



Semnan University

Journal of Modeling in Engineering

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

ISSN: 2783-2538



Research Article

A Fair Group Recommendation System Based on Members and Leader Influences

Mostafa Sabzekar ^{a,*}, Bentolhoda Moazeni ^b

^a Assistant Professor, Department of Computer Engineering, Birjand University of Technology, Birjand, Iran

^b M.S Graduated, Department of Computer Engineering, Islamic Azad University, Birjand Branch, Birjand, Iran

PAPER INFO

Paper history:

Received: 01 August 2023

Revised: 09 December 2023

Accepted: 13 December 2023

Keywords:

Group recommender systems,
Fairness,
Aggregation function.

ABSTRACT

In a group recommender system, the effort is made to provide recommendations to a group of individuals rather than a single person. In these systems, the opinions of all group members are influential in decision-making, aiming to provide the best choice despite different personal preferences. This article attempts to present a group recommender system capable of identifying the relationship among users and eventually determining the influence of each user on the group, subsequently offering the best recommendations based on these connections. Moreover, a new criterion for determining leadership in the group is introduced, which identifies the leader of the group based on the level of trust, similarity, belongingness, and dependence of users on the group. Additionally, a novel criterion for delivering fair recommendations to the group is proposed, suggesting items to users with the most positive feedback among all group members. The proposed algorithm is compared with similar algorithms in this domain in two sections. In the evaluation section of assigned rankings, the accuracy of the proposed method was close to 100% in all cases, reporting an average improvement of 5% compared to the compared methods. In the recommendation evaluation section, well-known criteria such as nDCG, group satisfaction, and fairness were used, where the proposed method showed an average improvement of 41%, 35%, and 38%, respectively, considering the number of diverse recommendations in each of the mentioned criteria on average.

DOI: <https://doi.org/10.22075/jme.2023.31390.2507>

© 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: sabzekar@birjandut.ac.ir

How to cite this article:

Sabzekar, M., & Moazeni, B. (2024). A fair group recommendation system based on members and leader influences. Journal of Modeling in Engineering, 22(77), 221-243. doi: 10.22075/jme.2023.31390.2507

مقاله پژوهشی

ارائه سیستم جدید توصیه عادلانه گروهی مبتنی بر تأثیر اعضا و رهبر

مصطفی سبزه کار^{۱*} و بنت‌الهدی مؤذنی^۲

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۲/۰۵/۱۰ بازنگری مقاله: ۱۴۰۲/۰۹/۱۸ پذیرش مقاله: ۱۴۰۲/۰۹/۲۲	در یک سیستم توصیه‌گر گروهی تلاش می‌شود ارائه توصیه به گروهی از افراد به جای یک فرد صورت پذیرد. در این سیستم‌ها نظرات تمام اعضای گروه در تصمیم‌گیری مؤثر بوده و سعی می‌شود تا با وجود متفاوت بودن ترجیحات شخصی، بهترین انتخاب فراهم آید. این مقاله، سعی در ارائه یک سیستم توصیه‌گر گروهی دارد که بتواند ارتباط بین کاربران و درنهایت تأثیر هر کاربر بر گروه را مشخص کرده و سپس با توجه به این ارتباطات، بهترین توصیه را به پیشنهاد دهد. همچنین، معیاری جدید برای تعیین رهبر در گروه تعیین می‌شود که با توجه به میزان اعتماد، شباهت و تعلق و واستگی کاربران به گروه، رهبر آن گروه را مشخص نماید. بعلاوه، معیار جدیدی برای ارائه توصیه عادلانه به گروه ارائه شده که با استفاده از آن آیتم‌هایی به کاربران توصیه شود که بیشترین نظر مثبت در بین همه اعضا گروه داشته باشد. الگوریتم پیشنهادی در دو بخش با الگوریتم‌های مشابه در این زمینه، مقایسه شده است. در بخش ارزیابی رتبه‌های تعیین شده، دقت روش پیشنهادی در همه حالات نزدیک به ۱۰۰٪ به دست آمد که به نسبت روش‌های مورد مقایسه به طور متوسط برابر ۵ درصدی را گزارش نمود. در بخش ارزیابی توصیه‌ها نیز از معیارهای شناخته شده nDCG، رضایت‌گروهی و عدالت استفاده شد که روش پیشنهادی با در نظر گرفتن تعداد توصیه‌های مختلف به طور متوسط در هریک از معیارهای ذکر شده در حالت میانگین به ترتیب ۴۱٪، ۳۵٪، ۳۸٪ و ۳۵٪ برابر یافته است.
واژگان کلیدی: سیستم توصیه‌گر گروهی، عدالت، تابع تجمعی.	

DOI: <https://doi.org/10.22075/jme.2023.31390.2507>

© 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/>)

منظور کمک کردن به کاربران آنلاین برای انتخاب مناسب ترین خدمات و محصولات بهره گرفته شده است [۱]. از دیگر زمینه‌های کاربرد سیستم‌های توصیه‌گر می‌توان به استفاده آن در تشخیص‌های پزشکی مانند دیابت [۲]، گردشگری [۳]، مراقبت از سلامت [۴]، شبکه‌های اجتماعی [۵]، انرژی‌های تجدیدپذیر [۶] ... اشاره نمود. از ابتدای پیدایش سیستم‌های توصیه‌گر، تعاریف مختلفی برای آن ارائه شده است. در سال ۱۹۹۷، رسنیک و وارین

۱- مقدمه

سیستم‌های توصیه‌گر ابزارهای نرم‌افزاری هستند که مجموعه‌ای از آیتم‌ها را در حوزه‌های مختلف، مطابق با سلیقه و ترجیحات کاربر انتخاب و پیشنهاد می‌نمایند. آیتم‌های پیشنهادی، می‌تواند در مورد مسائل مختلف مانند خرید کالا، گوش دادن به موسیقی یا نمایش اخبار آنلاین باشد. با پیشرفت روزافزون فناوری اطلاعات، سیستم‌های توصیه‌گر نقش مهمی به خصوص در تجارت الکترونیک به

* پست الکترونیک نویسنده مسئول: sabzekar@birjandut.ac.ir

۱. استادیار، گروه مهندسی کامپیوتر، دانشگاه صنعتی بیرجند، بیرجند، ایران

۲. دانشآموخته کارشناسی ارشد، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد بیرجند، بیرجند، ایران

استناد به این مقاله:

سبزه کار، مصطفی، و مؤذنی، بنت‌الهدی. (۱۴۰۳). ارائه سیستم جدید توصیه عادلانه گروهی مبتنی بر تأثیر اعضا و رهبر. مدل سازی در مهندسی، ۷۷(۲۲)، ۲۲۱-۲۴۳.

doi: 10.22075/jme.2023.31390.2507

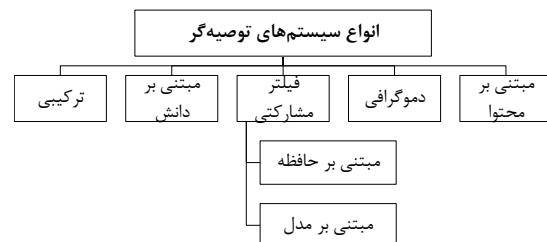
مختلف و متفاوتی نیز فراهم آید. روش‌های مبتنی بر فیلتر مشارکتی که خود به دو بخش مبتنی بر حافظه و مبتنی بر مدل تقسیم می‌شوند، براساس تصمیمات کاربر درگذشته کار می‌کنند و مبتنی بر این فرضیه‌اند که کاربرانی که رتبه‌بندی آن‌ها برای آیتم‌ها مشابه باشد یا رفتارهای مشابه داشته باشند، آیتم‌های مشابهی نیز برای توصیه دریافت می‌کنند. روش‌های مبتنی بر دانش بر اساس دانش خاص در مورد اینکه چگونه ویژگی‌های یک آیتم می‌تواند نیازها و ترجیحات کاربر را بطرف کند، یا چه میزان یک آیتم برای کاربر مفید و مؤثر است، عمل می‌نمایند. درنهایت، روش‌های ترکیبی از مزایای چند مورد بصورت همزمان بهره می‌گیرند.

بسیاری از سیستم‌های توصیه‌گر، تنها بر مدل تک کاربره تمرکز دارند اما در دنیای امروز، بخش وسیعی از فعالیت‌ها به صورت گروهی انجام می‌شود [۱۱]. با افزایش فعالیت‌های گروهی، نیاز به طراحی سیستم‌های توصیه‌گری است که به جای فرد، گروهی از افراد را برای ارائه یک توصیه واحد در نظر بگیرد. این سیستم‌ها به عنوان سیستم‌های توصیه‌گر گروهی شناخته می‌شوند [۱۲ و ۱۳]. در توصیه‌های گروهی، نظرات کل اعضای گروه در تصمیم‌گیری مؤثر است. بنابراین سعی می‌شود با استفاده از تجمیع ترجیحات، رضایت‌بخش‌ترین توصیه‌ها برای اعضای گروه تعیین گردد [۱۴]. وظیفه سیستم توصیه‌گر گروهی، طراحی مدلی به منظور رسیدگی به ترجیحات همه اعضای گروه است. این عمل، با استفاده از استراتژی‌های تجمیع^۲ و براساس نیازمندی‌های گروه انجام می‌شود [۹]. در این میان، وجود کاربران با علائق مشابه در یک گروه باعث توصیه‌های گروهی مؤثرتری می‌شود.

استراتژی‌های مورداستفاده برای سیستم توصیه‌گر گروهی را می‌توان از منظر نوع گروه، به دودسته اصلی گروه‌های ماندگار و گروه موقت تقسیم کرد. گروه‌های ماندگار، به گروه‌هایی با ساختارهای ثابت و سوابق تاریخی از تعاملات بین گروه و آیتم‌ها اشاره دارد. حال آن‌که گروه‌های دسته دوم، به صورت موقت تشکیل شده و کاربران ممکن است برای اولین بار در آن حضور یافته باشند و از این جهت، هیچ ساققه‌ای از تعاملات آن‌ها

سیستم توصیه‌گر را به عنوان سیستم‌هایی تعریف کردند که افراد سعی می‌کنند تا به یکدیگر آیتم‌های جذاب را توصیه کنند [۷]. محققان این تعریف را به سیستم‌هایی نسبت دادند که آیتم‌ها و گزینه‌هایی را به کاربران بر اساس علائق آن‌ها، صرف‌نظر از چگونگی ساخت و تولید این توصیه‌ها، پیشنهاد می‌دهند [۸]. در سال ۲۰۰۵، تعریف رسمی و فرموله شده از سیستم توصیه‌گر ارائه شد که در آن تابع مطلوبیت برای محاسبه میزان مناسب بودن یک آیتم برای کاربر، معرفی شد [۷]. طبق این تعریف فرض کنید C مجموعه همه کاربران، S مجموعه آیتم‌های قابل توصیه، u یک تابع مطلوبیت که میزان مفید بودن آیتم $s \in S$ را برای کاربر $c \in C$ اندازه‌گیری می‌کند (به طوری که $x: C \rightarrow S \Rightarrow R$ مجموعه گزینه‌های قابل توصیه به کاربر باشد، هدف یافتن توصیه‌ای است که مقدار تابع مطلوبیت u را بیشینه کند).

در سیستم‌های توصیه‌گر، ابتدا اطلاعاتی همچون ترجیحات کاربر، ویژگی‌های آیتم، تعامل گذشته کاربر و آیتم و زمان و مکان جمع‌آوری شده، سپس بر اساس این اطلاعات، میزان علاقه کاربر به هر آیتم تخمین زده می‌شود. درنهایت، مناسب‌ترین آیتمی که بتواند بیشترین رضایت را برای کاربر فراهم نماید، پیشنهاد می‌شود [۹ و ۱۰]. این سیستم‌ها به منظور تولید توصیه، از روش‌ها و الگوریتم‌های مختلفی استفاده می‌نمایند که در شکل (۱)، رایج‌ترین آن‌ها نمایش داده شده است.

