -0.6\,]$$

مقادیر بهینه‌ی متغیر BestVar (وزن‌ها و تعداد همسایه مجهول) برای الگوریتم پیشنهادی و W برای دو الگوریتم دیگر به صورت زیر بدست آمده است.

(۱۹)

BestVarIFGWOLIONNM=[1 0.6498 -0.054 -1.9881 -2.5613 142]

BestWPSO=[0.7114 0.3690 -0.1190 -0.5429 -0.8179]

BestWGWO=[0.6977 0.3783 -0.0041 -0.5488 -0.7512]

مقدار تابع هزینه پیشنهادی (رابطه (۹)) برای الگوریتم پیشنهادی در فولد u5، با در نظر گرفتن N=50 برابر با ۴/۵۶ و MAE برابر با ۰/۴۸۷است. در جدول ۱ الگوریتم پیشنهادی با الگوریتم‌های گرگ و بهینه‌سازی توده ذرات از نظر مقادیر تابع هزینه J و معیار MAE، مقایسه شده است. طبق داده‌های این جدول، مقادیر بدست آمده از الگوریتم پیشنهادی در مقایسه با سایر الگوریتم‌ها کمتر است.

جدول۱- مقایسه معیار J و MAE الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u5)

الگوریتم	MAE	J
گرگ خاکستری فازی ترکیب شده با شیر، تکامل تفاضلی و نلدرمید	۰/۴۸۷۰	۴/۵۶۰۰
گرگ خاکستری	۰/۵۶۳۷	۴/۸۱۷۲
توده ذرات	۰/۵۶۳	۴/۸۲۰۲

در ادامه در جداول ۲-۴ نتایج مقایسه میان معیارهای دقت، فراخوانی و F با تعداد بهینه k=142 برای الگوریتم پیشنهادی و تعداد ثابت k=100 برای دو الگوریتم دیگر نشان داده شده است. در این حالت تعداد توصیه‌ها از ۲ تا ۱۰۰ تغییر می‌کند.

جدول ۲- مقایسه معیار دقت الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u5)

	Precision		
	GWO	PSO	IFGWOLOADENM
N=2	۰/۹۷۸۸	۰/۹۶۹۸	۰/۹۸۷۸
N=5	۰/۹۷۳۳	۰/۹۶۵۹	۰/۹۸۲
N=10	۰/۹۴۶۲	۰/۹۴۰۶	۰/۹۶۴۹
N=15	۰/۹۱۲۵	۰/۹۰۶۸	۰/۹۳۸۹
N=20	۰/۸۷۲۸	۰/۸۶۸۳	۰/۹۰۱۹
N=25	۰/۸۳۰۹	۰/۸۲۶۸	۰/۸۵۹۷
N=30	۰/۷۹۱۰	۰/۷۸۷۸	۰/۸۲۰۲
N=35	۰/۷۵۳۵	۰/۷۵۰۸	۰/۷۸۴۱
N=40	۰/۷۱۹۶	۰/۷۱۷۷	۰/۷۵۱۶
N=45	۰/۶۸۹۶	۰/۶۸۷۷	۰/۷۲۱۲
N=50	۰/۶۶۲۰	۰/۶۵۹۶	۰/۶۹۳۳
N=55	۰/۶۳۵۹	۰/۶۳۳۴	۰/۶۶۷۴
N=60	۰/۶۱۱۷	۰/۶۰۹۴	۰/۶۴۲۹
N=65	۰/۵۸۹۲	۰/۵۸۷۵	۰/۶۲۰۶
N=70	۰/۵۶۸۶	۰/۵۶۶۳	۰/۵۹۹۵
N=75	۰/۵۴۹۰	۰/۵۴۶۷	۰/۵۷۹۹
N=80	۰/۵۳۱۳	۰/۵۲۹۰	۰/۵۶۱۸
N=85	۰/۵۱۴۵	۰/۵۱۲۴	۰/۵۴۴۸
N=90	۰/۴۹۸۸	۰/۴۹۷۰	۰/۵۲۹۰
N=95	۰/۴۸۴۳	۰/۴۸۲۵	۰/۵۱۳۹
N=100	۰/۴۷۰۱	۰/۴۶۸۳	۰/۴۹۹۶

CTED PROOF

جدول۳- مقایسه معیار فراخوانی الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u5)

	Recall		
	GWO	PSO	IFGWOLOADENM
N=2	۰/۱۰۰۳	۰/۰۹۹۹	۰/۱۰۳۶
N=5	۰/۲۳۳۵	۰/۲۳۳۲	۰/۲۴۱۶
N=10	۰/۴۱۳۴	۰/۴۱۲۵	۰/۴۲۶۷
N=15	۰/۵۳۵۱	۰/۵۳۳۷	۰/۵۵۰۸
N=20	۰/۶۱۷۲	۰/۶۱۶۲	۰/۶۳۵۲
N=25	۰/۶۷۶۰	۰/۶۷۵	۰/۶۹۴۲
N=30	۰/۷۲۱۷	۰/۷۲۱۰	۰/۷۴۱۲
N=35	۰/۷۵۷۹	۰/۷۵۷۵	۰/۷۷۹۱
N=40	۰/۷۸۸۱	۰/۷۸۷۸	۰/۸۱۰۴
N=45	۰/۸۱۲۳	۰/۸۱۲۲	۰/۸۳۵۴
N=50	۰/۸۳۲۰	۰/۸۳۱۸	۰/۸۵۵۷
N=55	۰/۸۴۸۷	۰/۸۴۸۴	۰/۸۷۲۷
N=60	۰/۸۶۳۱	۰/۸۶۲۷	۰/۸۸۷۳
N=65	۰/۸۷۵۳	۰/۸۷۵۳	۰/۹۰۰۱
N=70	۰/۸۸۶۰	۰/۸۸۵۹	۰/۹۱۱۱
N=75	۰/۸۹۵۱	۰/۸۹۵۲	۰/۹۲۰۶
N=80	۰/۹۰۳۷	۰/۹۰۳۹	۰/۹۲۹۱
N=85	۰/۹۱۱۳	۰/۹۱۱۶	۰/۹۳۶۸
N=90	۰/۹۱۷۶	۰/۹۱۸۱	۰/۹۴۳۲
N=95	۰/۹۲۳۳	۰/۹۲۳۷	۰/۹۴۸۹
N=100	۰/۹۲۸۲	۰/۹۲۸۶	۰/۹۵۳۹

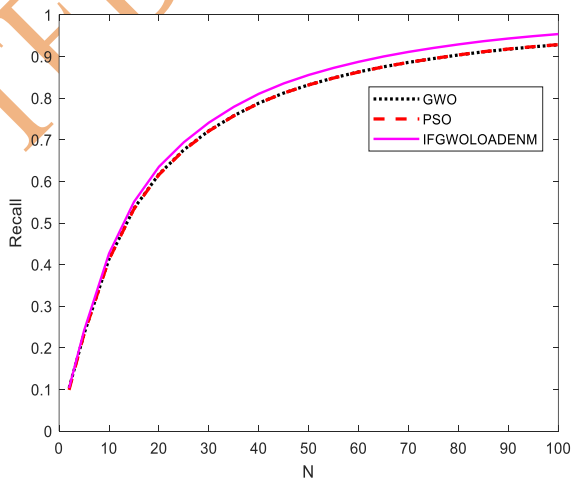
جدول ۴- مقایسه معیار F الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u5)

	F		
	GWO	PSO	IFGWOLOADENM
N=2	۰/۱۶۷۵	۰/۱۶۶۷	۰/۱۷۱۲
N=5	۰/۳۳۵۵	۰/۳۳۴۰	۰/۳۴۳۷
N=10	۰/۵۰۳۳	۰/۵۰۱۱	۰/۵۲۱۰
N=15	۰/۵۹۱۸	۰/۵۸۹۰	۰/۶۱۶۳
N=20	۰/۶۳۶۶	۰/۶۳۴۲	۰/۶۶۵۱
N=25	۰/۶۵۷۲	۰/۶۵۴۸	۰/۶۸۶۶
N=30	۰/۶۶۵۸	۰/۶۶۳۸	۰/۶۹۶۴
N=35	۰/۶۶۶۶	۰/۶۶۵۰	۰/۶۹۹۰
N=40	۰/۶۶۳۵	۰/۶۶۲۳	۰/۶۹۷۴
N=45	۰/۶۵۷۸	۰/۶۵۶۵	۰/۶۹۱۸
N=50	۰/۶۴۹۹	۰/۶۴۸۳	۰/۶۸۴۰
N=55	۰/۶۴۰۶	۰/۶۳۸۸	۰/۶۷۴۹
N=60	۰/۶۳۰۵	۰/۶۲۸۸	۰/۶۶۴۷
N=65	۰/۶۲۰۰	۰/۶۱۸۷	۰/۶۵۴۵
N=70	۰/۶۰۹۵	۰/۶۰۷۹	۰/۶۴۳۸
N=75	۰/۵۹۸۶	۰/۵۹۷	۰/۶۳۳۱
N=80	۰/۵۸۸۴	۰/۵۸۶۹	۰/۶۲۲۵
N=85	۰/۵۷۸۲	۰/۵۷۶۷	۰/۶۱۲۱
N=90	۰/۵۶۸۰	۰/۵۶۶۷	۰/۶۰۱۷
N=95	۰/۵۵۸۱	۰/۵۵۶۸	۰/۵۹۱۴
N=100	۰/۵۴۸۰	۰/۵۴۶۷	۰/۵۸۱۳

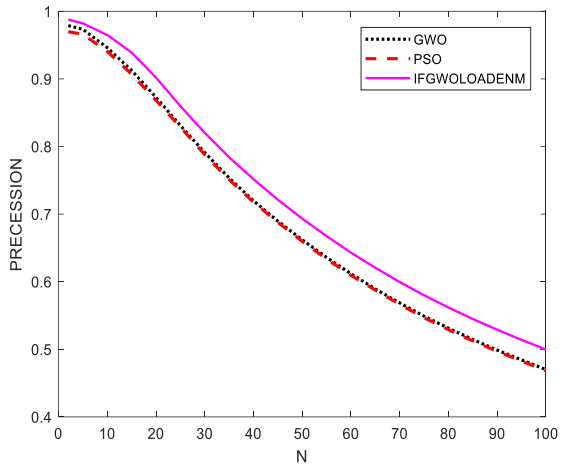
استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

هر چه معیارهای فراخوانی، دقت و F بزرگتر باشند، الگوریتم بهتر عمل کرده است. از جداول ۲ تا ۴ مشاهده می‌شود که برای همه مقادیر N در این سه معیار، الگوریتم پیشنهادی مقادیر بزرگتری بدست آورده است. به عنوان نمونه به ازای N=2 مقادیر فراخوانی، دقت و F برای الگوریتم پیشنهادی برابر با ۰/۱۰۳۶، ۰/۹۸۷۸ و ۰/۱۷۱۲ هستند در حالی که این مقادیر برای الگوریتم گرگ خاکستری به ترتیب برابر با ۰/۱۰۰۳، ۰/۹۷۸۸ و ۰/۱۶۷۵ و برای بهینه‌سازی توده ذرات به ترتیب برابر با ۰/۰۹۹۹، ۰/۹۶۹۸ و ۰/۱۶۶۷ می‌باشند.

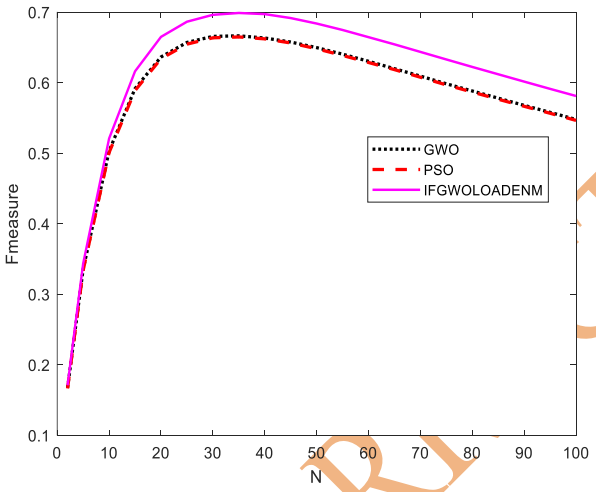
در شکل‌های ۵-۷ نتایج مربوط به معیارهای دقت، فراخوانی و F الگوریتم پیشنهادی و الگوریتم‌های GWO و PSO بر حسب تعداد توصیه نشان داده شده است.



شکل ۵- معیار Recall بر حسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u5)



شکل ۶-معیار Precision بر حسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u5)



شکل ۷- معیار F بر حسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u5)

از شکل‌های ۵-۷ مشاهده می‌شود که مقادیر فراخوانی، دقت و معیار F بدست آمده از روش پیشنهادی در مقایسه با PSO و GWO بیشتر شده‌اند به این معنا که الگوریتم پیشنهادی بهتر از دو الگوریتم دیگر عمل نموده است.

UNCORRECTED PROOF

شبیه سازی روی فولد u1

در ارزیابی فولد شماره ۱ (u1)، محدوده بردار متغیر به صورت زیر فرض شده است.

(۲۰)

$$VarMin = [1 \quad 0.5 \quad -0.5 \quad -2.5 \quad -4 \quad 10]$$

$$VarMax = [3 \quad 2.5 \quad 0.5 \quad -0.5 \quad -1 \quad 200]$$

تابع هزینه برای الگوریتم پیشنهادی طبق رابطه (۹) و برای دو الگوریتم GWO و PSO تابع هزینه MAE است.

تعداد کاربران همسایه برای الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات، برابر با مقدار ثابت ۱۰۰ است. همچنین بازه‌ی W برای این دو الگوریتم به صورت زیر در نظر گرفته شده است.

(۲۱)

$$WMin = [0.6 \quad 0.2 \quad -0.2 \quad -0.6 \quad -1]$$

$$WMax = [1 \quad 0.6 \quad 0.2 \quad -0.2 \quad -0.6]$$

مقادیر بهینه‌ی متغیر BestVar برای الگوریتم پیشنهادی و W برای دو الگوریتم دیگر به صورت زیر بدست آمده است.

(۲۲)

$$BestVarIFGWOLIONNM = [1.0000 \quad 0.6198 \quad -0.1535 \quad -2.2774 \quad -3.0000 \quad 152]$$

$$BestWPSO = [0.6072 \quad 0.4183 \quad -0.1043 \quad -0.5756 \quad -0.9290]$$

$$BestWGWO = [0.6044 \quad 0.4325 \quad -0.0269 \quad -0.4301 \quad -0.8376]$$

پس از اجرای شبیه‌سازی با N برابر ۵۰، مقدار تابع هزینه پیشنهادی رابطه (۹) برای الگوریتم پیشنهادی برابر با ۴/۵۵۸۴ و MAE برابر ۴۹۰۷/ شده است. در جدول ۵ از نظر مقادیر تابع هزینه J و معیار MAE، الگوریتم پیشنهادی با الگوریتم‌های گرگ و بهینه‌سازی توده ذرات مقایسه شده است. طبق جدول ۵، مقادیر MAE و J الگوریتم پیشنهادی در مقایسه با دو الگوریتم دیگر کمتر است که نشان‌دهنده بهبود عملکرد سیستم توصیه‌گر می‌باشد.

جدول۵- مقایسه معیار J و MAE الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u1)

الگوریتم	MAE	J
بهینه‌سازی گرگ خاکستری فازی ترکیب شده با الگوریتم‌های شیر، تکامل تفاضلی و نلدرمید	۰/۴۹۰۷	۴/۵۵۸۴
بهینه‌سازی گرگ خاکستری	۰/۵۶۲۶	۴/۸۰۳۰
بهینه‌سازی توده ذرات	۰/۵۶۱۴	۴/۸۱۳۳

همچنین در جداول ۶-۸ نتایج مقایسه میان معیارهای دقت، فراخوانی و F با تعداد بهینه k=152 برای الگوریتم پیشنهادی و تعداد ثابت k=100 برای الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات نشان داده شده است. در این ارزیابی تعداد توصیه‌ها از ۲ تا ۱۰۰ تغییر می‌کند.

UNCORRECTED PROOF

جدول۶- مقایسه معیار دقت الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u1)

	Precision		
	GWO	PSO	IFGWOLOADENM
N=2	۰/۹۷۳۵	۰/۹۶۶۶	۰/۹۹۰
N=5	۰/۹۶۸۴	۰/۹۶۶۱	۰/۹۸۴۱
N=10	۰/۹۴۲۶	۰/۹۳۹۳	۰/۹۶۹۶
N=15	۰/۹۰۸۵	۰/۹۰۳۹	۰/۹۴۰۲
N=20	۰/۸۷۰۳	۰/۸۶۶۷	۰/۹۰۳۷
N=25	۰/۸۳۱۸	۰/۸۲۸۶	۰/۸۶۶۴
N=30	۰/۷۹۳۱	۰/۷۹۰۵	۰/۸۲۸۰
N=35	۰/۷۵۷	۰/۷۵۴۰	۰/۷۹۱۸
N=40	۰/۷۲۳۶	۰/۷۲۰۱	۰/۷۵۷۸
N=45	۰/۶۹۲۴	۰/۶۸۹۵	۰/۷۲۶۶
N=50	۰/۶۶۳۶	۰/۶۶۱۴	۰/۶۹۷۸
N=55	۰/۶۳۷۸	۰/۶۳۵۳	۰/۶۷۱۰
N=60	۰/۶۱۳۹	۰/۶۱۱۷	۰/۶۴۶۷
N=65	۰/۵۹۲۵	۰/۵۹۰۱	۰/۶۲۴۸
N=70	۰/۵۷۲۸	۰/۵۷۰۲	۰/۶۰۴۳
N=75	۰/۵۵۳۹	۰/۵۵۱۵	۰/۵۸۵۲
N=80	۰/۵۳۵۹	۰/۵۳۳۹	۰/۵۶۷۲
N=85	۰/۵۱۹۱	۰/۵۱۷۳	۰/۵۵۰۴
N=90	۰/۵۰۳۵	۰/۵۰۱۹	۰/۵۳۴۸
N=95	۰/۴۸۸۸	۰/۵۱۷۳	۰/۵۲۰۱
N=100	۰/۴۷۴۷	۰/۴۷۳۲	۰/۵۰۵۷

جدول۷- مقایسه معیار فراخوانی الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u1)

	Recall		
	GWO	PSO	IFGWOLOADENM
N=2	۰/۰۹۹۲	۰/۰۹۹۰	۰/۱۰۳۰
N=5	۰/۲۳۶	۰/۲۳۶۰	۰/۲۴۳۶
N=10	۰/۴۰۹	۰/۴۰۸۶	۰/۴۲۳۸
N=15	۰/۵۲۶۵	۰/۵۲۵۰	۰/۵۴۳۱
N=20	۰/۶۱۰۷	۰/۶۱۰۰	۰/۶۲۷۷
N=25	۰/۶۷۴۲	۰/۶۷۳۳	۰/۶۹۲۱
N=30	۰/۷۲۰۸	۰/۷۱۹۹	۰/۷۳۹۷
N=35	۰/۷۵۷۸	۰/۷۵۶۵	۰/۷۷۷۵
N=40	۰/۷۸۷۷	۰/۷۸۶۴	۰/۸۰۷۵
N=45	۰/۸۱۲۲	۰/۸۱۱۴	۰/۸۳۳۰
N=50	۰/۸۳۲۷	۰/۸۳۲۳	۰/۸۵۴۶
N=55	۰/۸۵۰۵	۰/۸۴۹۹	۰/۸۷۲۸
N=60	۰/۸۶۵۴	۰/۸۶۴۸	۰/۸۸۸۳
N=65	۰/۸۷۸۷	۰/۸۷۷۹	۰/۹۰۱۹
N=70	۰/۸۹۰۳	۰/۸۸۹۶	۰/۹۱۳۸
N=75	۰/۹۰۰۵	۰/۸۹۹۸	۰/۹۲۴۱
N=80	۰/۹۰۹۱	۰/۹۰۸۷	۰/۹۳۳۱
N=85	۰/۹۱۶۴	۰/۹۱۶۲	۰/۹۴۱۰
N=90	۰/۹۲۳	۰/۹۲۲۹	۰/۹۴۷۷
N=95	۰/۹۲۸۶	۰/۹۲۸۵	۰/۹۵۳۵
N=100	۰/۹۳۳۵	۰/۹۳۳۴	۰/۹۵۸۵

جدول۸- مقایسه معیار F الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u1)

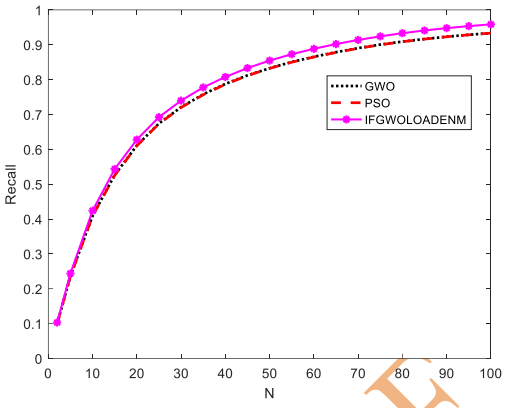
	F		
	GWO	PSO	IFGWOLOADENM
N=2	۰/۱۶۵۸	۰/۱۶۵۳	۰/۱۷۰۹
N=5	۰/۳۳۴۴	۰/۳۳۴۴	۰/۳۴۳۳
N=10	۰/۴۹۶۸	۰/۴۹۶۲	۰/۵۱۸۴
N=15	۰/۵۸۳۱	۰/۵۸۰۹	۰/۶۱۰۵
N=20	۰/۶۳۰۰	۰/۶۲۸۴	۰/۶۶۰۵
N=25	۰/۶۵۵۴	۰/۶۵۳۷	۰/۶۸۸۰
N=30	۰/۶۶۵۴	۰/۶۶۳۸	۰/۶۹۹۵
N=35	۰/۶۶۷۸	۰/۶۶۵۷	۰/۷۰۲۷
N=40	۰/۶۶۵۳	۰/۶۶۲۸	۰/۷۰۰۲
N=45	۰/۶۵۹۳	۰/۶۵۷۴	۰/۶۹۵۰
N=50	۰/۶۵۱۵	۰/۶۵۰۰	۰/۶۸۷۶
N=55	۰/۶۴۳	۰/۶۴۱۱	۰/۶۷۸۸
N=60	۰/۶۳۳۵	۰/۶۳۱۹	۰/۶۶۹۴
N=65	۰/۶۲۴۲	۰/۶۲۲۳	۰/۶۵۹۹
N=70	۰/۶۱۴۷	۰/۶۱۲۷	۰/۶۵۰۰
N=75	۰/۶۰۴۸	۰/۶۰۲۹	۰/۶۳۹۹
N=80	۰/۵۹۴۵	۰/۵۹۲۹	۰/۶۲۹۷
N=85	۰/۵۸۴۲	۰/۵۸۲۷	۰/۶۱۹۶
N=90	۰/۵۷۴۲	۰/۵۷۲۸	۰/۶۰۹۵
N=95	۰/۵۶۴۲	۰/۵۸۲۷	۰/۵۹۹۴
N=100	۰/۵۵۴۲	۰/۵۵۲۹	۰/۵۸۹۳

از جداول ۶-۸ مشاهده می‌شود که برای تمامی تعداد توصیه‌ها الگوریتم پیشنهادی بهتر از الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات عمل نموده است. به طوری که برای تعداد توصیه N=100، مقدار معیار فراخوانی، دقت و F بدست آمده از الگوریتم پیشنهادی به ترتیب برابر با ۰/۹۵۸۵، ۰/۵۰۵۷ و ۰/۵۸۹۳ شده است. در حالی که این سه معیار برای الگوریتم گرگ خاکستری به ترتیب برابر با ۰/۹۳۳۵، ۰/۴۷۴۷ و ۰/۵۵۴۲ و برای الگوریتم بهینه‌سازی توده ذرات به ترتیب برابر با ۰/۹۳۳۴، ۰/۴۷۳۲ و ۰/۵۵۲۹ است. به طور کلی با توجه به نتایج، مشخص می‌شود که الگوریتم پیشنهادی بهتر از دو الگوریتم دیگر عمل نموده است که نشان‌دهنده بهبود کیفیت توصیه‌های سیستم توصیه‌گر می‌باشد.