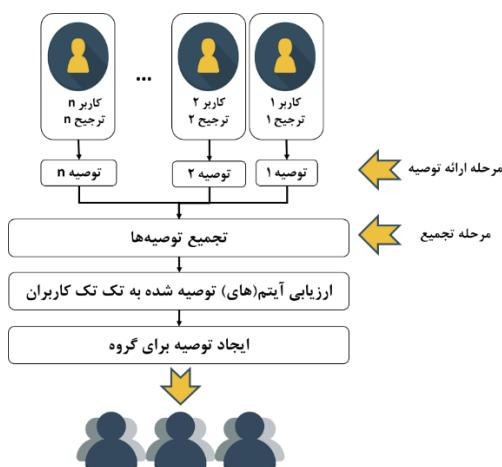


شکل ۱- انواع روش‌های تولید توصیه در سیستم توصیه‌گر

سیستم‌های مبتنی بر محتوا براساس سابقه علاقه‌مندی‌ها و ترجیحات کاربر، آموزش داده شده و درنهایت آیتم‌های مشابه با تاریخچه سابقه کاربر را به او توصیه می‌کنند. در روش‌های دموگرافی فرض بر این است که برای گروه‌های مختلف جمعیتی از قبیل سن، محدوده جغرافیایی و میزان تحصیلات، باید توصیه‌های

² Aggregation Strategies

توصیه نهایی برای گروه با توجه به تجمیع لیست توصیه‌ها تعیین می‌گردد. در این روش، مرحله توصیه قبل از تجمیع قرار دارد به این صورت که گزینه‌ها یا موارد توصیه شده به اعضای گروه، به‌طور جداگانه، توصیه و سپس ارزیابی می‌شوند. این استراتژی به عنوان تجمیع پیش‌بینی‌ها شناخته می‌شود. شکل (۳) نمایانگر استراتژی مربوط به رویکرد مبتنی بر یکپارچه‌سازی توصیه‌ها می‌باشد [۱۶ و ۱۸].

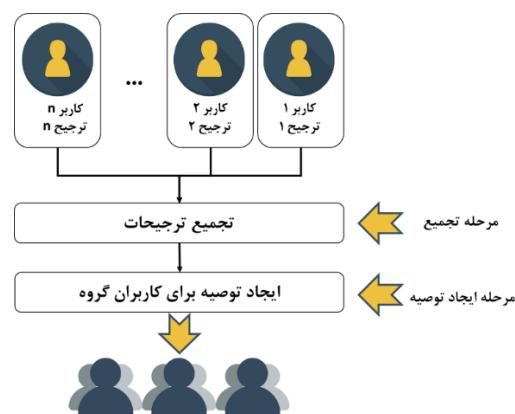


شکل ۳- رویکرد مبتنی بر یکپارچه‌سازی توصیه‌ها

یک چالش مهم در تمام سناریوهای توصیه گروه، چگونگی سازگار کردن گروه به عنوان یک کلیت، با توجه به اطلاعات و ترجیحات فردی اعضای گروه است [۲۰]. برای حل این مسئله به این نکته توجه می‌شود که چگونه ترجیحات شخصی می‌توانند برای رسیدن به توافق گروهی، تجمیع شوند. نظریه پردازان انتخاب اجتماعی، در اغلب موارد با مسائل مربوط به مرتب کردن رتبه‌ها در گیر هستند و سعی می‌کنند تا ترجیحات افراد را بر اساس آیتم‌های موجود مرتب کنند. این روش‌ها تلاش کمی برای طراحی و ارائه روش‌های تولید رتبه دارند. اما استفاده از این دسته روش‌ها برای زمانی که قرار است چندین ویژگی را در مرتب‌سازی دخالت دهنند، بسیار دشوار و حتی غیرممکن است. به منظور بهینه کردن فرآیند تجمیع، استفاده از تقریب می‌تواند راهکاری مناسب باشد. در استفاده از تقریب، سعی می‌شود تا توصیه‌ای ارائه شود که تا حد ممکن ترجیحات شخصی اعضا گروه را در نظر بگیرد.

توابع تجمیع را می‌توان به روش‌های مبتنی بر اکثریت، مبتنی بر توافق و خط مرزی طبقه‌بندی نمود [۲۱]. توابع

وجود ندارد [۱۵]. فارغ از نوع گروه، رویکردهای توصیه گروهی باید توصیه‌ای را برای گروه ارائه دهند که نمایانگر علاقه‌مندی‌های تمام اعضای گروه باشد. درنتیجه به تجمیع ترجیحات اعضا گروه برای تولید و ارائه یک توصیه به آن‌ها نیاز است [۱۶]. برای ایجاد توصیه گروه، می‌توان از دو روش مبتنی بر یکپارچه‌سازی پروفایل گروه و مبتنی بر یکپارچه‌سازی توصیه‌ها استفاده نمود [۱۷]. رویکرد نخست اغلب برای توصیه به گروه ماندگار مورد استفاده قرار می‌گیرد. این نوع رویکردها ابتدا یک پروفایل مشترک به نام پروفایل گروه، با توجه به تاریخچه تعاملات بین اعضای گروه و گزینه‌های توصیه‌شونده و همچنین ترجیحات اعضا گروه ایجاد کرده و گروه را به عنوان یک کاربر مجازی در نظر می‌گیرد. سیستم توصیه‌گر برای انجام عملیات توصیه به گروه، از این پروفایل گروه یا کاربر مجازی استفاده می‌کند. در این رویکرد، مرحله تجمیع قبل از مرحله توصیه قرار می‌گیرد. این استراتژی به عنوان تجمیع مدل‌ها نیز شناخته می‌شود [۱۸ و ۱۹]. شکل (۲) استراتژی مربوط به این رویکرد را نشان می‌دهد.



شکل ۲- رویکرد مبتنی بر یکپارچه‌سازی پروفایل گروه

از طرف دیگر، رویکرد مبتنی بر یکپارچه‌سازی توصیه‌ها اغلب برای توصیه به گروه‌های موقت استفاده می‌شود. از آنجا که در این رویکرد، سابقه تعاملات افراد گروه باهم و همچنین افراد با آیتم‌ها وجود ندارد، توصیه تنها از طریق تجمیع ترجیحات شخصی اعضا گروه حاصل می‌شود. بنابراین این رویکرد ابتدا برای هر یک از اعضای گروه به‌طور مستقل و جداگانه، اقدام به ارائه توصیه کرده و سپس توصیه‌های ارائه شده به اعضای گروه، به صورت رتبه‌بندی شده در یک لیست قرار داده می‌شود. درنهایت

ترجیحات کاربر را در نظر می‌گیرند [۲۳ و ۲۴]. در جدول ۱، بهطور خلاصه توابع ذکر شده نمایش داده شده‌اند. در فرمول‌های ارائه شده، u به کاربر و G به گروه و t به آیتم و I به مجموعه کل آیتم‌های توصیه شونده، اشاره دارد.

تجمیع مبتنی بر اکثریت، شامل مکانیزم‌های تجمیعی هستند که سعی در انتخاب محبوب‌ترین آیتم‌ها در بین کاربران را دارند [۹ و ۲۲]. توابع تجمیع مبتنی بر توافق سعی دارند تا ترجیحات همه اعضای گروه را در نظر گیرند [۲۰ و ۲۳]. توابع تجمیع خط مرزی، مکانیزم‌های تجمیعی را شامل می‌شوند که فقط زیرمجموعه‌ای از

جدول ۱- توابع تجمیع استفاده شده در منابع

استراتژی تجمیع	توضیح عملکرد	دسته	فرمول
تجمیع آرا یا تعدد (PLU)	توصیه‌ی آیتمی با بالاترین رأی برای هر کاربر در گروه	اکثریت	$\text{argmax}_{t \in I}(\text{votings}(t))$ [in each iteration]
(BRC) بوردا	بیشینه مجموع نمرات آیتم	اکثریت	$\text{argmax}_{t \in I}\left(\sum_{u \in G} \text{score}(u, t)\right)$
قانون کوپلندر (COP)	مقایسه دو آیتم	اکثریت	$\text{argmax}_{t \in I}(w(t, I - \{t\}) - l(t, I - \{t\}))$
رأی‌گیری تأییدی (APP)	عدد آیتم در نظر گرفته شده برای ارزیابی بالاتر از حد آستانه باشد.	اکثریت	$\text{argmax}_{t \in I}(\{u \in G : \text{eval}(u, t) \geq \text{threshold}\})$
جمع پذیری سودمند (ADD)	استفاده از مجموع رتبه‌های داده شده به آیتم‌ها	توافق	$\text{argmax}_{t \in I}\left(\sum_{u \in G} \text{eval}(u, t)\right)$
میانگین (AVG)	استفاده از میانگین رتبه‌های داده شده به آیتم‌ها	توافق	$\text{argmax}_{t \in I}\left(\frac{\sum_{u \in G} \text{eval}(u, t)}{ G }\right)$
ضرب (MUL)	استفاده از ضرب رتبه‌های داده شده به آیتم‌ها	توافق	$\text{argmax}_{t \in I}\left(\prod_{u \in G} \text{eval}(u, t)\right)$
میانگین بدون کمترین رتبه (AVM)	استفاده از میانگین رتبه‌های داده شده توسط گروه که از حد آستانه بیشتر باشند	توافق	$\text{argmax}_{(t \in I : \nexists u \in G \text{eval}(u, t) \leq \text{threshold})}\left(\frac{\sum_{u \in G} \text{eval}(u, t)}{ G }\right)$
عادلانه (FAI)	استفاده از رتبه‌بندی آیتم‌ها با توجه به ترتیب انتخاب آن‌ها توسط کاربران	توافق	$\text{argmax}_{t \in I}(\text{eval}(t))$ [in each iteration]
پایین‌ترین رتبه (LMS)	بیشینه کردن مقدار حداقل رتبه برای هر آیتم	خط مرزی	$\text{argmax}_{t \in I}(\text{mineval}(t))$
بیشترین لذت (MPL)	بیشینه کردن مقدار حداکثر رتبه برای هر آیتم	خط مرزی	$\text{argmax}_{t \in I}(\text{maxeval}(t))$
رأی اکثریت (MAJ)	بیشینه کردن، اکثریت رتبه برای هر آیتم	خط مرزی	$\text{argmax}_{t \in I}(\text{majorityeval}(t))$
محترم‌ترین فرد (MRP)	اختصاص رتبه بر اساس ارزش و احترام فرد	خط مرزی	$\text{argmax}_{t \in I}(\text{eval}(u_{mrp}, t))$

بر یکدیگر بر اساس شباهت و اعتماد آنها و همچنین میزان وابستگی و تعلق هر فرد به گروه و در نظر گرفتن مفهوم عدالت ارائه نماییم.

به طور خلاصه نوآوری‌های این مقاله را می‌توان به صورت زیر خلاصه نمود:

- انجام توصیه با توجه به تأثیر کاربران بر هم
- ارائه معیاری جدید برای تعیین رهبر در گروه با توجه به میزان اعتماد، شباهت و تعلق و وابستگی کاربران به گروه
- اندازه‌گیری تأثیر افراد موجود در گروه به صورت کارا

۲- پیشینه تحقیق

مطالعات و پژوهش‌های زیادی در حوزه سیستم توصیه گروهی انجام شده است. یکی از اولین تحقیقات در این زمینه در سال ۲۰۰۱ انجام شد یک سیستم توصیه گروهی به نام پلی‌لنژ^۴ به منظور پیشنهاد فیلم به گروهی از کاربران ارائه گردید [۲۷].

در [۲۸] یک سیستم توصیه گروهی ارائه شد که قادر به پشتیبانی از رتبه‌بندی جزئی آیتم‌ها از کاربران مختلف در قالب K لیست برتر است. این سیستم، از دو مرحله تشکیل شده است. در مرحله اول، لیست‌های توصیه‌ها برای اعضا گروه با استفاده از تکنیک فیلتر مشارکتی مبتنی بر کاربر تولید می‌شود. سپس، لیست توصیه‌های تولید شده در مرحله قبل با استفاده از رأی گیری تقریبی، ترکیب شده تا m آیتم کاندید، مشخص شوند. سپس K آیتم با رتبه بالاتر برای توصیه به گروه انتخاب می‌شوند.