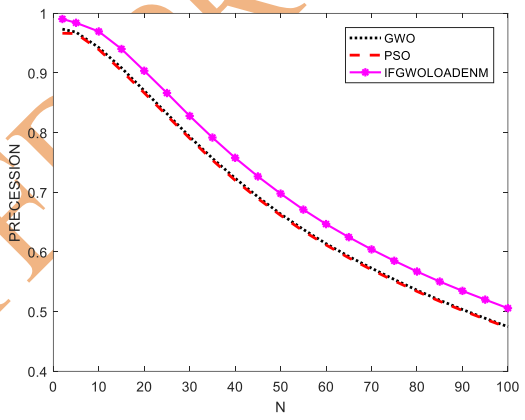
هر چه معیارهای فراخوانی، دقت و F بزرگتر باشند، الگوریتم بهتر عمل کرده است. از جداول ۲ تا ۴ مشاهده می‌شود که برای همه مقادیر N در این سه معیار، الگوریتم پیشنهادی مقادیر بزرگتری بدست آورده است. به عنوان نمونه به ازای N=2 مقادیر فراخوانی، دقت و F برای الگوریتم پیشنهادی برابر با ۰/۱۰۳۶، ۰/۹۸۷۸ و ۰/۱۷۱۲ هستند در حالی که این مقادیر برای الگوریتم گرگ خاکستری به ترتیب برابر با ۰/۱۰۰۳، ۰/۹۷۸۸ و ۰/۱۶۷۵ و برای بهینه‌سازی توده ذرات به ترتیب برابر با ۰/۰۹۹۹، ۰/۹۶۹۸ و ۰/۱۶۶۷ می‌باشند.

در شکل‌های ۸-۱۰ نتایج مربوط به معیارهای دقت، فراخوانی وF الگوریتم پیشنهادی و الگوریتم‌های گرگ خاکستری و بهینه سازی توده ذرات بر حسب تعداد توصیه نشان داده شده است.

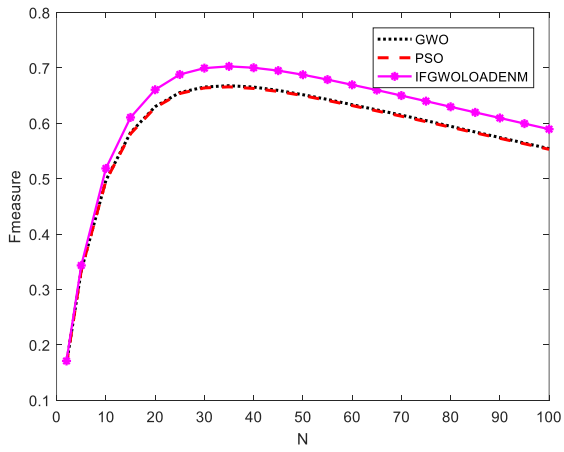
UNCORRECTED



شکل ۸- معیار Recall بر حسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u1)



شکل ۹- معیار Precision بر حسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u1)



شکل ۱۰- معیار F بر حسب تعداد توصیه برای الگوریتم پیشنهادی و الگوریتم‌های پایه (فولد u1)

از شکل‌های ۸-۱۰ مشاهده می‌شود که مقدار فراخوانی، دقت و معیار F بدست آمده از الگوریتم پیشنهادی در مقایسه با بهینه سازی توده ذرات و گرگ خاکستری به ازای تمام تعداد توصیه‌ها، بیشتر شده است که نشاندهنده عملکرد بهتر الگوریتم پیشنهادی نسبت به دو الگوریتم دیگر است.

۲-۴- ارزیابی توابع محک

توابع محک معروف اَکلی، گریوانک، رَستریگِن، روزنبروک، اِسفیر (کُره) و ۲۵ تابع محک دیگر برای ارزیابی الگوریتم پیشنهادی در نظر گرفته شده‌اند، بطوریکه توابع newf1 تا newf6 از CEC2022 و توابع newf7 تا newf10 از CEC2013 انتخاب شده‌اند. مقایسه میان الگوریتم پیشنهادی با الگوریتم گرگ خاکستری، بهینه‌سازی توده ذرات، الگوریتم گرگ خاکستری فازی ترکیب‌شده با شیر[۴۹] و نیز الگوریتم گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی [۵۰] با در نظر گرفتن اندازه جمعیت، تعداد تکرار و تعداد اجراها به ترتیب برابر با ۵۰۰، ۲۰۰ و ۳۰ انجام شده و نتایج در جداول ۹-۱۵ آورده شده است. اندازه ابعاد مسئله ۱۰۰ فرض شده و تنها تابع Drop با دو بعد مورد بررسی قرار گرفته است. زیرا این تابع دو بعدی است. 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 [-۴۰۰,۵۰۰] است. داده‌های جداول ۹-۱۵، مقدار میانگین به ازای کل اجراها (Mean)، بهترین مقدار (Min) و بدترین مقدار (Max) را نشان می‌دهند.

UNCORRECTED PROOF

جدول ۹- مقایسه الگوریتم IFGWOLOADENM با GWO، PSO، lFGWOLOA و IFGWOLOADE

الگوریتم		تابع محک			
		Sphere	Rosenbrock	Rastrigin	Griewank
گرگ خاکستری	Mean	۱۰/۷۸۵	۲۷۳۸/۶	۵۵۰/۰۶	۰/۴۹۸۵۴
	Min	۷/۰۹۳۵	۱۸۶۱/۸	۳۶۴/۹	۰/۲۸۵۷۵
	Max	۱۵/۲۸۷	۴۳۳۷/۲	۹۵۲/۱۴	۰/۵۶۱۵۹
توده ذرات	Mean	۰/۰۱۸۴۰۵	۳۲/۳۳۱	۶۰۵/۵۸	۰/۰۰۱۰۴۹
	Min	۰/۰۰۶۵۵۷	۲/۰۱۹۹	۵۰۳/۳۷	۰/۰۰۰۱۸۶۷
	Max	۰/۰۳۹۶	۱۰۰/۷۸	۶۹۵/۳۳	۰/۰۷۸۸
گرگ خاکستری فازی غنی شده با شیر[۴۹]	Mean	۱/۰۵۷e-۰۵	۱۸/۳۴۱	۹۹/۴۷۱	/۰۰۰۷۹۳۸۳ ۰
	Min	۹/۴۶۷۳e-۰۶	۰/۰۰۶۸۰۰۲	۳۳۴/۳۱	-۰۷ ۲/۴۵۵۵e
	Max	۱/۱۲۵۹e-۰۵	۲۰/۰۵۶	۵۲۱/۳۳	۰/۰۱۹۶۹
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی [۵۰]	Mean	۱/۵۹۴۱e-۰۷	۷/۹۴۷۵	۱۷۹/۱۹	۰/۰۰۰۵۹
	Min	۱/۴۳۱۴e-۰۷	۶/۵۰۲۴e-۰۵	۱۱۹/۴	۳/۰۲۷e-۰۹
	Max	۱/۸۲۳۷e-۰۷	۱۰/۳۲۵	۲۶۹/۶۳	۰/۰۱۲۳۲۱
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی و نلدرمید	**Mean**	**۵/۵۲۹۶e-۱۵**	**۰/۰۰۵۶۸۴۴**	**۱۶۵/۳**	**۰/۰۰۰۳۸۴۶**
	Min	**۵/۴۵۲۵e-۱۵**	**۵/۵۶۳۷e-۰۹**	**۹۷/۱۵**	**۲/۱۰۶e-۱۱**
	Max	**۵/۵۵۱۱e-۱۵**	**۰/۰۴۳۰۸۸**	**۲۳۸/۲۲**	**۰/۰۰۶۸۶۳**

جدول ۱۰- مقایسه الگوریتم IFGWOLOADENM با GWO، PSO، lFGWOLOA و IFGWOLOADE

الگوریتم		تابع محک			
		Bent Cigar	Discus	Elliptic	Katsura
گرگ خاکستری	Mean	۱/۱۸۹۵e+۰۷	۵۴۸/۰۸	۱/۳۸۳e+۰۶	۲۳۵/۶۱
	Min	۷/۹۰۱۸e+۰۶	۵۰۳/۷۸	/۰۹۶۲e+۰۶ ۱	۱۹/۷۸۷
	Max	۱/۴۶۹۱e+۰۷	۶۲۹/۵۳	۸۶۲۸۸e+۰۶ ۱/	۱۰۸۶/۹
توده ذرات	Mean	۱۵۵۷۷	۰/۱۳۷۶	۴۷۲/۸۳	۰/۲۷۷۸
	Min	۵۴۰۴/۲	۰/۱۲۵۲۴۹	۳۴۲/۰۵	۰/۰۳۰۶
	Max	۲۷۳۹۱	۰/۲۴۷۸	۶۹۳/۲	۰/۴۳۵
گرگ خاکستری فازی غنی شده با شیر[۴۹]	Mean	۲۴/۱۵	۰/۰۴۹	۴۲۲	۰/۰۱۶۷
	Min	۱۲/۷۷۷	۰/۰۰۹۸۷۶	۲۹۱	۰/۰۰۸۳۲
	Max	۳۶/۲۹۲	۰/۱۶۵۶	۴۹۷	۰/۰۶۵۱
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی [۵۰]	Mean	۱۲/۳۶۹	۰/۰۲۳۹۴۱	۲۹۵/۲۹	۰/۰۱۱۸۹
	Min	۰/۲۴۶۳۱	۰/۰۰۸۵۴۶۷	۱۸۵/۵	۰/۰۰۴۵۹۹۱
	Max	۳۳/۴۹۸	۰/۰۲۹۵	۴۰۳/۸۸	۰/۲۶۰۹۳
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی و نلدرمید	**Mean**	**۳/۵۵۳۳**	**۴/۹۹۶۶e-۱۰**	**۱۸۳/۱۴**	**۰/۰۰۴۴۱**
	Min	**۰/۰۲۲۳**	**۴/۹۹۶۴e-۱۰**	**۱۳۰/۴۶**	**۰/۰۰۰۳۰۶۶۸**
	Max	**۳۰/۰۸۵**	**۴/۹۹۷۳e-۱۰**	**۲۲۹/۴۲**	**۰/۰۱۳۵**