پژوهش [۲۹] یک طرح جدید به نام *PFGR* پیشنهاد نموده است که از تئوری بازی و احتمالات برای توصیه گروه استفاده می‌کند تا صحت و عدالت را بین اعضای یک گروه برقرار کند. این سیستم، اولین ترجیح هر کاربر را تخمین زده، با جمع کردن ترجیحات اعضای گروه، در مورد انتخاب یک سرویس تصمیم‌گیری می‌کند. سرانجام، *PFGR* فعالیت کاربران را در نظر گرفته و از استراتژی مبتنی بر تئوری بازی برای تهییه یک لیست رتبه‌بندی استفاده کرده تا برای هر عضو گروه تا حد ممکن، توصیه، عادلانه باشد.

سیستم توصیه گروهی، حتی در صورت عدم سازگاری ترجیحات، باید بتواند بهترین انتخاب ممکن را برای جمعی از افراد انجام دهد که کمترین فاصله را با ترجیحات اعضای گروه داشته باشد. در این سیستم‌ها باید عدالت^۱، تساوی^۲ و کارایی^۳ حاکم باشند. گروه‌های کاربران ممکن است ناهمگن باشند یعنی اگر آیتمی برای یک دسته از افراد گروه، خوب باشد، ممکن است برای افرادی دیگر از همان گروه نامطلوب باشد و در صورت انتخاب آن، این افراد ناراضی می‌شوند. بنابراین توصیه عادلانه، یک مسئله بسیار مهم در سیستم توصیه گروهی است و مقالات مختلفی به آن پرداخته‌اند. نویسنده‌گان در [۱۵] عدالت را نشان‌دهنده میزان رضایت کاربران مختلف در یک گروه، در مورد آیتم توصیه شده تعریف نموده و بیان می‌نمایند که عدالت باید بازتاب‌دهنده مقایسه بین میزان مطلوبیت کاربران موجود در یک گروه باشد. پژوهش [۲۵] این فرض را مطرح می‌کند که گروه، چندین بار، به‌طور عادلانه یک آیتم را انتخاب می‌کند و هر بار کاربران ناراضی از تصمیم‌گیری‌های قبلی، برای آیتم بعدی، اولویت بالاتری دارند. در [۲۶]، دو معیار به نام میزان تناسب^۴ و آزاد از حسابت^۵ برای تعیین عدالت ارائه شده است. در مفهوم اول، برای کاربر u و یک مجموعه آیتم مانند P می‌گوییم که P متناسب با u است، اگر حداقل m آیتم در P موجود باشد که کاربر u آن‌ها را ترجیح داده باشد، به این دلیل که m آیتم مورد علاقه کاربر در بسته پیشنهادی وجود دارد، این بسته برای کاربر عادلانه است. در مفهوم دوم، با در نظر گرفتن گروهی مانند G و مجموعه آیتم مانند P ، کاربر u عضو G آزاد از حسابت است اگر حداقل m آیتم از آیتم‌های مورد علاقه کاربر در مجموعه P باشد. در این صورت کاربر احساس می‌کند که بسته منصفانه است. در غیر این صورت نسبت به سایر اعضای گروه حسابت می‌کند.

با توجه به مطالب فوق، می‌توان گفت که عدالت در سیستم توصیه گروه به معنای کسب رضایت همه اعضای گروه در زمان توصیه است اما عملی کردن این مفهوم در سیستم توصیه گروه، هنوز به عنوان یک چالش پایر جا است. در این مقاله قصد داریم روش جدیدی برای محاسبه تأثیر اعضا

⁴ Proportionality

⁵ Envy-Freeness

⁶ Polylens

¹ Fairness

² Equity

³ Efficiency

تعیین رتبه‌های بالا جهت رتبه‌بندی گروه استفاده می‌شود. در این مقاله، ابتدا گروه‌های کاربران با استفاده از خوش‌بندی مشخص و شناسایی می‌شود. سپس، با استفاده از تکنیک‌های تجمعی نامبرده شده در فصل قبل، اقدام به پیش‌بینی رتبه‌بندی جهت ارائه توصیه به گروه می‌شود.

مقاله [۳۳] یک رابطه ترجیحی برای سیستم توصیه‌گر گروهی پیشنهاد نموده است که از ماتریس فاکتور برای پیش‌بینی روابط ناشناخته برای اعضای گروه استفاده می‌کند. برای تجمعی ترجیحات نیز از طریق یک استراتژی تجمع وزن جدید استفاده شده است. این پژوهش، برای تشکیل گروه از ترجیحات مشترک بین اعضا استفاده کرده است. سپس یک گراف ترجیحات جهت‌دار برای تعیین رتبه‌بندی آیتم‌ها توسط گروه کاربران استفاده شده که از آن برای تعیین وزن هر کاربر به آیتم و درنهایت وزن گروه کاربران به یک آیتم استفاده می‌شود.

از سوی دیگر، نویسنده‌گان در [۳۴] روشی به منظور توسعه سیستم‌های توصیه‌گر گروهی به نام MC-GR ارائه کردند. هدف از این مقاله، ایجاد توصیه‌هایی با در نظر گرفتن سهم هر یک از اعضای گروه از طریق وزن دادن به اعضا بر اساس درجه اهمیت آن‌ها، است. برای دستیابی به این هدف، ابتدا یک مدل امتیاز مشارکت اعضا تحت عنوان MCS پیشنهاد شده تا درجه اهمیت هر عضو مشخص گردد. سپس یک مدل رتبه‌بندی میانگین محلی مبتنی بر فاصله منهتن برای اصلاح پیش‌بینی‌ها ایجاد شده است.

محققین در [۳۵]، روشی به نام فیلترینگ مشارکتی مبتنی بر گروه برای ارائه توصیه به گروه پیشنهاد نموده‌اند. نقطه قوت این رویکرد این است که آیتم‌های مرتبط بر اساس موضوعات مورد علاقه هر گروه از کاربران پیشنهاد می‌شود. در پژوهشی دیگر برای به دست آوردن یک سیستم توصیه‌گر گروهی واقع‌بینانه، قاطعیت شخصیت افراد در نظر گرفته شده است [۳۶]. این روش ترجیحات زوجی را برای رتبه‌بندی‌ها در سیستم‌های توصیه‌گر گروهی در نظر گرفته است. به این منظور یک رویکرد سه مرحله‌ای ارائه شده که ابتدا از سه روش امتیازدهی زوجی برای پیش‌بینی امتیازات آیتم‌ها استفاده شده است. در گام دوم نمودار تاثیرگذاری شامل ویژگی‌ها شخصیتی از جمله قاطعیت و همکاری ایجاد شده و در نهایت یک مدل پویایی عقیده به

نتایج تجربی حاکی از موفقیت *PFGR* در ارائه توصیه‌های عادلانه با دقت بالا می‌باشد.

نویسنده‌گان در [۳۰] تلاش در ارائه یک سیستم توصیه‌گر گروه نمودند تا بتواند یک آیتم یا بسته‌ای از آیتم‌ها را به طور عادلانه به یک گروه از کاربران تخصیص دهند. این مطالعه دو رویکرد مختلف ارائه داده است. در رویکرد نخست ابتدا احتمال انتخاب آیتم α توسط گروه β محاسبه شده سپس، احتمال‌های به دست آمده برای هر آیتم باهم ترکیب شده تا احتمال بسته محاسبه شود. در این مدل فرض می‌شود آیتم‌ها مستقل از هم هستند. در مدل دوم با فرض وابسته بودن آیتم‌ها، ابتدا گروه با یک احتمال یکی از کاربران را به عنوان نماینده انتخاب می‌کند. این کاربر برای همه آیتم‌ها تصمیم‌گیری می‌کند و آیتم‌ها را انتخاب می‌کند. سپس احتمال اینکه آیتم α توسط کاربر β انتخاب شود محاسبه می‌شود. در نهایت احتمال اینکه این بسته توسط سایر کاربران ترجیح داده شود محاسبه شده و میزان رضایت آن‌ها از بسته مشخص می‌گردد.

در [۱۷] یک مفهوم ساده از عدالت مورد بررسی قرار گرفته که در آن حداقل مطلوبیتی که عضو گروه دریافت می‌کند، به عنوان عدالت شناخته می‌شود. این مطالعه از مفهوم بهینگی پرتو^۱ استفاده نموده و آیتم یا مجموعه آیتم‌های که برای همه اعضای گروه رتبه بالاتری را کسب کرده باشد، به عنوان بهینه پرتو در نظر گرفته و توصیه می‌شود.

نوروزی و کوهی نیز در پژوهش [۳۱]، یک سیستم توصیه‌گر گروهی ارائه داده‌اند که ابتدا با استفاده از خوش‌بندی اقدام به تشکیل گروه بر اساس شباهت کاربران می‌نماید. سپس دو معیار شباهت و اعتماد تعریف شده که بر اساس این دو معیار برای هر گروه یک رهبر تعیین می‌شود. همچنین میزان تأثیر هر یک از اعضا بر اساس معیار اعتماد مشخص می‌شود. درنهایت بعد از تعیین میزان تأثیر رهبر و هر عضو در گروه، رتبه هر آیتم مشخص شده و با استراتژی میانگین، یک توصیه به گروه ارائه می‌شود.

نویسنده‌گان در [۳۲] دو روش جدید تجمعی با ترکیبی از روش‌های رأی‌گیری تأییدی و سودمندی افزایشی ارائه نمودند تا آیتم‌های مورد علاقه اعضای گروه را مشخص و توصیه کنند. معیار سودمندی افزایشی، برای تعیین مجموع ترجیحات اعضای گروه و معیار رأی‌گیری تأییدی، برای

^۱ Pareto Optimality

ارائه گردید. استفاده از این الگوریتم سبب می‌شود تا نتایج مرتبطتری یافت شود. همچنین یکی از مزایای دیگر این روش، پشتیبانی از بهروزرسانی پویای پیش‌بینی‌های رتبه‌بندی در حالت آنلاین است. در [۳۹] مفهوم اعتماد نیز به سیستم‌های توصیه‌گر گروهی اضافه گردیده و در نتیجه سیستمی ارائه شده که با اضافه کردن مفهوم اعتماد در فرمول شباهت قادر است معتمدترین کاربر را نیز برای یک کاربر مشخص شده پیشنهاد دهد. جدول ۲ به طور خلاصه پژوهش‌های انجام شده و سیستم‌های توصیه‌گر گروهی مختلف را نشان می‌دهد.

منظور تجمعی آرا و عقاید ارائه گردیده است.

یک سیستم توصیه‌گر با ترکیب یک ماژول توصیه‌گر و یک سیستم خبره فازی در [۳۷] ارائه شده است. ماژول توصیه-گیر خود ترکیبی از سه زیرسیستم از نوع فیلتر مشارکتی، مبتنی بر محتوا و مبتنی بر دانش می‌باشد. این پژوهش بهدلیل ترکیب روش‌های اساسی ذکر شده، قادر است توصیه‌های محتوای دقیق‌تری ارائه دهد که باعث افزایش عملکرد شده است.