UNCORRECTED PROOF

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

جدول ۱۱- مقایسه الگوریتم IFGWOLOADENM با IFGWOLOADE و lFGWOLOA، PSO،GWO

الگوریتم		تابع محک			
		Ackley	Happycatfcn	Zhakharov	camel3
گرگ خاکستری	Mean	۲/۵۷۷۸	۰/۳۴۰۷۹	۹۲/۲۶۸	۱/۵۵۱۱ e-۰۷
	Min	۱/۲۰۹۵	۰/۲۴۲۵۸	۸۳/۳۵۶	۳/۲۲۵۵ e-۰۸
	Max	۳/۶۴۲۳	۰/۳۹۹	۱۰۰/۹۱	۳/۹۰۶ e-۰۷
توده ذرات	Mean	۱/۲۹۸۵	۰/۴۲۳۰۶	۱۴۱/۵۶	۴/۱۰۴۸ e-۰۸
	Min	۰/۴۷۶۹	۰/۳۴۸۱۱	۸۹/۹۹۴	۱/۵۵۸ e-۰۹
	Max	۲/۴۰۴	۰/۵۱۷۸	۲۰۷/۶۲	۱/۲۹۲۲ e-۰۷
گرگ خاکستری فازی غنی شده با شیر[۴۹]	Mean	۱/۰۸۰۴	۰/۳۰۹۰۴	۲۴/۸۴۱	۱/۳۵ e-۱۲
	Min	۰/۳۹۵۴	۰/۱۹۳	۱۵/۴۱۵	۹/۹۴ e-۱۳
	Max	۲/۲۴۰۲	۰/۳۳۷	۳۶/۹۲۱	۳/۷۱۸ e-۱۲
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی [۵۰]	Mean	۱/۰۱۵۳۵	۰/۱۵۳	۱۷/۹۴۱	۹/۰۲۷۹ e-۱۴
	Min	۰/۳۰۱۲	۰/۱۰۵۱	۷/۲۷۲	۱/۴۷۰۲ e-۱۴
	Max	۱/۹۶۴	۰/۲۰۲	۲۸/۹۸۶	۲/۷۵۹۳ e-۱۳
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی و نلدرمید	**Mean**	**۰/۲۹۲۸۴**	**۰/۰۶۰۰۹**	**۲/۹۳۰۹ e-۱۰**	**۱/۲۹۲۱e-۱۵**
	Min	**۶/۵۷۲۵e-۰۸**	**۰/۰۱۲۹**	**۲/۲۲۷۶ e-۱۰**	**۱/۱۱۹۴e-۱۶**
	Max	**۱/۶۳۳۵**	**۰/۰۹۲۴۸**	**۴/۲۹۰۱ e-۱۰**	**۷/۳۷۷۶e-۱۴**

جدول ۱۲- مقایسه الگوریتم IFGWOLOADENM با IFGWOLOADE و lFGWOLOA، PSO،GWO

الگوریتم		تابع محک			
		HGBat	EF8F2_func	Drop	Schwefel
گرگ خاکستری	Mean	۹/۹۶۳۷	۲۶۰/۳۱	۰/۰۲۵۵	۱۴۴/۵۳
	Min	۱/۱۴۲	۱۴۵/۴۸	۲/۲۸۱۴ e-۰۷	۱۱۸/۶۳
	Max	۴۳/۲۲۴	۴۸۴/۸	۰/۱۶۷	۱۷۴/۱۱
توده ذرات	Mean	۱/۳۹۸۴	۱۵۲/۱۸	۰/۰۱۷۵	۰/۰۳۵۶۲۹
	Min	۰/۷۹۴	۴۶/۸۲۳	۱/۱۶۴ e-۰۸	۰/۱۰۷۳۱
	Max	/۳۸۶۵۸۳	۴۶۷/۸۷۴	۰/۰۸۴۲	۰/۶۸۷۳۱
گرگ خاکستری فازی غنی شده با شیر[۴۹]	Mean	۰/۳۹۴	۱۴۰/۲۵	۰/۰۱۵۳	۱/۷۸ e-۰۴
	Min	۰/۲۵۳	۳۵/۱۲	۳/۵۴۲۵ e-۱۱	۵/۲۱ e-۰۵
	Max	۰/۳۹۴	۳۹۶/۲۵	۰/۰۷۲۴	۷/۱۳۲ e-۰۴
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی [۵۰]	Mean	۰/۳۴۳۳	۱۳۱/۷۲	۰/۰۱۲۷	۲/۰۷ e-۰۸
	Min	/۲۱۲۸۹۰	۲۷/۱۲	۷/۷۳۱۶ e-۱۳	۱/۷۳۳۹ e-۰۸
	Max	۰/۳۷۲	۳۷۵/۸	۰/۰۶۳۷	۲/۵۲۸ e-۰۸
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی و نلدرمید	**Mean**	**/۱۸۴۱۶۰**	**۲۶/۵۹۸**	**۲/۶۶۰۱ e-۱۴**	**۱/۴۱۸۸ e-۱۰**
	Min	**۰/۱۳۵۳**	**۲۳/۷۹۷**	**۳/۷۷۴۸ e-۱۵**	**۱/۰۹۱۴ e-۱۰**
	Max	**/۲۵۵۷۱۰**	**۳۳/۷۸۸**	**۳/۶۱۹۳ e-۱۴**	**۱/۶۷۳۵ e-۱۰**

UNCORRECTED PROOF

جدول ۱۳- مقایسه الگوریتم IFGWOLOADENM با IFGWOLOADE و IFGWOLOA، PSO،GWO

الگوریتم		تابع محک			
		Hybrid1	Hybrid2	Hybrid3	beale
گرگ خاکستری	Mean	۲/۲۰۸۳ e+۰۶	۰/۲۶۴۵۱	۳/۳۰۱۸ e+۰۵	۳/۱۸۷۳ e-۰۸
	Min	۱/۲۵۲۵ e+۰۶	۰/۰۵۲۷	۲/۱۳۳۲ e+۰۵	۴/۰۶۳۸ e-۰۹
	Max	۳/۶۹۹۲ e+۰۶	۰/۶۶۲۸۹	۴/۰۷۵۸ e+۰۵	۷/۹۳۸۳ e-۰۸
توده‌ذرات	Mean	۳/۰۶۸۷ e+۰۴	۱/۱۲۶۶ e-۰۴	۴/۰۹۹۸ e+۰۳	۳/۰۹۲۴ e-۰۶
	Min	۹/۷۷۶۷ e+۰۳	۷/۴۸۵۱ e-۰۶	۹/۱۱۳۳ e+۰۲	۲/۲۹۳۷ e-۰۷
	Max	۵/۹۸۶۵ e+۰۵	۲/۲۵۷۱ e-۰۳	۹/۰۶۶۷ e+۰۴	۱/۲۲۰۵ e-۰۵
گرگ خاکستری فازی‌غنی شده‌با شیر[۴۹]	Mean	۲۶۹/۴	۴/۴۱ e-۰۵	۱۴۷/۲	۲/۴۷۶ e-۰۹
	Min	۱۴۴/۹	۳/۱۹۷۵ e-۰۶	۵/۵۳۸	۲/۹۰ e-۱۱
	Max	۳۹۱/ ۶۹	۵/۴۸ e-۰۴	۲۸۸/۴۳	۱/۱۴۹۳ e-۰۸
گرگ خاکستری فازی‌ترکیب شده‌باشیرو تکامل تفاضلی [۵۰]	Mean	۲۷/۹۶۴	۵/۲۱۲۱ e-۰۷	۸/۷۲۴۷	۲/۰۳۹۵ e-۱۳
	Min	۷/۳۷۲۱	۳/۲۹۹۸ e-۰۷	۰/۳۸۱	۴/۲۲۸۱ e-۱۴
	Max	۷۷/۷۰۴	۶/۹۴۸۵ e-۰۷	۲۷/۶۹۸	۴/۹۳۲۱ e-۱۳
گرگ خاکستری فازی ترکیب شده‌باشیر وتکامل تفاضلی‌و نلدرمید	**Mean**	**۲۳/۱۸**	**۶/۳۴۸۴e-۱۳**	**۱/۸۹۲۵e-۰۵**	**۵/۴۷۰۹e-۱۴**
	Min	**۲/۰۶۳**	**۲/۸۸۳۵e-۱۳**	**۱/۸۶۸۷e-۰۵**	**۲/۹۹۳۲e-۱۵**
	Max	**۵۳/۹۳**	**۹/۹۶۴۷e-۱۳**	**۱/۹۰۶۵e-۰۵**	**۲/۵۴۶۲e-۱۳**

جدول ۱۴- مقایسه الگوریتم IFGWOLOADENM با GWO، PSO، IFGWOLOA و IFGWOLOADE

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[۴۹]	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 ترکیب شده با شیر و تکامل تفاضلی [۵۰]	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
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی و نلدرمید	**Mean**	**۹۹/۵**	**۴۰۳۸۱**	**-۴۹۹/۹**	**۵/۵۳۷۵e-۱۵**	**۵/۳۰۲۶e-۱۵**
	Min	**۷۱/۲۳**	**۴۰۳۸۱**	**-۵۰۰**	**۵/۴۸۲۲e-۱۵**	**۴/۴۶۱۳e-۱۵**
	Max	**۱۱۵/۴۶**	**۴۰۳۸۱**	**-۴۹۹**	۵/۵۵۱۱ e -۱۵	۵/۵۵۱۳ e -۱۵

UNCORRECTED PROOF

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

جدول ۱۵- مقایسه الگوریتم IFGWOLOADENM با GWO، PSO، lFGWOLOA و IFGWOLOADE

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[۴۹]	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 ترکیب شده با شیر و تکامل تفاضلی [۵۰]	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
گرگ خاکستری فازی ترکیب شده با شیر و تکامل تفاضلی و نلدرمید	**Mean**	**۱۲/۴۸**	**۳۴/۲۶۲**	**۶۸/۸۷۶**	**۰/۰۰۱۲۵**	**۲/۰۹۷۴ e-۰۸**
	Min	**۸/۹۹**	**۳۴/۲۶۲**	**۵۷/۹۹۸**	**۰/۰۰۱۲۴**	**۶/۴۴۹۸ e-۰۹**
	Max	**۲۳/۴۹**	**۳۴/۲۶۲**	**۷۹/۲۲**	**۰/۰۰۱۲۷**	**۳/۱۶۵۲ e-۰۸**

براساس جداول ۹–۱۵ استنباط می‌شود که الگوریتم پیشنهادی در کمینه‌سازی موفق‌تر از چهار الگوریتم دیگر از نظر میانگین، بهترین و بدترین جواب بدست آمده، عمل نموده است.

۴-۳-میانگین MAE الگوریتم پیشنهادی

در جدول ۱۶ مقدار MAE برای تمام فولدهای مجموعه‌داده مووی‌لنز و نیز میانگین MAE به ازای الگوریتم پیشنهادی، الگوریتم‌های گرگ خاکستری، بهینه‌سازی توده ذرات و گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی [۵۰] آورده شده است.

جدول ۱۶- معیار MAE الگوریتم پیشنهادی برای فولدهای دیتاست مووی‌لنز

فولد	PSO	GWO	IFGWOLOADE	IFGWOLOADENM
اول	۰/۵۵۹۸	۰/۵۵۱۲	۰/۴۹۲۱	۰/۴۹۰۷
دوم	۰/۵۶۵۴۳	۰/۵۶۵۳۸	۰/۴۹۴۵۷	۰/۴۸۵۹
سوم	۰/۵۵۴۳۳	۰/۵۵۳۹۷	۰/۴۹۳۴۲	۰/۴۸۹۳
چهارم	۰/۵۵۱۹۱	۰/۵۵۱۸۷	۰/۴۹۱۷۵	۰/۴۸۹۶
پنجم	۰/۵۵۷۳	۰/۵۴۹۵	۰/۴۸۷۸	۰/۴۸۷
میانگین	**۰/۵۵۷۸**	**۰/۵۵۴۴**	**۰/۴۹۱۹**	**۰/۴۸۸۵**

از جدول ۱۶ مشاهده می‌شود که الگوریتم پیشنهادی برای تمام فولدها در مقایسه با سه الگوریتم دیگر مقدار MAE کمتری بدست آورده است. در نهایت با توجه به میانگین MAE بدست آمده از الگوریتم پیشنهادی مشخص می‌گردد که این الگوریتم از الگوریتم‌های گرگ خاکستری، بهینه‌سازی توده ذرات و گرگ خاکستری فازی ترکیب‌شده با شیر و تکامل تفاضلی [۵۰] عملکرد بهتری دارد.

۴-۴- آزمون t الگوریتم پیشنهادی

در جدول ۱۷ نتایج بدست آمده از آزمون t، میان الگوریتم پیشنهادی و الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات نشان داده شده است.