با هدف افزایش دقت و سرعت سیستم‌های توصیه‌گر گروهی در [۳۸] با بهره‌گیری از الگوریتم slope one روشی

جدول ۲- خلاصه سیستم‌های توصیه‌گر گروهی

نام پژوهه	سال	توضیحات
Top-K Lists [۲۸]	۲۰۱۷	<p>نقاط قوت:</p> <ul style="list-style-type: none"> - ایجاد لیست آیتم‌های رتبه‌بندی شده برای هر کاربر و سپس ادغام این لیست. - استفاده از رتبه‌بندی جزئی و فراهم‌شدن - امکان اینکه کاربران تنها تعدادی از آیتم‌ها را رتبه‌بندی کنند. <p>نقاط ضعف:</p> <ul style="list-style-type: none"> - عدم مؤثری‌بودن برای مقابله با شروع سرد، آیتم‌ها و کاربران جدید
PFGR [۲۹]	۲۰۲۰	<p>نقاط قوت:</p> <ul style="list-style-type: none"> - ارائه توصیه عادلانه برای همه اعضای یک گروه - استفاده از تئوری بازی و احتمالات که با داشتن پایه ریاضی توصیه‌های دقیق‌تری انجام می‌شود. <p>نقاط ضعف:</p> <ul style="list-style-type: none"> - زمان بروزه زینه بودن محاسبات
[۳۰]	۲۰۱۷	<p>نقاط قوت:</p> <ul style="list-style-type: none"> - استفاده از معیار عدالت برای توصیه گروهی، بررسی دقیق مفهوم عدالت <p>نقاط ضعف:</p> <ul style="list-style-type: none"> - زمان بروزه زینه بودن محاسبات
max-min fairness [۲۶]	۲۰۱۷	<p>نقاط قوت:</p> <ul style="list-style-type: none"> - استفاده از مفهوم عدالت <p>نقاط ضعف:</p> <ul style="list-style-type: none"> - زمان بروزه زینه بودن محاسبات
Pareto optimality [۱۷]	۲۰۱۹	<p>نقاط قوت:</p> <ul style="list-style-type: none"> - استفاده از مفهوم بهینگی پرتو، استفاده از مفهوم عدالت <p>نقاط ضعف:</p> <ul style="list-style-type: none"> - زمان بروزه زینه بودن محاسبات
[۳۱]	۲۰۲۰	<p>نقاط قوت:</p> <ul style="list-style-type: none"> - تعیین روابط کاربران بر هم در گروه و دخیل کردن این روابط در تصمیم‌گیری نهایی <p>نقاط ضعف:</p> <ul style="list-style-type: none"> - استفاده از معیار میانگین بدون درنظر گرفتن مفاهیمی همچون عدالت، میزان رضایت کاربران از توصیه
[۳۲]	۲۰۲۱	<p>نقاط قوت:</p> <ul style="list-style-type: none"> - ساده‌بودن عملیات توصیه <p>نقاط ضعف:</p>

	- عدم توجه به تأثیر کاربران بر تصمیمات هم - نقاط قوت: - ارائه روش جدید برای تجمعی ترجیحات، استفاده از گراف ترجیحات برای رتبه‌بندی آیتم‌ها در گروه - تخمین مناسب رتبه‌های آیتم‌ها در گروه - نقاط ضعف: - زمان بر بودن تولید گراف ترجیحات برای هر کاربر و درنتیجه زمان بر بودن تعیین رتبه آیتم‌ها برای گروه	۲۰۲۱	[۳۳]
	- نقاط قوت: - استفاده از تأثیر اعضا بر رتبه ارائه شده از سوی آن‌ها، - ارائه یک مدل جدید برای ترکیب رتبه‌های موجود در گروه - نقاط ضعف: - استفاده از نمونه‌گیری تصادفی برای تعیین نماینده هر گروه	۲۰۱۶	MC-GR [۳۴]
	- نقاط قوت: - استفاده از فیلترینگ مشارکتی پیشرفته برای ارائه توصیه - استخراج موضوعات مورد علاقه کاربران قبل از ارائه توصیه و سپس استفاده از آن برای توصیه - نقاط ضعف: - عدم توجه به رضایت‌بخش بودن آیتم توصیه شده نهایی برای کاربران	۲۰۱۶	Group-based Collaborative Filtering [۳۵]
	- نقاط قوت: - اعمال اولویت‌های زوجی برای محاسبه دقیق‌تر رتبه‌بندی آیتم‌ها - استفاده از ویژگی‌های شخصیتی برای درک تأثیر کاربر بر تصمیم نهایی - نقاط ضعف: - جمع آوری اطلاعات مربوط به ویژگی‌های شخصیتی کاربران با آزمون TKI - ثابت در نظر گرفتن ویژگی‌های شخصیتی کاربران در حالی که ممکن است کاربری تغییر نگرش دهد	۲۰۲۲	[۳۶]
	- نقاط قوت: - ترکیب رویکردهای مبتنی بر محتوا و مبتنی بر فیلتر مشارکتی - استفاده از الگوریتم‌های استاندارد سیستم‌های توصیه‌گر که به طور کامل بدون نیاز به الگوریتم‌های دیگر در سیستم یکپارچه شده‌اند - داشتن یک مازوّل خرجه فازی که از رتبه‌بندی نهایی محصولات بر اساس پارامترهای مختلف اطمینان حاصل می‌نماید. - نقاط ضعف: - عدم ارزیابی مستمر خروجی‌ها	۲۰۲۳	[۳۷]
	- نقاط قوت: - افزایش دقت توصیه گروهی در زمان کوتاه‌تر با استفاده از روش Slope One - پشتیبانی از به روزرسانی پویای پیش‌بینی‌های رتبه‌بندی در حالت آنلاین - نقاط ضعف: - نیاز به استفاده از اطلاعات بیشتر در مورد کاربران	۲۰۲۳	[۳۸]
	- نقاط قوت: - افزودن مفهوم اعتماد به سیستم توصیه‌گر گروهی	۲۰۲۳	[۳۹]

الگوریتم‌ها به روابط کاربران در گروه و تأثیرات آن‌ها بر نظرات یکدیگر توجه نمی‌کنند. در صورتی که نظر کاربران در گروه می‌تواند تحت تأثیر سایرین تغییر کند، الگوریتم‌هایی هم که سعی در یافتن این روابط دارند، هنوز با چالش‌های بسیاری مواجه هستند. تخمین دیه‌ها و اطلاعات

بر اساس بررسی مطالعات موجود در این حوزه، مواردی هنوز به عنوان چالش مطرح است. اولین چالش ناقص بودن و مناسب نبودن استراتژی‌های تجمعی جاری برای سیستم‌های توصیه‌گر است. این استراتژی‌ها اغلب بازخورد تصمیمات قلی، را در نظر نمی‌گیرند. دوم اینکه اغلب

در هر سیستم توصیه‌گر، مجموعه‌ای از کاربران به صورت $\{u_1, u_2, \dots, u_n\}$ و همچنین مجموعه‌ای از آیتم‌ها به صورت $\{I_1, I_2, \dots, I_m\}$ وجود دارد که به ترتیب n تعداد کاربران و m تعداد آیتم‌ها است. هر کاربر مانند u به هر یک از آیتم‌های موجود در مجموعه آیتم‌ها، می‌تواند علاقه داشته باشد، یا نداشته باشد. برای تعیین میزان علاقه کاربر به یک آیتم، از رتبه کاربر استفاده می‌شود. به عبارت بیشتر، نظر کاربران در مورد هر آیتم، در یک ماتریس ذخیره می‌شود که این ماتریس به نام ماتریس کاربر-آیتم، حاوی n سطر و m ستون است. نظر هر کاربر به صورت یک مقدار عددی در این ماتریس ذخیره می‌شود. حداقل و حداکثر مقدار، نحوه مقداردهی و ... همگی وابسته به سیستم جمع‌آوری‌کننده اطلاعات است. حالت کلی ماتریس کاربر-آیتم مطابق رابطه (۱) می‌باشد.

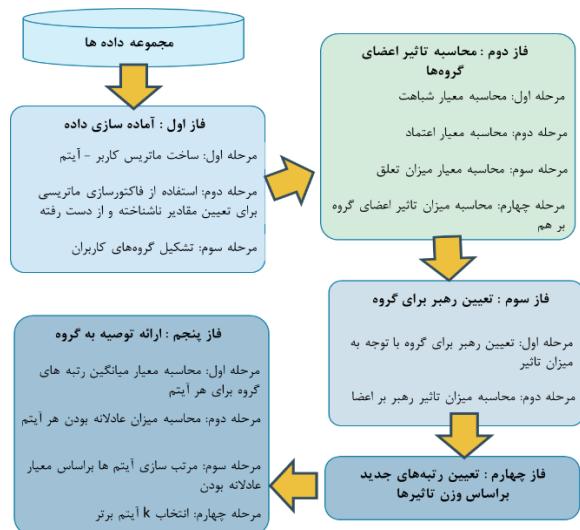
$$\text{user-item} \begin{bmatrix} r_{1,1} & r_{1,2} & r_{1,3} & \cdots & r_{1,n} \\ r_{2,1} & r_{2,2} & r_{2,3} & \cdots & r_{2,n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{m,1} & r_{m,2} & r_{m,3} & \cdots & r_{m,n} \end{bmatrix} \quad (1)$$

در ماتریس یادشده، $r_{i,j}$ رتبه کاربر i ام به آیتم j ام را نشان می‌دهد. در اغلب مجموعه‌ها، کاربران به همه آیتم‌ها رتبه‌ای اختصاص نمی‌دهند چراکه سیستم‌های توصیه‌گر کاربران را ملزم به رتبه‌دهی به همه آیتم‌ها نمی‌کند. بنابراین، برخی از مقادیر از دست‌رفته، تلقی می‌شوند. حال آنکه یک سیستم توصیه‌گر، فارغ از گروهی بودن آن، بر اساس رتبه‌های داده شده به آیتم‌ها، اقدام به ارائه توصیه می‌کند، که عدم وجود رتبه می‌تواند بر کارایی و دقت سیستم تأثیر بگذارد. فاکتورسازی ماتریسی^۱، یک نوع مدل عامل پنهان و یکی از محبوب‌ترین روش‌های توصیه است که توانایی بالایی در مواجهه با داده‌های ناشناخته و از دست‌رفته و رتبه‌های ضمنی دارد. فاکتورسازی ماتریسی یک ماتریس کاربر-آیتم با ورودی‌های ناشناخته را به دو ماتریس مختلف کاربر و آیتم تجزیه می‌کند. ماتریس کاربر فاکتورهای پنهان کاربران را و ماتریس آیتم عوامل پنهان آیتم‌ها را نشان می‌دهد. بنابراین، کاربران و آیتم‌ها بر روی یک فضای پنهان با رتبه پایین نگاشت می‌شوند. سپس، با تخمین ورودی‌های ماتریس کاربر و ماتریس آیتم، می‌توان از طریق فرآیند بهینه‌سازی به یک ماتریس کاربر-آیتم که نزدیک‌ترین ماتریس به ماتریس واقعی است، دست پیدا کرد و

از دست‌رفته، یافتن میزان اثرگذاری هر فرد بر سایر افراد در گروه، نحوه دخالت‌دادن نظرات کاربران بر هم همگی از موضوعاتی هستند که در این زمینه باید به آن‌ها توجه کرد.

۳- روش پیشنهادی

همان‌طور که گفته شد، سیستم‌های توصیه گروهی سعی دارند تا برای گروهی از افراد که دارای منافع مشترک هستند (به‌گونه‌ای که رضایت همه آن‌ها جلب نمایند) توصیه‌هایی را فراهم نمایند. یکی از مهم‌ترین مسائل در این سیستم‌ها روابط اجتماعی و تأثیر افراد بر یکدیگر در گروه‌ها است. به طور معمول، در گروه‌ها برخی از افراد به نام رهبر وجود دارند که بیش از سایر اعضا، مورد اعتماد و توجه هستند. از این‌رو، بر سایر افراد تأثیرگذار بوده و سایر افراد نظرات خود را بر اساس نظرات آن‌ها تغییر می‌دهند. علاوه بر رهبر، این امکان نیز وجود دارد تا افراد، با توجه به سایر اعضا گروه، نظر و ترجیحات خود را تغییر دهند. در این پژوهش، سعی شده است تا با استفاده از همین موضوعات، روش جدیدی برای محاسبه تأثیر اعضا بر یکدیگر بر اساس شباهت و اعتماد آن‌ها و همچنین میزان وابستگی و تعلق هر فرد به گروه ارائه شود. الگوریتم پیشنهادی یک سیستم توصیه‌گر عادلانه مبتنی بر تأثیر اعضا ارائه می‌دهد که شامل پنج فاز است. شکل (۴)، فلوچارت مربوط به سیستم پیشنهادی را نشان می‌دهد. در ادامه هر فاز را به تفضیل شرح می‌دهیم.



شکل ۴- روش کلی الگوریتم پیشنهادی FairILGRS

۳-۱- فاز اول: آماده سازی مجموعه داده

^۱ Matrix factorization

گروههای کارمندان در مجموعه‌داده کارمندان، یا گروههای خانوادگی یا دوستان. گروههای آنلاین که به آن‌ها گروههای ضمنی نیز گفته می‌شود، آشکار نیستند و باید توسط الگوریتم‌های مختلف آن‌ها را شناسایی کرد. بنابراین، در این نوع گروه‌بندی، گروه‌ها توسط خود سیستم و با تحلیل داده‌های موجود در آن ایجاد می‌شوند. برای به دست آوردن این گروه‌ها از میزان شباهت افراد، شباهت ترجیحات افراد و... استفاده می‌شود. در گروه‌بندی تصادفی، گروه خاصی از پیش تعريف نشده است و افراد بر اساس یک معیار مشترک، گروه‌بندی می‌شوند. مانند همه افرادی که در یک ورزشگاه هستند و یا همه افرادی که در تور مسافرتی خاصی هستند. با توجه به جدید بودن حیطه سیستم‌های توصیه‌گر، در اغلب موارد و تحقیقات، مجموعه‌داده‌ها فاقد گروه‌های آشکار هستند؛ لذا جهت استفاده از آن‌ها ابتدا باید گروه‌ها را شناسایی و مشخص کرد. بنابراین، قدم اول در الگوریتم پیشنهادی، شناسایی گروه‌های کاربران است. در این مقاله از الگوریتم خوشبندی K-means برای تشکیل گروه استفاده می‌شود.

در این مقاله، ابتدا به اندازه‌ای از پیش‌ تعیین شده، K گره به عنوان مرکز خوش انتخاب می‌شود. در اینجا، تعداد گروه‌ها متناسب با مجموعه داده مشخص خواهد شد. سپس با توجه به میزان شباهت سایر گره‌ها با مرکز خوش، هر گره به یک خوش تخصیص می‌یابد. به منظور اندازه‌گیری شباهت کاربران از رابطه (۵) استفاده می‌شود [۳۱]:

$$similarity_{u,v} = \frac{(\sum_{i \in I} (r_{u,i} - \bar{r}_u)(r_{v,i} - \bar{r}_v))}{\sqrt{\sum_{i \in I} (r_{u,i} - \bar{r}_u)^2} \sqrt{\sum_{i \in I} (r_{v,i} - \bar{r}_v)^2}} \quad (\delta)$$

در رابطه فوق، $r_{u,i}$ رتبه کاربر u به آیتم i ام است. \bar{r}_u نیز به میانگین رتبه هایی که کاربر u به همه آیتم ها داده است، اشاره دارد. به طور مشابه $r_{v,i}$ رتبه کاربر v به آیتم i ام و \bar{r}_v میانگین رتبه هایی است که کاربر v به همه آیتم ها داده است. عملیات انتخاب گره و تشکیل خوش، به تعداد تکرار معین انجام شده و درنهایت بهترین خوش، به عنوان خوش-های نهایی انتخاب می شوند.

۲-۳- فاز دوم: محاسبه‌ی تاثیر اعضای گروه

در این فاز برای محاسبه تأثیر اعضای گروه از سه معیار شباهت، اعتماد و تعلق به گروه استفاده می‌شود. در ادامه نحوه محاسبه آن‌ها را مورد بررسی قرار می‌دهیم.

روودی‌های مجهول در ماتریس اصلی کاربر-آیتم را پر کرد.
در این مقاله فاکتورسازی ماتریسی را مطابق با روش ارائه شده در [۴۰] نموده‌ایم. مطابق رابطه (۲) فاکتورسازی ماتریسی، تقریب یک ماتریس R با حاصل ضرب دو ماتریس کوچک‌تر W_1 و W_2 است.

$$R = W_1 W_2^T \quad (\Upsilon)$$

که در این رابطه، $W_1 \in \mathbb{R}^{|U| \times K}$ ماتریسی است که در آن هر سطر u بردار حاوی K عامل نهفته که کاربر u را توصیف می‌کند، دارد و $W_2 \in \mathbb{R}^{|I| \times K}$ ماتریسی است که در آن هر ردیف i بردار حاوی عوامل پنهان K را که آیتم λ_{ik} را توصیف می‌کند، شامل می‌شود. فرض کنید که W_{1uk} و W_{2ik} ، درآیه‌ها و W_{2i} و W_{1u} به ترتیب بردارهای W_1 و W_2 باشند، رتبه r داده شده توسط کاربر u به آیتم i با استفاده از رابطه‌ی (۳) پیش‌بینی می‌شود [۴۰]:

$$\hat{r}_{ui} = \sum_{k=1}^k W_{1_{uk}} W_{2_{ik}} = W_{1_u} W_{2_i}^T \quad (\textcircled{3})$$

W_1 و W_2 پارامترهای مدل (ماتریس‌های عامل پنهان) هستند که می‌توان آن‌ها را با بهینه‌سازی تابع هدف مطابق با رابطه (۴) یاد گرفت [۴۰]:

$$O^{MF} = \sum_{(u,i) \in R} (R_{ui} - W_{1_u} W_{2_i}^T)^2 + \lambda (\|W_1\|_F^2 + \|W_2\|_F^2) \quad (\dagger)$$

که در آن $\|W\|^2_F$ یک نرم فورینوس^۱ است و $1 < \lambda < 0$ یک عبارت منظم‌سازی است که مقداری بین صفر تا یک دارد و برای جلوگیری از بیش برآش استفاده می‌شود. بعد از به دست آوردن رتبه‌های ازدست‌رفته، اقدام به گروه‌بندی کاربران می‌شود. برای به دست آوردن گروه‌های کاربران، روش‌های مختلفی وجود دارد. یکی از مسائل اصلی سیستم توصیه‌گر گروهی، تشکیل و یا یافتن گروهی از افراد است که ترجیحات سازگار دارند که به عنوان تشکیل گروه شناخته می‌شود. تشکیل گروه، زیربنای اصلی این سیستم‌ها است. این سیستم‌ها می‌توانند حاوی گروه‌های آفلاین، آنلاین و تصادفی باشد.

در گروه‌های آفلاین که به آن‌ها گروه‌های صریح هم گفته می‌شود؛ لیست اعضا از پیش مشخص است. در این نوع گروه‌بندی، گروه‌ها از قبل تعییف می‌شوند. برای مثال،

1 Norm February

بعدن علایق دو کاربر، می‌توان تعداد آیتم‌ها مورد علاقه هر دو را مشخص کرد. برای این منظور، با فرض اینکه $r_{u,i}$ رتبه‌ای است که کاربر u ام به آیتم i داده است، $categorize(r_{u,i})$ مطابق با رابطه (۷) مشخص می‌کند که آیتم مورد علاقه کاربر بوده است یا خیر.

$$categorize(r_{u,i}) = \begin{cases} \text{if } r_{u,i} \geq (0.5 \times r_{max}) & \text{like} \\ \text{else} & \text{unlike} \end{cases} \quad (7)$$

بعد از محاسبه آیتم‌های مورد علاقه دو کاربر، با فرض اینکه $like_u$ و $like_v$ به ترتیب مجموعه آیتم‌هایی باشند که کاربر u و کاربر v به آن‌ها علاقه داشته‌اند، می‌توان میزان اشتراک آیتم‌ها را مطابق با رابطه (۸)، به دست آورد [۳۱]:

$$Partnership_{u,v} = \frac{like_u \cap like_v}{like_u} \quad (8)$$

علاوه بر آن، می‌توان از اختلاف رتبه دو کاربر نیز برای تعیین دقیق‌تر از رابطه (۹) استفاده نمود [۳۱]:

$$Distance_{u,v} = \frac{1}{1 + (\sqrt{\sum_{i \in I_{u,v}} (r_{u,i} - r_{v,i})^2})} \quad (9)$$

که $r_{u,i}$ و $r_{v,i}$ به ترتیب رتبه‌ای است که کاربر u و v به آیتم i داده‌اند. $I_{u,v}$ نیز آیتم‌هایی است که بین دو کاربر مشترک هستند و هر دو به آن‌ها رتبه داده‌اند. درنهایت با توجه به روابط (۸) و (۹) می‌توان معیار اعتماد را مطابق با رابطه (۱۰)، به دست آورد [۳۱]:

$$Trust_{u,v} = \frac{2 \times Partnership_{u,v} \times Distance_{u,v}}{Partnership_{u,v} + Distance_{u,v}} \quad (10)$$

در رابطه (۱۰)، میزان اعتماد به صورت یک عدد بین صفر و یک محاسبه می‌شود. هرچه این مقدار بیشتر باشد، یعنی میزان اعتماد کاربر u به v بیشتر است.

ج) معیار تعلق به گروه: در یک گروه، اغلب افراد از کسی تأثیر می‌گیرند که به سایر گروه‌ها گرایش کمتری داشته باشد. برای مثال، در گروه دوستان کسی که این گروه را شکل داده، علاوه بر اینکه دارای محبوبیت و اهمیت بیشتری است، به گروه نیز تعلق بیشتری دارد، چون او افراد و دوستان مختلف خود را دور هم جمع کرده است. در خانواده، پدر و مادر به عنوان تشکیل‌دهنده گروه خانواده، تعلق بیشتری به این گروه دارند. در سیستم توصیه‌گر، اغلب

الف) معیار شباهت: کاربرانی که شباهت بیشتری دارند، تأثیر بیشتری از هم می‌پذیرند. بهمنظور تعیین شباهت کاربران از رابطه (۵)، استفاده می‌شود، اما جهت نرم‌افزاری مقادیر از رابطه (۶) استفاده می‌شود. با این نرم‌افزاری، مقدار شباهت بین صفر و یک خواهد بود و هرچه این مقدار بیشتر باشد، شباهت بین دو کاربر بیشتر است.

$$\text{similarity}_{u,v} = \frac{\text{similarity}_{u,v} - \min(\text{similarity})}{\max(\text{similarity}) - \min(\text{similarity})} \quad (6)$$

در سیستم توصیه‌گر، شباهت بین کاربران می‌تواند بر اساس رتبه‌ای که کاربران به هر آیتم داده‌اند، محاسبه شود. بنابراین افرادی که به آیتم‌های موجود رتبه یکسانی داده‌اند، سریع‌تر می‌توانند در مورد یک آیتم مشترک، به توافق برسند.

ب) معیار اعتماد: اعتماد، میزان باور کاربران به یکدیگر، بر اساس الگوهایی مانند توانایی، تخصص و قابلیت اطمینان افراد است. اعتماد لزوماً یک رابطه دوطرفه بیان می‌شود که بیشتر موارد، به عنوان یک رابطه یک‌طرفه بیان می‌شود که طی آن یک شخص که به کاربران دیگر اعتماد دارد، «امین» و شخصی که هدف روابط اعتماد است، «اعتماد‌کننده» نام می‌گیرد. اعتماد بین کاربران به دو صورت صریح و ضمنی بیان می‌شود. اعتماد صریح بیانگر وجود یک رابطه اعتماد واضح بین کاربران است که به طور مستقیم توسط آن‌ها بیان می‌شود، در حالی که اعتماد ضمنی به صراحت توسط کاربران بیان نمی‌شود، بلکه بر اساس برخی شواهد، استاد و شباهت‌ها به دست می‌آید.