UNCORRECTED PROOF

جدول ۱۷- مقایسه آزمون t الگوریتم پیشنهادی و الگوریتم‌های پایه

تابع محک	الگوریتم	P	h
Sphere	IFGWOLOADENM-GWO	۳/۳۳۲۴e-۱۲	۱
	IFGWOLOADENM-PSO	۰/۰۰۲۱۵۳	۱
Rosenbrock	IFGWOLOADENM-GWO	۰/۰۲۴۰۱۸	۱
	IFGWOLOADENM-PSO	۰/۰۳۳۷	۱
Rastrigin	IFGWOLOADENM-GWO	۱/۹۰۸۱e-۰۴	۱
	IFGWOLOADENM-PSO	۰/۰۰۲۱۷	۱
Griewank	IFGWOLOADENM-GWO	۰/۳۸۸۰۹	۰
	IFGWOLOADENM-PSO	۰/۱۰۸۷	۰
Ackley	IFGWOLOADENM-GWO	۱/۶۶۸۳e-۱۶	۱
	IFGWOLOADENM-PSO	۱/۶۹۲۰۵e-۱۰	۱
Bent cigar	IFGWOLOADENM-GWO	۱/۰۷۸۷e-۰۸	۱
	IFGWOLOADENM-PSO	۳/۷۱۹۵e-۰۴	۱
discus	IFGWOLOADENM-GWO	۱/۷۴۲e-۰۵	۱
	IFGWOLOADENM-PSO	۳/۵۳۶۵e-۰۷	۱
Elliptic	IFGWOLOADENM-GWO	۰/۰۰۱۶	۱
	IFGWOLOADENM-PSO	۲/۰۸۸۹e-۰۴	۱
katsura	IFGWOLOADENM-GWO	۰/۰۱۰۴	۱
	IFGWOLOADENM-PSO	۸/۸۰۱۶e-۱۰	۱
happycatfcn	IFGWOLOADENM-GWO	۲/۳۶۸۱e-۰۸	۱
	IFGWOLOADENM-PSO	۱/۳۴۸۶e-۱۶	۱
HGBat	IFGWOLOADENM-GWO	۶/۰۹۲۸e-۰۴	۱
	IFGWOLOADENM-PSO	۷/۵۹۳۹e-۰۸	۱
EF8F2_func	IFGWOLOADENM-GWO	۲/۴۲۵۸e-۰۶	۱
	IFGWOLOADENM-PSO	۱/۵۹۷۹e-۰۷	۱
Drop	IFGWOLOADENM-GWO	۰/۰۱۶۴	۱
Schwefel	IFGWOLOADENM-GWO	۳/۶۲۲۶e-۰۵	۱
	IFGWOLOADENM-PSO	۹/۵۸۸۱e-۰۵	۱
Zhakharov	IFGWOLOADENM-GWO	۳/۸۸۹۲e-۰۸	۱
	IFGWOLOADENM-PSO	۱/۱۹۲۸e-۰۵	۱
hybrid1	IFGWOLOADENM-GWO	۱/۹۳۳۴e-۰۵	۱
	IFGWOLOADENM-PSO	۱/۲e-۰۴	۱
hybrid2	IFGWOLOADENM-GWO	۱/۳۳۹۱e-۰۵	۱
	IFGWOLOADENM-PSO	۰/۰۰۳۲	۱
hybrid3	IFGWOLOADENM-GWO	۰/۰۰۲۳	۱
	IFGWOLOADENM-PSO	۵/۱۹۳۱e-۰۶	۱
beale	IFGWOLOADENM-GWO	۰/۱۵۴۴	۰
	IFGWOLOADENM-PSO	۰/۰۰۷	۱
camel3	IFGWOLOADENM-GWO	۵/۸۸۲e-۰۵	۱
	IFGWOLOADENM-PSO	۰/۰۱۶۴	۱

در جدول ۱۷ مقدار P و h نشان داده شده است. با توجه به اینکه اگر مقدار P کمتر از ۰/۰۵ باشد، به معنای آن است که الگوریتم پیشنهادی عملکرد قابل توجه‌ای در مقایسه با الگوریتم دیگر دارد، نتایج مقایسه میان الگوریتم پیشنهادی و گرگ خاکستری در ۲۰ تابع محک مورد بررسی، نشان می‌دهد که در دو تابع (Griewank و beale) عملکرد دو الگوریتم مشابه است و برای ۱۸ تابع دیگر، الگوریتم پیشنهادی عملکرد بهتری دارد. همچنین مقایسه میان الگوریتم پیشنهادی و بهینه‌سازی توده ذرات نشان می‌دهد که فقط برای تابع Griewank، دو الگوریتم عملکردی مشابه دارند. با توجه به این نتایج مشخص می‌شود که عملکرد الگوریتم پیشنهادی بهتر از الگوریتم‌های پایه است.

UNCORRECTED PROOF

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

۴-۵- مقایسه MAE الگوریتم پیشنهادی و الگوریتم‌های تحقیقات مرتبط

تحقیقات مختلفی در زمینه سیستم‌های توصیه‌گر روی مجموعه داده مووی‌لنز انجام شده است. مقدار MAE بدست آمده از الگوریتم پیشنهادی (الگوریتم گرگ خاکستری فازی ترکیب شده با الگوریتم‌های شیر، تکامل تفاضلی و نلدرمید) و الگوریتم‌های پیشنهادی سایر تحقیقات مرتبط در جدول ۱۸ آورده شده است.

جدول ۱۸- معیار MAE الگوریتم پیشنهادی و الگوریتم‌های تحقیقات مرتبط

الگوریتم	MAE	منبع
PCA-GAKM	۰/۷۹	[۶۴]
PCA-SOM	۰/۸۲	[۶۴]
SOM-CLUSTER	۰/۸۱۹	[۶۴]
UPCC	۰/۸۲۵	[۶۴]
k-means cluster	۰/۸۲۵	[۶۴]
PCA- k-means	۰/۸۵	[۶۴]
GAKM CLUSTER	۰/۸۱۵	[۶۴]
ABC-KM	۰/۷۷۳	[۶۴]
KM-APSO	۰/۶۸۶	[۶۵]
KM-FOA	۰/۶۷۲	[۶۵]
GA 2011	۰/۷۵	[۷]
COA	۰/۵۲	[۶۶]
FPMF	۰/۷۳۱۸	[۶۷]
KLD-FCM-MRS	۰/۷	[۶۸]
FunkSVD	۰/۷۲۱	[۶۹]
TFMF	۰/۷۰۸۴	[۷۰]
OSA	۰/۶۶	[۷۱]
UITrust_C	۰/۷۳۳	[۵۲]
MBODBN	۰/۷۱۶	[۷۲]
Co Clustering	۰/۷۴۶	[۷۳]
Chat-Rec	۰/۵۹۳	[۷۴]
iMovieRec	۰/۶۴۴	[۷۵]
Cascade Hybrid Filtering based on CNN	۰/۸۶۴۳	[۷۶]
Kmeans- Deep learning (DL)	۰/۸۷۴۱	[۷۷]
Kmeans - LCGOA	۰/۷۳	[۷۸]
IFGOWLOADENM		

براساس جدول ۱۸، کاتاریا در سال ۲۰۱۸ یک سیستم توصیه‌گر فیلم مشارکتی ترکیبی[1] براساس الگوریتم خوشه‌بندی K میانگین[2] و الگوریتم کلونی زنبور عسل مصنوعی (اِی‌بی‌سی[3]) پیشنهاد داد اما بهبودی روی الگوریتم بهینه‌سازی ایجاد نشد. با سیستم پیشنهادی (اِی‌بی‌سی-کی‌اِم[4]) مقادیر بالایی از MAE به ازای مقادیر مختلف K، بدست آمد[۶۴]. در مطالعه توحیدی و دادخواه الگوریتم‌های بهینه‌سازی جنگل[5] و بهینه‌سازی ازدحام ذرات شتاب‌یافته[6] به همراه الگوریتم خوشه‌بندی K میانگین برای بهبود عملکرد سیستم توصیه‌گر ویدئو پالایش مشارکتی مبتنی بر کاربر به‌کار گرفته شدند و مقادیر MAE دو الگوریتم به ترتیب برابر با ۰/۶۷۲ و ۰/۶۸۶ شد. در این مرجع نیز بهبودی روی الگوریتم‌های بهینه‌سازی انجام نشده است[۶۵]. بوبادیلا و همکاران الگوریتم ژنتیک[7] با تکنیک نزدیکترین همسایه را برای بهبود سیستم توصیه‌گر فیلم پالایش مشارکتی بکار بردند و MAE آن برابر با ۰/۷۵ شد که مقدار بالایی است و در این الگوریتم نیز بهبودی اعمال نشد[۷]. حاتمی و پاشازاده

[1] . hybrid collaborative movie recommender system

[2] . k-means clustering algorithm

[3] . Artificial Bee Colony (ABC)

[4] . ABC-KM

[5] . Forest Optimization (FOA)

[6] . Accelerated Particle Swarm Optimization (APSO)

[7] . Genetic Algorithm

UNCORRECTED PROOF

از الگوریتم بهینه‌سازی فاخته[۱] و تکنیک نزدیکترین همسایه برای بهبود سیستم توصیه‌گر فیلم پالایش مشارکتی استفاده کردند. در این مرجع مقدار MAE برابر با ۰/۵۲ شد که در مقایسه با مراجع قبلی مقدار کمتری است اما خود الگوریتم پایه بهبود داده نشد[۶۶]. در بررسی فنگ و همکاران روش فاکتورسازی ماتریسی با استفاده از معیار تشابه چندعاملی[۲] ، برای بهبود سیستم توصیه‌گر بکار رفته است. مقدار MAE بدست‌آمده از این روش برابر با ۰/۷۳۱۸ شد که مقدار بالایی است[۶۷]. از روش خوشه بندی C میانگین فازی مبتنی بر واگراییکولبک لیبلر[۳] (کِی‌اِل‌دی-اِفسی‌اِم) و تابع شباهت مجذور-کسینوسی[۴] بهبود یافته برای یافتن همسایگان کاربر هدف توسط ویمالا و ویوکانداندان استفاده شد. مقدار MAE بدست آمده در این مرجع برابر با ۰/۷ است[۶۸]. گزدر و هیدری از یک الگوریتم براساس تکنیک فاکتورسازی ماتریسی به نام فانک‌اِس‌وی‌دی[۵] با تابع شباهت نمایی برای بهبود سیستم توصیه‌گر فیلم پالایش مشارکتی استفاده کردند و مقدار MAE برابر با ۰/۷۲۱ بدست آمد که تقریبا مقدار بالایی است[۶۹]. روش فاکتورسازی ماتریسی با ویژگی‌های موقتی[۶] برای بهبود سیستم توصیه‌گر فیلم توسط بهارا و ناین استفاده شد که مقدار MAE بدست آمده از این روش برابر با ۰/۷۰۸۴ است[۷۰]. در مطالعه روحیت و همکاران از الگوریتم توقف بهینه[۷] برای بهبود سیستم توصیه‌گر فیلم استفاده شد و مقدار MAE بدست آمده از این روش برابر با ۰/۶۶ است[۷۱]. یک مدل چند بعدی برای بهبود کیفیت توصیه سیستم توصیه‌گر براساس طبقه‌بندی و آنتروپی اطلاعات رتبه‌بندی‌های کاربر-آیتم از طریق یک فرآیند انتخاب k نزدیکترین همسایه مبتنی بر طبقه‌بندی توسط یوآن و همکاران پیشنهاد شد. تابع شباهت در این مرجع، پیرسون است که بهبودی روی آن اعمال نشد و مقدار MAE بدست آمده نیز برابر با ۰/۷۳۳ است[۵۶]. سریدهار و همکاران ترکیبی از بهینه‌سازی پروانه سلطنتی (اِم‌بی‌اُ[۸]) برای انتخاب ویژگی و شبکه باور عمیق (دی‌بی‌اِن[۹]) برای طبقه‌بندی به‌منظور بهبود سیستم توصیه‌گر ارائه دادند که مقدار MAE بدست آمده از این روش برابر با ۰/۷۱۶ می‌باشد. در این مرجع بهبودی در خصوص الگوریتم پایه انجام نشده است[۷۲]. سیستم توصیه‌گر فیلم با استفاده از تنظیم پارامتر همسایگی کاربر و فیلم از طریق هم‌خوشه‌بندی[۱۰] توسط آیرن و آگراوال ارائه شد که مقدار MAE آن برابر ۰/۷۴۶ است[۷۳]. گائو و همکاران یک الگوی جدید به نام Chat-Rec سیستم توصیه‌گر تقویت‌شده ChatGPT پیشنهاد داده‌اند که به طور نوآورانه مدل‌های زبانی بزرگ (LLM[11])ها را برای ساخت سیستم‌های توصیه‌گر مکالمه‌ای با تبدیل پروفایل‌های کاربر و تعاملات تاریخی به پیام‌ها تقویت می‌کند. در آزمایش‌ها مقدار MAE برابر ۰/۵۹۳ بدست آمد و مشخص شد Chat-Rec به طور مؤثر نتایج k توصیه برتر را بهبود می‌بخشد[۷۴]. هوآنگ و همکاران یک روش ترکیبی توصیه فیلم مبتنی بر مدل کاربر-تصویر-آیتم[۱۲] (iMovieRec) برای سیستم توصیه‌گر ارائه کردند. MAE این مدل، ۰/۶۴۴ است[۷۵]. آرسیتانیا و همکاران رویکرد پالایش ترکیبی آبشاری با استفاده از شبکه عصبی کانولوشنی[۱۳] را ارائه دادند و مقدار MAE برابر با ۰/۸۶۴۳ بدست آمد[۷۶]. 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 می‌باشد[۷۷]. ژائو و همکاران یک روش توصیه