در این مقاله، رابطه اعتماد بین کاربران به صورت ضمنی در نظر گرفته می‌شود، زیرا هیچ اعتماد صریحی در مجموعه داده مورد استفاده وجود ندارد. به همین دلیل نیاز به داشتن روابطی برای تعیین میزان اعتماد است. همان‌طور که گفته شد، یکی از ویژگی‌های مهم معیار اعتماد نامتقارن بودن است، به این معنی که میزان اعتماد کاربر u به کاربر v با میزان اعتماد کاربر v به کاربر u متفاوت است. در حالت کلی، در یک سیستم توصیه‌گر که قرار است یک آیتم باتوجه به ترجیحات، وضعیت و علایق کاربر به او توصیه شود، یک کاربر مانند u زمانی می‌تواند به کاربر دیگر مانند v اعتماد کند که سلایق و ترجیحات او با کاربر v تا حد زیادی یکسان باشد. بدین ترتیب کاربر u ، به نظر و ایده کاربر v اعتماد می‌کند. بهمنظور محاسبه میزان مشترک

میزان تأثیر کاربر u بر کاربر v را با استفاده از رابطه (۱۴) اندازه‌گیری کرد:

$$\text{Weight_Inf}_{u,v} = \frac{2 \times \text{Trust}_{v,u} \times \text{similarity}_{v,u} \times \text{Dependency}_u}{(\text{Trust}_{v,u} + \text{similarity}_{v,u} + \text{Dependency}_u)} \quad (14)$$

۳-۳- فاز سوم: تعیین رهبر برای هر گروه

رهبر برجسته‌ترین فرد در گروه‌های اجتماعی است. در فعالیت‌های گروهی، رهبر کسی است که اعضای گروه به او بیشترین اعتماد را داشته و تعلق بیشتری به گروه داشته باشد. علاوه‌بر این، رهبر می‌تواند نظرات مشابهی را برای اعضای ارائه دهد. از این‌رو، الگوریتم پیشنهادی، با توجه به سه معیار شباهت، تعلق به گروه و اعتماد، رهبر را تعیین می‌کند. در حقیقت کسی که بالاترین شباهت، سطح اعتماد و میزان تعلق را به گروه داشته باشد، به عنوان رهبر در نظر گرفته می‌شود. رابطه (۱۵) برای شناسایی رهبر در یک گروه تعریف شده است. پس از آن به منظور تعیین میزان تأثیر و نفوذ رهبر بر اعضای گروه از رابطه (۱۶) استفاده می‌شود.

$$\text{leader}_{G_g} = \left\{ u: \underset{v \in G_g : v \neq u}{\operatorname{argmax}} \sum_{v \in G_g : v \neq u} \text{similarity}_{v,u} + \text{Trust}_{v,u} + \text{Dependency}_u \right\} \quad (15)$$

$$\text{LeaderWeight}_{inf_{u,v}} = \frac{\sum_{L, u \in G_g : L \neq u} \text{similarity}_{u,L} + \text{Trust}_{v,u} + \text{Dependency}_u}{2 \times (N_{G_g} - 1)} \quad (16)$$

۴-۳- فاز چهارم: تعیین رتبه‌های جدید بر اساس وزن تأثیرها

باتوجه به تأثیری که یک کاربر می‌تواند بر کاربران دیگر بگذارد، رتبه‌های کاربران به آیتم‌ها تغییر می‌نماید. در این فاز رتبه‌ها بر اساس وزن تأثیر کاربران به روزرسانی می‌شوند. به منظور به روزرسانی رتبه‌های کاربران به هر آیتم، مطابق رابطه (۱۷) عمل می‌شود.

$$\text{new}_{r_{u,i}} = r_{u,i} + \frac{\sum_{v=1}^{N_{G_g}} \text{WeightInf}_{u,v} \times (r_{v,i} - r_{u,i})}{|N_{G_g}|}, \\ \text{where } u, v \in G_g \quad (17)$$

در این رابطه $WeightInf_{u,v}$ نشان‌دهنده میزان تأثیر کاربر v بر u است که از رابطه (۱۴) محاسبه می‌شود و اگر

نمی‌توان افراد تشکیل‌دهنده گره را مشخص کرد. اما می‌توان گفت کسانی که بیشترین تعلق را به یک گروه دارند، نسبت به سایر گروه‌ها گرایش کمتری دارند. این مفهوم، در خوشبندی به عنوان شاخص نیمرخ^۱ مطرح است. شاخص نیمرخ، فاصله بین داده‌ها در خوشبندی متفاوت را بررسی می‌کند و این هدف را دنبال می‌کند که خوشبندی داده شده به یک نمونه داده، تا چه میزان درست و مطلوب بوده است. این معیار به پیوستگی درون خوشبندی و به میزان تفکیک‌پذیری آن‌ها بستگی دارد. مقدار نیمرخ برای هر نقطه، میزان تعلق آن را به خوشبندی در مقایسه با خوشبندی مجاور اندازه می‌گیرد. به منظور محاسبه این معیار مطابق با رابطه (۱۱) ابتدا میزان شباهت یک کاربر مانند u به گروه تعیین می‌شود:

$$\text{InSim}(u) = \frac{1}{|C| - 1} \sum_{v \in C} \text{similarity}_{u,v} \quad (11)$$

در رابطه فوق، $\text{similarity}_{u,v}$ میزان شباهت دو کاربر را نشان می‌دهد که مطابق با رابطه (۵) محاسبه می‌شود. $|C|$ تعداد اعضای گروه C است.

سپس میانگین شباهت کاربر با کاربران موجود در سایر گروه را بررسی می‌شود. از آنجاکه تعداد کاربران زیاد است، این امر منجر به افزایش تعداد محاسبات می‌شود؛ لذا در این بخش، از هر گروه، به طور تصادفی، تعدادی از کاربران مشخص و از این کاربران برای محاسبه میزان شباهت می‌شود. درنهایت نیز کمترین میزان میانگین شباهت، مشخص می‌شود. رابطه (۱۲) این شباهت را محاسبه می‌کند.

$$\text{OutSim}(u) = \min_{k=1, \dots, N} \frac{1}{|C_k|} \sum_{v \in C_k} \text{similarity}_{u,v} \quad (12)$$

در رابطه (۱۲) نیز، $\text{similarity}_{u,v}$ شباهت دو کاربر u و v است، C_k گروه k را نشان می‌دهد. $|C_k|$ تعداد اعضای گروه است. درنهایت، مقدار نهایی معیار وابستگی به صورت رابطه (۱۳) محاسبه می‌شود:

$$\text{Dependency}_u = 1 - \left| \frac{\text{OutSim}(u) - \text{InSim}(u)}{\max\{\text{InSim}(u), \text{OutSim}(u)\}} \right| \quad (13)$$

هر چه مقدار Dependency_u به یک نزدیک‌تر باشد، وابستگی بیشتر است. حال با ترکیب این مقادیر می‌توان

^۱ Silhouette Index

محاسبه می شود. با فرض اینکه g گروهی از مجموعه گروهها یعنی G باشد.

$$\text{average}_{item}(i) = \frac{\sum_{u \in g} \text{new}_{rate}_{u,i}}{N_g}, i \in I \quad (20)$$

در رابطه (۲۰)، $\text{average}_{item}(i)$ میانگین رتبه‌های است که به آیتم i داده شده است. $\text{new}_{rate}_{u,i}$ رتبه‌ای است که کاربر u به آیتم i داده است. N_g تعداد کاربران موجود در گروه g است.

(د) در گام چهارم، حاصل ضرب میانگین رتبه‌های کسب شده برای هر آیتم ($\text{average}_{item}(i)$) در مجموع رتبه (rank) به دست آمده برای هر آیتم محاسبه می‌گردد. درنهایت، آیتم‌ها بر اساس این رتبه مرتب شده و k آیتم بزرتر برای توصیه به گروه انتخاب می‌شوند.

۴- ارزیابی و نتایج

در این بخش عملکرد الگوریتم پیشنهادی در مقایسه با چندین روش پایه و اخیراً ارائه شده، مورد ارزیابی قرار گرفته است. بهمنظور پیاده‌سازی الگوریتم پیشنهادی از زبان برنامه‌نویسی پایتون، در محیط Anaconda استفاده شده است. بر اساس بررسی‌ها و تحقیقات انجام شده، در اغلب تحقیقات، بهمنظور پیاده‌سازی و ارزیابی الگوریتم سیستم توصیه‌گر گروهی، از مجموعه‌داده‌های معمول در سیستم توصیه‌گر سنتی استفاده شده است و مجموعه‌داده مشخص و معینی باهدف سیستم توصیه‌گر گروهی تعیین نشده است. براین‌اساس، ما از مجموعه‌داده MovieLens بهمنظور ارزیابی و پیاده‌سازی الگوریتم خود استفاده می‌کنیم. این مجموعه یکی از مجموعه‌داده‌های مشهور و محبوب در زمینه سیستم توصیه‌گر است که به شکل آنلاین قابل دسترسی است.^۱ مجموعه داده‌ای شامل رتبه‌بندی‌ها و برچسب‌های عددی است که بر اساس رتبه‌های داده شده به فیلم‌های مختلف توسط کاربران یک سرویس توصیه کننده آنلاین فیلم جمع‌آوری شده است. در این مقاله ما از مجموعه داده ml-latest-small که یکی از نسخه‌های کم حجم از این مجموعه‌داده است، استفاده می‌کنیم. این مجموعه‌داده که در سال ۲۰۱۸ ایجاد گردید، شامل ۱۰۰۸۳۶ رتبه و ۳۶۸۳ برچسب در مورد ۹۷۴۲ فیلم است که توسط ۶۱۰ کاربر ایجاد شده است. همه کاربران منتخب حداقل به ۲۰ فیلم امتیاز داده بودند. مجموعه‌داده، فاقد اطلاعات

$LeaderWeight_{Inf_{u,v}}$ باشد از مقدار در رابطه (۱۶) استفاده می‌شود.

۵-۳- فاز پنجم: ارائه توصیه به گروه

در این مرحله، توصیه به گروه ارائه می‌شود. برای ارائه توصیه نیاز به استفاده از یک معیار جهت تجمعی آرا و رتبه‌های کاربران گروه است. به همین منظور در این مقاله ترکیبی از استراتژی‌های تجمعی موجود مورد استفاده قرار گرفته به‌گونه‌ای که عدالت در توصیه‌ها، بیشینه شود. همچنین آیتمی که اکثر افراد از آن راضی باشند، به عنوان آیتم عادلانه در نظر گرفته می‌شود. با داشتن این تعریف، مراحل تجمعی رتبه‌ها در چهار مرحله انجام می‌شود که در ادامه شرح داده می‌شود.

(الف) ابتدا میانگین رتبه‌هایی که هر کاربر به همه آیتم‌ها داده است، محاسبه می‌شود. تفاوت این معیار با معیار میانگین سنتی که پیش‌تر بحث شد، در این است که معیار میانگین سنتی، میانگین رتبه‌هایی را که همه کاربران به یک آیتم داده‌اند مشخص می‌کند. در حالی که در این مقاله، میانگین رتبه‌هایی که یک کاربر به همه آیتم‌ها داده است را محاسبه می‌نماییم. در حقیقت این معیار، پراکندگی و توزیع رتبه دهی کاربر را مشخص می‌نماید و بنابراین می‌توان تعیین کرد که هر کاربر در زمان رتبه دهی چه میزان سخت‌گیر و حساس است. رابطه (۱۸) نحوه محاسبه این معیار را نشان می‌دهد.

$$\text{average}_{user}(u) = \frac{\sum_{i \in I} \text{new}_{rate}_{u,i}}{|I|} \quad (18)$$

که در این رابطه u یک کاربر و i یک آیتم از مجموعه آیتم‌ها یعنی I بوده و $\text{new}_{rate}_{u,i}$ رتبه‌ای است که کاربر u به آیتم i داده و $|I|$ تعداد آیتم‌های موجود برای توصیه می‌باشد.

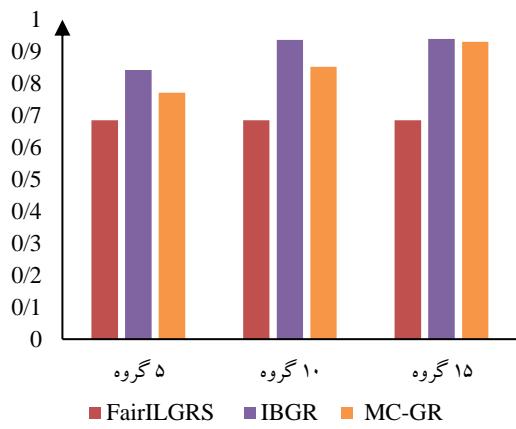
(ب) در گام دوم، برای هر کاربر آیتم‌هایی که رتبه آن بیشتر از میانگین باشد، مشخص می‌شود. سپس آیتم‌هایی بر اساس میانگین رتبه کاربر جدا می‌شوند. آیتم‌هایی که بالاتر از میانگین رتبه کاربر باشند، به عنوان آیتم قابل قبول و در غیر این صورت به عنوان آیتم‌های غیرقابل قبول لحظه می‌شوند.

$$\text{rank}(u, i) = |\text{new}_{rate}_{u,i} > \text{average}_{user}(u)| \quad (19)$$

(ج) در گام سوم، با استفاده از استراتژی میانگین سنتی، میانگین رتبه‌های کسب شده برای هر آیتم در گروه

¹ <http://www.grouplens.org>

روش پیشنهادی و الگوریتم‌های ارائه شده در [31] IBGR و MC-GR [34] بر روی مجموعه داده نشان می‌دهد. دلیل استفاده از این دو الگوریتم در کنار الگوریتم پیشنهادی این است که از بین تمامی مقالات معرفی شده، تنها این دو مورد، به تخمین تاثیر کاربران برهم می‌پرداختند. هدف از استفاده از این معیار این است که میزان مناسب بودن رتبه‌های تخمین زده شده اندازه‌گیری شود.