[1] . Cuckoo optimization

[2] . multifactor similarity measure

[3] .Kullback–Leibler Divergence-based Fuzzy C-Means Clustering(KLD-FCM)

[4] . sqrt-cosine

[5] . FunkSVD

[6] . temporal effects

[7] . Optimal Stopping Algorithm

[8] .Monarch Butterfly Optimization (MBO)

[9] . Deep Belief Network (DBN)

[10] . Co-Clustering

[11] Large Language Model

[12] . iMovieRec: a hybrid movie recommendation method based on a user-image-item model

[13] . Cascade Hybrid Filtering method based on CNN

UNCORRECTED PROOF

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

مبتنی بر خوشه‌بندی را پیشنهاد دادند که یک الگوریتم بهینه‌سازی ملخ بهبودیافته، به نام LCGOA، را با الگوریتم k میانگین ترکیب می‌کند. MAE حاصله از این روش برابر با ۰/۷۳ است[۷۸].

با توجه به جدول ۱۸ و مقدار MAE الگوریتم‌های ارائه شده در تحقیقات مذکور و میانگین MAE الگوریتم IFGWOLOADENM که برابر با ۴۸۸۵/ می‌باشد، مشخص می‌شود که میانگین خطای مطلق این الگوریتم نسبت به الگوریتم‌های ارائه شده در سایر تحقیقات کمتر است که نشاندهنده عملکرد خوب الگوریتم پیشنهادی در مجموعه داده مووی‌لنز است.

۵- نتیجه‌گیری و کارهای آینده

سیستم‌های توصیه فیلم برای سال‌های متمادی یک حوزه تحقیقاتی فعال بوده‌اند و مطالعات متعددی برای بهبود اثربخشی این سیستم‌ها انجام شده است. با ظهور تکنیک‌های یادگیری ماشینی، محققان سیستم‌های توصیه پیچیده‌تری را توسعه داده‌اند که می‌توانند از داده‌های کاربر بیاموزند و توصیه‌های شخصی ارائه کنند. پالایش مشارکتی یک تکنیک پرکاربرد در سیستم‌های توصیه فیلم است[۱۲]. این رویکرد که سرعت و پایداری بسیار خوبی در زمینه سیستم‌های توصیه‌گر دارد، در سال ۱۹۹۲ ارائه شد و اولین بار در سال ۱۹۹۴ در سیستم فیلترینگ اخبار گروپ لنز[1] استفاده شد. الگوریتم پالایش مشارکتی ساده، قابل درک [۷۹] و در ارائه توصیه‌های شخصی مؤثر است و به طور گسترده در پلتفرم‌های مختلف پخش آنلاین فیلم مورد استفاده قرار گرفته است[۱۲]. این تکنیک به کاربران کمک می‌کند تا فیلم‌های مورد نظر خود را براساس تجربه تماشای فیلم کاربران دیگر به شیوه‌ای کارآمد، موثر و بدون اتلاف وقت، پیدا کنند[۸۰]

اثربخشی سیستم‌های توصیه فیلم به عوامل مختلفی مانند دقت الگوریتم‌های یادگیری ماشین مورد استفاده، کیفیت و کمیت داده‌های در دسترس، و معیارهای ارزیابی مورد استفاده برای ارزیابی عملکرد سیستم، بستگی دارد[۱۲]. در حالی که تحقیقات در مورد سیستم‌های توصیه‌گر شامل جهات زیادی می‌شود، اما تحقیقات الگوریتمی برای بهبود دقت توصیه‌ها بسیار مورد توجه است [۲۱] [۸۱]. با وجود اینکه هیچ توصیه یا پیش بینی ۱۰۰٪ دقیق نیست، می‌توان با استفاده از الگوریتم‌های یادگیری ماشین توصیه‌هایی نسبتا دقیق ارائه کرد[۸۰]. در این مقاله یک سیستم توصیه فیلم مبتنی بر رویکرد پالایش مشارکتی مبتنی بر همسایگی کاربرمحور براساس یک تابع شباهت بهینه و پارامتر k بهینه پیشنهاد شد که مقدار وزن‌های تابع شباهت و k نزدیکترین همسایه توسط یک الگوریتم بهینه‌سازی هوشمند ترکیبی جدید در قالب یک مسئله بهینه‌سازی تنظیم شده است. این سیستم با استفاده از مجموعه داده مووی لنز، که شامل رتبه‌بندی فیلم توسط کاربران است، ارزیابی و عملکرد سیستم با استفاده از معیارهای میانگین خطای مطلق، دقت، فراخوانی، معیار F و معیار پیشنهادی اندازه‌گیری شد. نتایج نشان داد که سیستم پیشنهادی از کیفیت پیش‌بینی و کیفیت توصیه‌های خوبی برخوردار است. به طور کلی، سیستم توصیه‌گر فیلم پیشنهادی با استفاده از الگوریتم‌های یادگیری ماشین، اثربخشی تکنیک‌های یادگیری ماشین را در ساخت سیستم‌های توصیه شخصی نشان می‌دهد. این سیستم را می‌توان در پلتفرم های پخش آنلاین فیلم ادغام کرد تا با ارائه توصیه‌های شخصی و مرتبط، تجربه‌ی کاربری را بهبود بخشد.

برای ارزیابی الگوریتم بهینه‌سازی هوشمند ترکیبی پیشنهادی روی سیستم توصیه‌گر، ابتدا فولد شماره ۵ (u5) و سپس فولد شماره ۱(u1) انتخاب شد و نتایج نشان داد که MAE بدست آمده از الگوریتم پیشنهادی در مقایسه با الگوریتم‌های گرگ خاکستری و بهینه‌سازی توده ذرات کمتر است که نشاندهنده بهبود دقت پیش‌بینی سیستم توصیه‌گر می‌باشد. سپس ارزیابی الگوریتم پیشنهادی، با تعداد توصیه‌ها از ۲ الی ۱۰۰ روی این دو فولد نشان داد که به ازای تمام تعداد توصیه‌ها، الگوریتم پیشنهادی از نظر سه معیار دقت، فراخوانی و F ، مقادیر بزرگتری بدست آورده است که نشاندهنده عملکرد بهتر آن در مقایسه با دو الگوریتم پایه و بهبود کیفیت توصیه‌های سیستم توصیه‌گر است. در ادامه عملکرد الگوریتم پیشنهادی توسط توابع محک مورد بررسی قرار گرفت و نتایج نشان داد که الگوریتم پیشنهادی در کمینه‌سازی موفق‌تر از الگوریتم‌های بهینه‌سازی توده

[1] . GroupLens

UNCORRECTED PROOF

ذرات، گرگ خاکستری پایه، گرگ خاکستری فازی ترکیب شده با الگوریتم شیر[۴۹]، گرگ خاکستری فازی ترکیب شده با الگوریتم شیرو تکامل تفاضلی[۵۰] عمل نموده است.

با توجه به اینکه روش پیشنهادی تنها از اطلاعات امتیازدهی کاربران استفاده می‌کند، برای پلتفرم‌های امروزی که دارای کلان‌داده شامل خلاصه، برچسب‌ها، زیرنویس‌ها، مرور و سایر متون هستند، مناسب نمی‌باشد. همچنین، در این روش چون کاربران بینشی در مورد نحوه محاسبه توصیه‌ها ندارند، نمی‌توانند چگونگی شکل‌گیری توصیه‌ها را درک کنند[۸۲]. در تحقیقات آینده می‌توان از تکنیک‌های پردازش زبان طبیعی (NLP) برای تحلیل مرورها، نظرات و بازخوردهای کاربران استفاده کرد تا بینش بهتری درباره ترجیحات کاربران به دست آید و نگاشت مرورهای متنی به رتبه‌بندی را انجام داد تا درک کاربران از دلایل پیشنهاد فیلم افزایش یابد، زیرا پردازش زبان طبیعی قابلیت توضیح دلیل ارائه توصیه‌ها را دارد[۸۳]. علاوه بر این، برای غلبه بر مشکل پراکندگی داده‌ها در سیستم توصیه‌گر، می‌توان رویکرد ترکیبی مبتنی بر تکنیک‌های فاکتورگیری ماتریسی[۱] ارائه داد[۱]. براساس این رویکرد، کاربران و آیتم‌ها با ویژگی‌های نهفته با دقت بالا در سیستم‌های توصیه‌گر مدل می‌شوند. به عنوان مثال، امتیازی که یک کاربر به یک فیلم می‌دهد، می‌تواند به تعداد محدودی ویژگی نهفته وابسته باشد، مانند علاقه کاربر به ژانر فیلم. در سیستم پیشنهادی، رتبه‌بندی صریح برای توصیه فیلم استفاده می‌شود، اما در آینده می‌توان از تکنیک‌های تشخیص احساسات[۲] برای استخراج ترجیحات کاربران استفاده کرد و این روش را به عنوان راه‌حلی برای مشکل شروع سرد، در نظر گرفت[۸۳]. همچنین، ادغام اطلاعات زمینه‌ای مانند زمان و مکان می‌تواند به طراحی یک سیستم توصیه‌گر ترکیبی بافت‌آگاه[۳][۸۳] منجر شود تا فیلم‌هایی توصیه شوند که با زمینه فعلی کاربر مطابقت دارند و تغییر علایق کاربر براساس مکان و زمان را پوشش دهند و تجربه کلی کاربری را بهبود دهند. از نظر تأثیرات تجاری، ضروری است بررسی شود که آیا بهبود صحت پیش‌بینی توسط الگوریتم پیشنهادی، به افزایش ارزش کسب‌وکار در محیط واقعی، از جمله نرخ کلیک (CTR[2])، تعامل بیشتر کاربران با پلتفرم و نرخ حفظ مشتری [۸۴] منجر می‌شود یا خیر. سیستم پیشنهادی همچنین می‌تواند به عنوان توصیه‌گر گروهی توسعه یابد، زیرا در پلتفرم‌های آنلاین فیلم، یک حساب کاربری معمولاً توسط چندین کاربر استفاده می‌شود[۸۵][۸۶]. نمونه ای از توصیه گروهی، توصیه یک فیلم است که همه اعضای یک خانواده را که با هم به تماشا نشسته‌اند، راضی می‌کند [۸۷]. الگوریتم پیشنهادی را می‌توان از نظر معیارهای ارزیابی که عملکرد سیستم‌های توصیه فیلم را فراتر از صحت[۳] اندازه‌گیری کنند از قبیل تازگی[۴]، تنوع[۵]، سرندیپیتی[۶] و پوشش[۷] مورد بررسی قرار داد، زیرا در حوزه سیستم‌های توصیه‌گر، سال‌هاست که به خوبی ثابت شده است که بهینه‌سازی برای صحت پیش‌بینی، کافی نیست و چندین فاکتور کیفیت دیگر باید به‌طور موازی در نظر گرفته شود[۸۴]. در این تحقیق، مسئله بهبود عملکرد سیستم توصیه‌گر به عنوان یک مسئله بهینه‌سازی تک‌هدفه با استفاده از تابع هزینه تک‌هدفه پیشنهادی (شامل چهار هدف مختلف برای ارزیابی سیستم) بررسی شد. در تحقیقات آینده، می‌توان این اهداف را جداگانه در نظر گرفت و از الگوریتم‌های بهینه‌سازی چندهدفه مانند الگوریتم ژنتیک چند هدفه (NSGA-II[8]) استفاده نمود. همچنین الگوریتم فراابتکاری ترکیبی طراحی شده (گرگ خاکستری فازی ترکیب شده با الگوریتم بهینه‌سازی شیر و الگوریتم تکامل تفاضلی)، با الگوریتم نلدرمید به عنوان یک الگوریتم جستجوی محلی قدرتمند، ترکیب شد. برای تحقیقات آینده پیشنهاد می‌شود الگوریتم برنامه‌ریزی