شکل ۵- مقایسه معیار میانگین خطای مطلق

بر اساس شکل (۵)، هر سه الگوریتم عملکردی قابل قبول داشتند، اما الگوریتم پیشنهادی توانسته خطای کمتری را گزارش نماید. دلیل این امر می‌تواند ناشی از نحوه محاسبه تأثیر کاربران بر هم در روش پیشنهادی باشد.

ب) ریشه میانگین مربعات خطای مطلق

ریشه میانگین مربعات خطای کمتری از معیارهای رایج برای ارزیابی سیستم‌های توصیه‌گر است که از رابطه (۲۲) محاسبه می‌شود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n |Pr_i - Acr_i|^2}{N}} \quad (22)$$

که مقدار پیش‌بینی شده توسط الگوریتم و Acr_i مقدار واقعی برای آیتم i ام و N نیز تعداد کل آیتم‌ها است. هرچقدر مقدار این معیار به صفر نزدیک‌تر باشد، به معنای این است که میزان خطای کمتر بوده و نتایج مطلوب‌تر است. شکل (۶) نتایج به دست آمده از محاسبه معیار ریشه میانگین مربعات خطای را برای سه روش FairILGRS و MC-GR و IBGR بر روی مجموعه داده نشان می‌دهد.

دموگرافیک (مانند سن، تحصیلات و...) است و تنها هر کاربر دارای یک شناسه بوده و هیچ اطلاعات دیگری از کاربر ارائه نمی‌شود.

به منظور ارزیابی عملکرد روش پیشنهادی، روش ارائه شده را با چندین پژوهش اخیر ارائه شده و سه روش پایه بر اساس معیارهای ارزیابی گوناگون مقایسه نموده‌ایم. ارزیابی از دو مرحله تشکیل شده است. در مرحله اول، رتبه‌بندی‌های جدید اعضا که بر اساس تأثیرات پیش‌بینی شده‌اند، ارزیابی می‌شوند. به منظور ارزیابی دقیق‌تر، گروههایی با اندازه ۵، ۱۰ و ۱۵ در نظر گرفته شده است. در مرحله دوم، رضایت گروه‌ها، از k آیتم و توصیه‌های داده شده به گروه مورد ارزیابی قرار گرفته است. در این مرحله نیز، به منظور ارزیابی دقیق‌تر، گروههایی با اندازه ۵، ۱۰ و ۱۵ در نظر گرفته شده است. همچنین جهت بررسی مقیاس‌پذیر بودن الگوریتم، تعداد توصیه‌ها، ۱، ۵، ۱۰، ۱۵ و ۲۰ تعیین شده‌اند.

۴-۱- ارزیابی رتبه‌های تعیین شده

برای ارزیابی رتبه‌های تعیین شده، از معیارهای میانگین خطای مطلق، ریشه میانگین مربعات خطای و دقت استفاده شده است. در ادامه هر یک از معیارهای فوق معرفی و نتایج حاصل از آن‌ها، ذکر می‌گردد.

الف) میانگین خطای مطلق

سنترین معیار در ارزیابی سیستم توصیه‌گر، معیار میانگین خطای مطلق است که جهت ارزیابی توانایی یک سیستم برای پیش‌بینی علاقه کاربر به یک آیتم خاص استفاده می‌شود. این معیار تفاوت بین مقدار واقعی و مقدار پیش‌بینی شده را با استفاده از رابطه (۲۱) اندازه‌گیری می‌کند.

$$MAE = \frac{\sum_{i=1}^n |Pr_i - Acr_i|}{N} \quad (21)$$

که مقدار Pr_i پیش‌بینی شده توسط الگوریتم و Acr_i مقدار واقعی برای آیتم i ام است. N نیز تعداد کل آیتم‌ها است. هر چه مقدار میانگین خطای مطلق به صفر نزدیک‌تر باشد، به معنای این است که میزان خطای کمتر بوده و نتایج مطلوب‌تر است. شکل (۵) نتایج حاصل از این معیار را برای

در شکل (۷)، میزان دقت الگوریتم‌ها در محاسبه رتبه‌ها گزارش شده است. براساس این نمودار، الگوریتم پیشنهادی عملکردی بهتری در قیاس با سایر روش‌ها داشته است. در این بخش همان‌طور که بیان شد الگوریتم پیشنهادی عملکردی بهتری بر اساس سه معیار ارزیابی نسبت به سایرین داشته است. دلیل این امر می‌تواند ناشی از نحوه محاسبه اثرگذاری کاربران برهمن باشد. به عبارت بهتر الگوریتم پیشنهادی سعی کرده است تا حد زیادی رتبه‌های کاربران را حفظ کند و تأثیر کاربران و رهبر را به طور معقولانه‌تری بر رتبه کاربر اعمال کند.

۴-۲-۴- ارزیابی توصیه‌ها

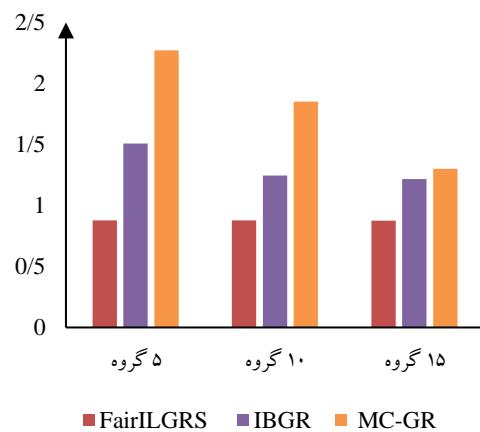
در این بخش به بررسی توصیه‌های داده شده به کاربران پرداخته و مشخص می‌شود که استراتژی تجمعی پیشنهاد شده تا چه میزان مناسب و مطلوب بوده است. به همین منظور برای ارزیابی عملکرد روش پیشنهادی، آن را با روش‌های IBGR [۳۱]، MC-GR [۳۴]، GCF [۳۵]، ATL [۲۸]، Aggregating-top-list (ATL) Fairness [۲۸] و همچنین AwU Package [۳۰] و [۳۲] روشن‌های تجمعی (MUL)، ضرب رتبه‌های تخصیص داده شده به آیتم‌ها (PLU) رای‌گیری (PLU) و پایین‌ترین رتبه (LMS) که در فصل یک عنوان شدند، مقایسه نموده‌ایم. برای این منظور از معیارهای سود تجمعی تنزیل شده نرمال شده، رضایت گروهی و عدالت استفاده شده است.

الف) سود تجمعی تنزیل شده نرمال شده (nDCG) سود تجمعی تنزیل شده نرمال شده (nDCG)، یک معیار استاندارد برای ارزیابی خوب بودن یک لیست رتبه‌بندی شده از توصیه‌ها است. برای محاسبه این معیار، فرض کنید که p_1, p_2, \dots, p_k لیست رتبه‌بندی شده از آیتم‌ها برای توصیه به گروه داشته باشیم؛ u یک کاربر و r_{upi} امتیاز او به آیتم i است. برای اساس، معیار DCG و nDCG از رابطه (۲۴) محاسبه می‌شود [۱]:

$$DCG_k^u = r_{up1} + \sum_{i=2}^k \frac{r_{upi}}{\log_2(i)} \quad (24)$$

$$nDCG_k^u = \frac{DCG_k^u}{IDCG_k^u}$$

مقدار $IDCG_k^u$ حداکثر مقدار DCG_k^u است که برای کاربر u به دست آمده است. معیار ذکر شده، میزان مناسب بودن



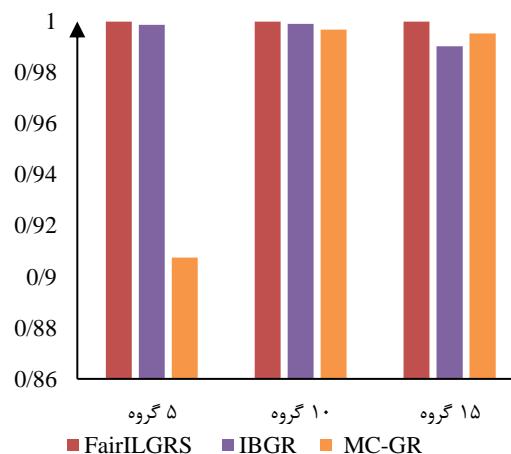
شکل ۶- مقایسه معیار ریشه میانگین مربعات خطأ

مطلوب با نتایج به دست آمده در شکل (۶)، براساس این معیار نیز روش پیشنهادی خطای کمتری را گزارش نموده است. (ج) دقت

در این مقاله دقت به عنوان یک مکمل نرمال شده میانگین خطای مطلق معکس شده و طبق رابطه (۲۳) محاسبه می‌شود.

$$Precision = 1 - \frac{\sum_{i=1}^I \frac{|Pr_i - Acr_i|}{\max(|R_{max} - Acr_i|, |R_{min} - Acr_i|)}}{I} \quad (23)$$

که مقدار Pr_i پیش‌بینی شده توسط الگوریتم، Acr_i مقدار واقعی برای آیتم i ام، R_{max} حداکثر مقدار رتبه، R_{min} حداقل مقدار رتبه و I نیز تعداد کل آیتم‌های است. بیشتر بودن این معیار نشان‌دهنده مطلوب‌تر بودن نتایج است. شکل (۷) نتایج به دست آمده از معیار دقت برای روش‌های پیشنهادی، IBRG و MC-GR روی مجموعه داده‌ای را نشان می‌دهد.



شکل ۷- مقایسه معیار دقت

جدول ۵- نتایج به دست آمده از معیار nDOG با ۱۰ توصیه

۱۵	۱۰	۵	تعداد گروه نام الگوریتم
0.3595	0.3574	0.6214	IBGR
0.4474	0.5221	0.5989	PLU
0.4279	0.4252	0.3227	MUL
0.3248	0.4234	0.4169	LMS
0.6899	0.6320	0.6150	MC-GR
0.6975	0.6507	0.6384	GCF
0.6850	0.6328	0.6983	ATL
0.7243	0.6347	0.7171	Fairness Package
0.7347	0.7347	0.7204	AwU
0.7211	0.7211	0.7211	FairILGRS

جدول ۶- نتایج به دست آمده از معیار nDOG با ۱۵ توصیه

۱۵	۱۰	۵	تعداد گروه نام الگوریتم
0.3478	0.3522	0.3118	IBGR
0.5438	0.5168	0.4022	PLU
0.4279	0.4252	0.3227	MUL
0.3248	0.3234	0.3169	LMS
0.4111	0.6044	0.6384	MC-GR
0.6269	0.6174	0.6451	GCF
0.6977	0.6226	0.6308	ATL
0.6301	0.6344	0.6128	Fairness Package
0.6823	0.6777	0.6471	AwU
0.7201	0.7201	0.7201	FairILGRS

توصیه ها را نشان می دهد. این معیار، برای هر کاربر به طور مجزا، بررسی می کند که بسته انتخاب شده، توانسته است رضایت آن کاربر را کسب کند یا خیر. در نهایت از میانگین میزان رضایتمندی کاربران، مقدار این معیار محاسبه می گردد. جدول ۳ تا ۷ نتایج به دست آمده از این معیار را، برای الگوریتم پیشنهادی و سایر روش ها مورد مقایسه، با تعداد گروه های ۵، ۱۰ و ۱۵ و همچنین تعداد توصیه های ۱، ۵، ۱۰ و ۲۰ نشان می دهد.