[1] . Matrix Factorization

[2] . click-through rates (CTR)

[3] . accuracy

[4] . Novelty

[5] . Diversity

[6] . Serendipity

[7] . Coverage

[8] . Non-Dominated Sorting Genetic Algorithm II (NSGA-II)

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

مربعی متوالی(SQP[1])، به منظور افزایش احتمال رسیدن به بهینه سراسری، جایگزین الگوریتم نلدرمید شده و مورد ارزیابی قرار گیرد. همچنین می‌توان بهینه‌سازی را برای فرمول پیش‌بینی رتبه انجام داد و عملکرد سیستم توصیه‌گر را بررسی نمود.

تعارض منافع

نویسندگان اعلام می کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

تاییدیه اخلاقی

نویسندگان متعهد می‌شوند که مطالب این مقاله را در هیچ مجله دیگری به چاپ نرسانده اند.

مشارکت های نویسندگان

هاله نخعی راد تحقیق و تحلیل داده‌ها، نرم‌افزار و شبیه‌سازی، آنالیز و تحلیل نتایج، نگارش و تهیه پیش‌نویس اصلی

حسام زندحسامی تحلیل، بازبینی و ویرایش

عباس طلوعی اشلقی تحلیل، بازبینی و ویرایش

منابع مالی

در انجام این تحقیق، کمک مالی از هیچ سازمانی دریافت نشده است.

UNCORRECTED PROOF

[1] .Sequential Quadratic Programming(SQP)

مراجع

[1] S. Gupta, D. Rawat, K. Gupta, A.K. Yadav, R. Gandhi, A. Gupta. “Movie Recommendation System Using Machine Learning and MERN Stack.” In: A. Khanna, Z. Polkowski, O. Castillo (eds) Proceedings of Data Analytics and Management. Lecture Notes in Networks and Systems, vol. 572. Springer, Singapore (2023). https://doi.org/10.1007/978-981-19-7615-5_20

[2] P. Khadka, P. Lamichhane. “Content-based Recommendation Engine for Video Streaming Platform.” (2023). https://doi.org/10.48550/arXiv.2308.08406

[3] K. Ma. “Content-based Recommender System for Movie Website.” (2016).

[4] P. Sharma, Y. Lokesh. “Movie Recommendation System Using Item Based Collaborative Filtering.” International Journal of Innovative Research in Computer Science & Technology (IJIRCST), 8(4) (2020). https://ssrn.com/abstract=3672412

[5] S. Suresh Kumar, M. Srivastava, Mohana. “YouTube and Movie Recommendation System Using Machine Learning.” Second International Conference on Electronics and Renewable Systems (ICEARS), Tuticorin, India, pp. 1352–1356 (2023). https://doi.org/10.1109/ICEARS56392.2023.10084999

[6] Z. Yao. “Review of Movie Recommender Systems Based on Deep Learning.” SHS Web of Conferences, 159 (2023). https://doi.org/10.1051/shsconf/202315902010

[7] J. Bobadilla, F. Ortega, A. Hernando, J. Alcalá. “Improving collaborative filtering recommender system results and performance using genetic algorithms.” Knowledge-Based Systems, 24, 1310–1316 (2011). https://doi.org/10.1016/j.knosys.2011.06.005

[8] J.L. Herlocker, J.A. Konstan, L.G. Terveen, J.T. Riedl. “Evaluating collaborative filtering recommender systems.” ACM Transactions on Information Systems (TOIS), 22(1), 5–53 (2004).

[9] D. Valcarce, A. Landin, J. Parapar, A. Barreiro. “Collaborative filtering embeddings for memory-based recommender systems.” Engineering Applications of Artificial Intelligence, 85, 347–356 (2019). http://dx.doi.org/10.1016/j.engappai.2019.06.020

[10] Y. Koren, R. Bell. “Advances in Collaborative Filtering.” In: F. Ricci, L. Rokach, B. Shapira, P. Kantor (eds) Recommender Systems Handbook. Springer, Boston, MA (2011). https://doi.org/10.1007/978-0-387-85820-3_5

[11] M. Papagelis, D. Plexousakis, T. Kutsuras. “Alleviating the Sparsity Problem of Collaborative Filtering Using Trust Inferences.” Lecture Notes in Computer Science, 3477, 224–239 (2005). https://doi.org/10.1007/11429760_16

[12] V. Tyagi, V. Sharma, Y. Samantray. “Movie Recommendation System.” International Journal of Advance Research And Innovative Ideas In Education (IJARIIE), 9(3), 2815–2818 (2023).

[13] X. Ning, C. Desrosiers, G. Karypis. “A Comprehensive Survey of Neighborhood-Based Recommendation Methods.” In: F. Ricci, L. Rokach, B. Shapira (eds) Recommender Systems Handbook. Springer, Boston, MA (2015). https://doi.org/10.1007/978-1-4899-7637-6_2

[14] J. Herlocker, J.A. Konstan, J. Riedl. “An empirical analysis of design choices in neighborhood-based collaborative filtering algorithms.” Information Retrieval, 5(4), 287–310 (2002). https://doi.org/10.1023/A:1020443909834

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

[15] R. Chen, Q. Hua, Y.S. Chang, B. Wang, L. Zhang, X. Kong. “A Survey of Collaborative Filtering-Based Recommender Systems: From Traditional Methods to Hybrid Methods Based on Social Networks.” IEEE Access, 6, 64301–64320 (2018). https://doi.org/10.1109/ACCESS.2018.2877208

[16] B. Alhijawi, Y. Kilani. “A collaborative filtering recommender system using genetic algorithm.” Information Processing & Management (2020). https://doi.org/10.1016/j.ipm.2020.102310

[17] S. Mirjalili, S.M. Mirjalili, A. Lewis. “Grey Wolf Optimizer.” Advances in Engineering Software, 69, 46–61 (2014). http://dx.doi.org/10.1016/j.advengsoft.2013.12.007

[18] M. Köppen, D. Wolpert, W. Macready. “Remarks on a recent paper on the ‘No free lunch’ theorems.” Evolutionary Computation, IEEE Transactions on, 5, 295–296 (2001). https://doi.org/10.1109/4235.930318

[19] A. Akkaya, C. Közkurt, R. Durgut. “A Study on Meta-Heuristic Algorithms Used for Problem Solving in Recent Years.” Pioneer and Contemporary Studies in Engineering, 328–353 (2023). https://doi.org/10.59287/pcse.357

[20] X. Li, M. Yin. “Parameter estimation for chaotic systems by hybrid differential evolution algorithm and artificial bee colony algorithm.” Nonlinear Dynamics, 77 (2014). https://doi.org/10.1007/s11071-014-1273-9

[21] R. Burke, A. Felfernig, M. Göker. “Recommender Systems: An Overview.” AI Magazine, 32, 13–18 (2011). https://doi.org/10.1609/aimag.v32i3.2361

[22] F. Furtado, A. Singh. “Movie recommendation system using machine learning.” International Journal of Research in Industrial Engineering, 9(1), 84–98 (2020). https://10.22105/riej.2020.226178.1128

[23] R. Lavanya, U. Singh, V. Tyagi. “A Comprehensive Survey on Movie Recommendation Systems.” In 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS), 532–536 (March 2021). IEEE.

[24] R.E. Nakhli, H. Moradi, M.A. Sadeghi. “Movie recommender system based on percentage of view.” In 2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI), 656–660 (February 2019). IEEE. https://10.1109/KBEI.2019.8734976

[25] U. Thakker, R. Patel, M. Shah. “A comprehensive analysis on movie recommendation system employing collaborative filtering.” Multimedia Tools and Applications, 80(19), 28647–28672 (2021).

[26] M. Saraswat, S. Chakraverty, A. Kala. “Analyzing emotion based movie recommender system using fuzzy emotion features.” International Journal of Information Technology, 12, 467–472 (2020).

[27] C. Lee, D. Han, K. Han, M. Yi. “Improving graph-based movie recommender system using cinematic experience.” Applied Sciences, 12(3), 1493 (2022).

[28] S. Salloum, D. Rajamanthri. “Implementation and evaluation of movie recommender systems using collaborative filtering.” Journal of Advances in Information Technology, 12, 189–196 (2021). https://10.12720/jait.12.3.189-196

[29] T. Anwar, V. Uma. “Comparative study of recommender system approaches and movie recommendation using collaborative filtering.” International Journal of System Assurance Engineering and Management, 12, 426–436 (2021).

[30] H. Tahmasebi, R. Ravanmehr, R. Mohamadrezaei. “Social movie recommender system based on deep autoencoder network using Twitter data.” Neural Computing and Applications, 33, 1607–1623 (2021).

[31] F. Pecune, S. Murali, V. Tsai, Y. Matsuyama, J. Cassell. “A model of social explanations for a conversational movie recommendation system.” In Proceedings of the 7th International Conference on Human-Agent Interaction, 135–143 (September 2019).

[32] R.H. Singh, S. Maurya, T. Tripathi, T. Narula, G. Srivastav. “Movie recommendation system using cosine similarity and KNN.” International Journal of Engineering and Advanced Technology, 9(5), 556–559 (2020).

[33] S.R.S. Reddy, S. Nalluri, S. Kunisetti, S. Ashok, B. Venkatesh. “Content-Based Movie Recommendation System Using Genre Correlation.” In Proceedings of the Second International Conference on SCI 2018, Volume 2 (2019). https://doi.org/10.1007/978-981-13-1927-3_42

[34] M. Gupta, A. Thakkar, A. Aashish, V. Gupta, D.P.S. Rathore. “Movie Recommender System Using Collaborative Filtering.” 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC), 415–420 (2020). https://doi.org/10.1109/ICESC48915.2020.9155879

[35] J. Zhang, Y. Wang, Z. Yuan, Q. Jin. “Personalized real-time movie recommendation system: Practical prototype and evaluation.” Tsinghua Science and Technology, 25(2), 180–191 (2020). https://doi.org/10.26599/TST.2018.9010118

[36] F. Lang, L. Liang, K. Huang, T. Chen, S. Zhu. “Movie recommendation system for educational purposes based on field-aware factorization machine.” Mobile Networks and Applications, 26(5), 2199–2205 (2021).

[37] S.S. Choudhury, S.N. Mohanty, A.K. Jagadev. “Multimodal trust based recommender system with machine learning approaches for movie recommendation.” International Journal of Information Technology, 13(2), 475–482 (2021). https://doi.org/10.1007/s41870-020-00553-2

[38] R. Ahuja, A. Solanki, A. Nayyar. “Movie Recommender System Using K-Means Clustering AND K-Nearest Neighbor.” 263–268 (2019). https://doi.org/10.1109/CONFLUENCE.2019.8776969

[39] N. Bhalse, R. Thakur. “WITHDRAWN: Algorithm for movie recommendation system using collaborative filtering.” https://doi.org/10.1016/j.matpr.2021.01.235 (2021).

[40] Z.Z. Darban, M.H. Valipour. “GHRS: Graph-based hybrid recommendation system with application to movie recommendation.” Expert Systems with Applications, 200, 116850 (2022).

[41] M.M. Reddy, R.S. Kanmani, B. Surendiran. “Analysis of Movie Recommendation Systems; with and without considering the low rated movies.” 1–4 (2020). https://doi.org/10.1109/ic-ETITE47903.2020.453

[42] P. Sharma, L.Y. Yadav. “Movie Recommendation System Using Item Based Collaborative Filtering.” International Journal of Innovative Research in Computer Science & Technology (IJIRCST), ISSN 2347-5552 (2020).

[43] X. Ha, T.Y. Tang. “Incorporating Singular Value Decomposition in User-based Collaborative Filtering Technique for a Movie Recommendation System: A Comparative Study.” In Proceedings of the 2019 International Conference on Pattern Recognition and Artificial Intelligence (PRAI ’19), 12–15 (2019). https://doi.org/10.1145/3357777.3357782

[44] M.S. Kumar, J. Prabhu. “A hybrid model collaborative movie recommendation system using K-means clustering with ant colony optimisation.” International Journal of Internet Technology and Secured Transactions, 10(3), 337–354 (2020).

[45] M.F. Aljunid, D.H. Manjaiah. “Movie Recommender System Based on Collaborative Filtering Using Apache Spark.” In: V. Balas, N. Sharma, A. Chakrabarti (eds) Data Management, Analytics and Innovation. Advances in Intelligent Systems and Computing, vol. 839. Springer, Singapore (2019). https://doi.org/10.1007/978-981-13-1274-8_22

[46] G. Adomavicius, A. Tuzhilin. “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 (2005). https://doi.org/10.1109/TKDE.2005.99

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

[47] J. Lu, D. Wu, M. Mao, W. Wang, G. Zhang. “Recommender system application developments: a survey.” Decision Support Systems, 74, 12–32 (2015).

[48] M. Balabanović, Y. Shoham. “Fab: content-based, collaborative recommendation.” Communications of the ACM, 40(3), 66–72 (1997).

[49] Z. Nakhaei Rad, H. Zandhessami, A. Tolouei Ashlaghi. “Improving Collaborative Filtering Recommender System Results and Performance using Combination of Fuzzy Grey Wolf Optimizer Algorithm and Lion Optimization Algorithm.” Journal of Industrial Management Perspective, 11(4), 197–222 (2021). https://doi.org/10.52547/JIMP.11.4.197 (In Persian)

[50] H. Nakhaei Rad, H. Zandhessami, and A. Toloie Eshlaghy. “Improving Collaborative Filtering-based Recommender System Using New Hybrid Meta-Heuristic Algorithm.” Journal of Soft Computing and Information Technology 14, no. 4 (2025): 63–81. https://doi.org/10.22034/jscit.2025.500498.2094 (In Persian)

[51] T.M. Ma, X. Wang, F.C. Zhou, S. Wang. “Research on diversity and accuracy of the recommendation system based on multi-objective optimization.” Neural Computing and Applications, 35(7), 5155–5163 (2023). https://doi.org/10.1007/s00521-020-05438-w

[52] Y. Yuan, L. Chen, J. Yang. “A Multidimensional Model for Recommendation Systems Based on Classification and Entropy.” Electronics, 12(2), 402 (2023). https://doi.org/10.3390/electronics12020402

[53] N. Luong Vuong, T. Vo, T. Nguyen. “Adaptive KNN-Based Extended Collaborative Filtering Recommendation Services.” Big Data and Cognitive Computing, 7, 106 (2023). https://doi.org/10.3390/bdcc7020106

[54] P. Resnick, N. Iacovou, M. Suchak, et al. “GroupLens: An Open Architecture for Collaborative Filtering of Netnews.” In Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work, Chapel Hill, NC, 22–26 October 1994, 175–186. https://doi.org/10.1145/192844.192905

[55] W. Wang, Y. Lu. “Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model.” IOP Conference Series: Materials Science and Engineering, 324, 012049 (2018). https://doi.org/10.1088/1757-899X/324/1/012049

[56] B. Rawat, S. Dwivedi. “Selecting Appropriate Metrics for Evaluation of Recommender Systems.” International Journal of Information Technology and Computer Science, 11, 14–23 (2019). https://doi.org/10.5815/ijitcs.2019.01.02

[57] L. Rodriguez, O. Castillo, J. Soria. “A Study of Parameter Dynamic Adaptation with Fuzzy Logic for the Grey Wolf Optimizer Algorithm.” 228–238 (2017). https://doi.org/10.1007/978-3-319-62434-1_19

[58] M. Yazdani, F. Jolai. “Lion Optimization Algorithm (LOA): A nature-inspired metaheuristic algorithm.” Journal of Computational Design and Engineering (2015). http://dx.doi.org/10.1016/j.jcde.2015.06.003

[59] M. Ahmad, N.A. Mat Isa, W. Lim, K.M. Ang. “Differential evolution: A recent review based on state-of-the-art works.” AEJ - Alexandria Engineering Journal, 61, 3831–3872 (2022). https://doi.org/10.1016/j.aej.2021.09.013

[60] R. Storn, K. Price. “Differential evolution–a simple and efficient heuristic for global optimization over continuous spaces.” Journal of Global Optimization, 11(4), 341–359 (1997).

[61] X. Li, M. Yin. “Parameter estimation for chaotic systems by hybrid differential evolution algorithm and artificial bee colony algorithm.” Nonlinear Dynamics, 77 (2014). https://doi.org/10.1007/s11071-014-1273-9

[62] J.A. Nelder, R. Mead. “A Simplex method for function minimization.” The Computer Journal, 7(4), 308–313 (1965). https://doi.org/10.1093/comjnl/7.4.308

[63] J. Zhou, G. Cui, S. Hu, Z. Zhang, C. Yang, Z. Liu, … M. Sun. “Graph neural networks: A review of methods and applications.” AI Open, 1, 57–81 (2020).

[64] R. Katarya. “Movie recommender system with metaheuristic artificial bee.” Neural Computing and Applications, 30 (2018). https://doi.org/10.1007/s00521-017-3338-4

[65] N. Tohidi, C. Dadkhah. “Improving the performance of video collaborative filtering recommender systems using optimization algorithm.” International Journal of Nonlinear Analysis and Applications (IJNAA), 11(1), 283–295 (2020). http://dx.doi.org/10.22075/IJNAA.2020.19127.2058

[66] M. Hatami, S. Pashazadeh. “Improving results and performance of collaborative filtering-based recommender systems using cuckoo optimization algorithm.” International Journal of Computer Applications, 88(16) (2014). https://doi.org/10.5120/15440-3981

[67] C. Feng, J. Liang, P. Song, Z. Wang. “A fusion collaborative filtering method for sparse data in recommender systems.” Information Sciences, 521, 365–379 (2020). https://doi.org/10.1016/j.ins.2020.02.052

[68] S.V. Vimala, K. Vivekanandan. “A Kullback–Leibler divergence-based fuzzy C-means clustering for enhancing the potential of a movie recommendation system.” SN Applied Sciences, 1(7), 1–11 (2019). https://link.springer.com/article/10.1007/s42452-019-0708-9

[69] A. Gazdar. “A new Similarity Measure for Collaborative Filtering based Recommender Systems.” Knowledge-Based Systems (2019). https://doi.org/10.1016/j.knosys.2019.105058

[70] G. Behera, N. Nain. “Collaborative Filtering with Temporal Features for Movie Recommendation System.” Procedia Computer Science, 218, 1366–1373 (2023). https://doi.org/10.1016/j.procs.2023.01.115

[71] S. Rohit, V. Sathish, T. Mehrotra, B. Das. “Applications of Optimal Stopping Algorithm for Social Graph Based Recommendation.” In 2019 IEEE Students Conference on Engineering and Systems (SCES), 1–6 (2019). https://doi.org/10.1109/SCES46477.2019.8977222

[72] S. Sridhar, D. Dhanasekaran, G.C.P. Latha. “Content-based movie recommendation system using MBO with DBN.” Intelligent Automation & Soft Computing, 35(3), 3241–3257 (2023). https://doi.org/10.32604/iasc.2023.030361

[73] S. Airen, J. Agrawal. “Movie Recommender System Using Parameter Tuning of User and Movie Neighbourhood via Co-Clustering.” Procedia Computer Science, 218, 1176–1183 (2023). https://doi.org/10.1016/j.procs.2023.01.096

[74] Y. Gao, J. Li, X. Wang, W. X. Zhao, and M. Wang. “Chat-Rec: Towards interactive and explainable LLMs-augmented recommender system.” arXiv preprint arXiv:2303.14524 (2023). https://doi.org/10.48550/arXiv.2303.14524

[75] S. Hwang, H. Ahn, and E. Park. “iMovieRec: A hybrid movie recommendation method based on a user-image-item model.” International Journal of Machine Learning and Cybernetics 9 (2023): Article 01828-3. https://doi.org/10.1007/s13042-023-01828-3

[76] I. H. Arsytania, E. B. Setiawan, and I. Kurniawan. “Movie recommender system with cascade hybrid filtering using convolutional neural network.” Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI) 9, no. 4 (2024): 1262–1274.

[77] S. Siet, S. Peng, S. Ilkhomjon, M. Kang, and D.-S. Park. “Enhancing sequence movie recommendation system using deep learning and KMeans.” Applied Sciences 14, no. 6 (2024): 2505. https://doi.org/10.3390/app14062505

[78] Z. Zhao, Y. Wang, H. Liu, L. Chen, and X. Zhang. “Clustering-based recommendation method with enhanced grasshopper optimisation algorithm.” CAAI Transactions on Intelligence Technology (2025): 1–16. https://doi.org/10.1049/cit2.12408

[79] H. Wang, G. Yu. “Personalized recommendation system K-neighbor algorithm optimization.” In Proceedings of the 1st International Conference on Information Technologies in Education and Learning (2016). https://doi.org/10.2991/icitel-15.2016.24

[80] A. Surendran, A. Kumar Yadav, A. Kumar. “Movie Recommendation System using Machine Learning Algorithms.” International Research Journal of Engineering and Technology (IRJET), 7(4) (2020).

[81] G. Lekakos, P. Caravelas. “A Hybrid approach for movie recommendation.” Multimedia Tools and Applications, 36, 55–70 (2008). https://doi.org/10.1007/s11042-006-0082-7

[82] B. Loepp, K. Herrmanny, J. Ziegler. “Blended Recommending: Integrating Interactive Information Filtering and Algorithmic Recommender Techniques.” (2015). https://doi.org/10.1145/2702123.2702496

[83] S. Lubos, A. Felfernig, M. Tautschnig. “An overview of video recommender systems: state-of-the-art and research issues.” Frontiers in Big Data, 6, 1281614 (2023). https://doi.org/10.3389/fdata.2023.1281614

[84] D. Jannach, M. Jugovac. “Measuring the Business Value of Recommender Systems.” ACM Transactions on Management Information Systems, 10, 1–23 (2019). https://doi.org/10.1145/3370082

[85] A. Felfernig, R. Burke. “Constraint-based recommender systems: technologies and research issues.” In Proceedings of the 10th international conference on Electronic commerce, 1–10 (2008).

[86] Judith Masthoff. “Group Recommender Systems: Aggregation, Satisfaction and Group Attributes.” (2015). https://doi.org/10.1007/978-1-4899-7637-6_22

[87] T. De Pessemier, D. Verlee, L. Martens. “Enhancing Recommender Systems for TV by Face Recognition.” 243–250 (2016). https://doi.org/10.5220/0005861302430250