جدول ۳- نتایج به دست آمده از معیار nDOG با یک توصیه

۱۵	۱۰	۵	تعداد گروه نام الگوریتم
0.4578	0.4328	0.4387	IBGR
0.4293	0.4360	0.4493	PLU
0.3279	0.3252	0.5227	MUL
0.4248	0.3234	0.4169	LMS
0.5607	0.5949	0.5963	MC-GR
0.5711	0.5811	0.5787	GCF
0.5855	0.5998	0.5973	ATL
0.6724	0.6919	0.6908	Fairness Package
0.6854	0.6807	0.6512	AwU
0.7230	0.7230	0.7230	FairILGRS

جدول ۴- نتایج به دست آمده از معیار nDOG با ۵ توصیه

۱۵	۱۰	۵	تعداد گروه نام الگوریتم
0.3721	0.3585	0.3450	IBGR
0.6769	0.6085	0.3149	PLU
0.5227	0.5252	0.3279	MUL
0.5169	0.5234	0.4248	LMS
0.5722	0.5214	0.5558	MC-GR
0.5373	0.5336	0.6695	GCF
0.5421	0.5364	0.6834	ATL
0.6505	0.6408	0.6696	Fairness Package
0.6819	0.6784	0.6504	AwU
0.7218	0.7217	0.7217	FairILGRS

جدول ۸- نتایج به دست آمده از معیار GSM با یک توصیه

15	10	5	تعداد گروه نام الگوریتم
0.5667	0.5210	0.5101	IBGR
0.0417	0.0455	0.0230	PLU
0.5299	0.6350	0.6384	MUL
0.4629	0.4313	0.4884	LMS
0.6794	0.5926	0.6078	MC-GR
0.7181	0.5547	0.5009	GCF
0.5331	0.5904	0.6100	ATL
0.6514	0.5340	0.5135	Fairness Package
0.6662	0.6247	0.6101	AwU
0.7011	0.6360	0.6438	FairILGRS

جدول ۹- نتایج به دست آمده از معیار GSM با ۵ توصیه

15	10	5	تعداد گروه نام الگوریتم
0.4385	0.5117	0.5214	IBGR
0.0500	0.0606	0.1171	PLU
0.4730	0.4351	0.4380	MUL
0.5629	0.5360	0.5088	LMS
0.7011	0.6965	0.5962	MC-GR
0.5818	0.5000	0.5254	GCF
0.5134	0.5792	0.5970	ATL
0.6888	0.5077	0.5446	Fairness Package
0.6900	0.6835	0.6066	AwU
0.6652	0.6101	0.6112	FairILGRS

جدول ۱۰- نتایج به دست آمده از معیار GSM با ۱۰ توصیه

15	10	5	تعداد گروه نام الگوریتم
0.4272	0.4681	0.4986	IBGR
0.0346	0.0411	0.0655	PLU
0.5730	0.5426	0.6438	MUL
0.5629	0.5872	0.5088	LMS
0.5712	0.5072	0.5215	MC-GR
0.5953	0.5903	0.5614	GCF
0.5436	0.5905	0.5621	ATL
0.5941	0.5909	0.5279	Fairness Package
0.5874	0.5971	0.6131	AwU
0.6009	0.6007	0.5984	FairILGRS

جدول ۷- نتایج به دست آمده از معیار nDOG با ۲۰ توصیه

15	10	5	تعداد گروه نام الگوریتم
0.3436	0.4328	0.3048	IBGR
0.4209	0.4093	0.4033	PLU
0.3279	0.5179	0.3274	MUL
0.4782	0.4335	0.4938	LMS
0.7226	0.7284	0.7033	MC-GR
0.7049	0.6523	0.6017	GCF
0.7009	0.6630	0.6813	ATL
0.7102	0.6493	0.6198	Fairness Package
0.6631	0.7206	0.6967	AwU
0.7192	0.7198	0.7198	FairILGRS

بر اساس نتایج نشان داده شده در جداول ۳ تا ۷، الگوریتم پیشنهادی، در همه موارد به جز حالت تعداد توصیه ۱۰ و تعداد گروه ۱۵ از سایر روش‌ها بهتر عمل نموده است.

ب) رضایت گروهی

این معیار برای ارزیابی توصیه‌های ارائه شده به گروه‌ها، استفاده می‌شود و طی آن سعی می‌شود تا میزان رضایت گروه‌ها را بر اساس هر عضو بسنجد. رضایت گروهی را می‌توان با رابطه (۲۵) تخمین زد.

$$GSM_{G_g} = \frac{\sum_{u \in G_g} I_u^s \cap I_R}{N_{G_g} * N_{I_R}} \quad (25)$$

در معادله فوق، I_u^s نشان‌دهنده آیتم‌هایی است که کاربر u به آن‌ها رتبه‌ای بالاتر از $0.5 \times R_{\max}$ دارد. I_R مجموعه آیتم‌های توصیه شده به کاربر، N_{G_g} تعداد اعضای گروه و N_{I_R} تعداد آیتم‌های توصیه شده به گروه است. هرچه مقدار این معیار بیشتر باشد، نشان‌دهنده مطلوب بودن عملکرد الگوریتم است. جداول ۸ تا ۱۲ نشان‌دهنده عملکرد روش پیشنهادی در مقایسه با سایر روش‌ها بر اساس معیار رضایت گروهی می‌باشد. معیار رضایت گروهی نیز، میزان مناسب بودن توصیه‌ها را نشان می‌دهد. با این تفاوت که این معیار، کل گروه را در نظر می‌گیرد و در حقیقت رضایت یک گروه را نسبت به توصیه‌ها محاسبه می‌کند. براساس نتایج به دست آمده در جداول ۸ تا ۱۲، الگوریتم پیشنهادی، در اغلب موارد توانسته است، میزان مطلوبی را کسب کند.

$$m = \left\lceil \frac{\text{recommend_package}}{5} \right\rceil \quad (27)$$

که در رابطه بالا *recommend_package* به معنای تعداد توصیه‌های داده شده به کاربر است. جداول (۱۳) تا (۱۷) نتایج حاصل از این معیار را نشان می‌دهد.

جدول ۱۳- نتایج به دست آمده از معیار عادلانه بودن با یک توصیه

تعداد گروه نام الگوریتم	۱۵	۱۰	۵
IBGR	0.5667	0.5210	0.5101
PLU	0.3279	0.3234	0.2299
MUL	0.4248	0.3252	0.2585
LMS	0.3721	0.3474	0.2227
MC-GR	0.4861	0.4596	0.4464
GCF	0.4659	0.4443	0.4305
ATL	0.5720	0.5440	0.3324
Fairness Package	0.5467	0.5210	0.4045
AwU	0.5990	0.6247	0.6279
FairILGRS	0.7011	0.6360	0.6438

جدول ۱۴- نتایج به دست آمده از معیار عادلانه بودن با ۵ توصیه

تعداد گروه نام الگوریتم	۱۵	۱۰	۵
IBGR	0.5227	0.5981	0.5686
PLU	0.2607	0.2573	0.3695
MUL	0.4174	0.3695	0.3438
LMS	0.3279	0.3384	0.4088
MC-GR	0.4980	0.5318	0.5477
GCF	0.4918	0.5153	0.5425
ATL	0.5814	0.5798	0.5857
Fairness Package	0.5585	0.5657	0.5712
AwU	0.6639	0.6870	0.6945
FairILGRS	0.7244	0.6549	0.6685

جدول ۱۱- نتایج به دست آمده از معیار GSM با ۱۵ توصیه

تعداد گروه نام الگوریتم	۱۵	۱۰	۵
IBGR	0.4134	0.5462	0.5743
PLU	0.0281	0.0286	0.0444
MUL	0.4730	0.4809	0.5438
LMS	0.4629	0.5539	0.5088
MC-GR	0.3213	0.5545	0.5657
GCF	0.5680	0.5174	0.5263
ATL	0.5629	0.5539	0.5088
Fairness Package	0.5191	0.5631	0.5728
AwU	0.5646	0.5911	0.6070
FairILGRS	0.5872	0.5920	0.5877

جدول ۱۲- نتایج به دست آمده از معیار GSM با ۲۰ توصیه

تعداد گروه نام الگوریتم	۱۵	۱۰	۵
IBGR	0.5022	0.5210	0.5539
PLU	0.0278	0.0303	0.0473
MUL	0.4385	0.5743	0.5438
LMS	0.5214	0.4681	0.5088
MC-GR	0.5292	0.5576	0.5667
GCF	0.5799	0.5212	0.5263
ATL	0.5214	0.5681	0.5888
Fairness Package	0.5435	0.5490	0.5673
AwU	0.5812	0.5741	0.5767
FairILGRS	0.5775	0.5862	0.5809

پ) عادلانه بودن توصیه:

این معیار به بررسی میزان عادلانه بودن توصیه می‌پردازد و بر اساس رابطه (۲۶) محاسبه می‌گردد.

$$fairness_{package}(g) = \frac{|g_N|}{|g|} \quad (26)$$

در رابطه (۲۶)، $|g_N|$ تعداد اعضايی از گروه را نشان می‌دهد که حداقل به m آیتم از مجموعه آیتم‌های توصیه شده، علاقه داشتند. $|g|$ نشان دهنده تعداد همه اعضايی گروه است. در اينجا، بسته به اندازه توصیه‌ها، مقدار m را به صورت زير در نظر مي‌گيريم:

معیار ذکر شده، عادلانه بودن توصیه‌ها را در نظر می‌گیرد. درواقع برای هر کاربر برسی می‌کند که در هر بسته توصیه شده چند آیتم مورد علاقه آن کاربر بوده است. در صورتی که تعداد این آیتم‌ها از حد آستانه بیشتر باشد، یعنی رضایت آن کاربر برآورده شده است. در غیر این صورت، کاربر ناراضی خواهد بود. هرچه تعداد کاربران ناراضی بیشتر باشد، یعنی عدالت در ارائه توصیه رعایت نشده است. براساس نتایج نمایش داده شده در جداول ۱۳ تا ۱۷، الگوریتم پیشنهادی، در اغلب موارد توانسته است، عملکرد مطلوبی را گزارش نماید.

با توجه به نتایج کسب شده برای سه معیار عنوان شده، می‌توان گفت که استراتژی پیشنهاد شده در این مقاله، در اغلب موارد، عملکردی مناسب‌تر و بهتر داشته است. در سایر استراتژی‌های تجمیع، به رتبه‌نایابی داده شده به آیتم توسط یک کاربر توجه می‌شود. اما در استراتژی پیشنهادی، رتبه‌های هر کاربر به طور مستقل مشخص شده و در نهایت آیتم‌های مورد علاقه کاربر براساس میانگین رتبه‌های خود او مشخص می‌شود. این امر می‌تواند سبب شود تا کاربرانی که سخت‌گیر هستند و رتبه‌های پایینی به آیتم‌ها می‌دهند، و یا بر عکس، کاربرانی که آسان‌گیر بوده و به همه آیتم‌ها رتبه‌های بالا می‌دهند، روی آیتم‌های (های) نهایی انتخاب شده برای گروه تاثیر کمتری داشته باشند. به عبارت بهتر، سعی می‌شود که برای گروه آیتم‌هایی انتخاب شود که برای هر فرد به طور مستقل از سایر افراد مناسب بوده است. در حالی که سایر استراتژی‌های تجمیع، اثرات ناشی از افراد سخت‌گیر و آسان‌گیر را در نظر نمی‌گرفتند و همین امر سبب می‌شود تا برخی آیتم‌ها در حالی که مطلوب هستند، به عنوان نامطلوب در نظر گرفته شوند و بر عکس.

۵- نتیجه‌گیری و کارهای آینده

در روش پیشنهادی یک سیستم توصیه‌گر ارائه گردید که قادر است با توجه به تأثیر کاربران بر هم، اقدام به ارائه توصیه نماید. هدف اول روش پیشنهادی، ارائه معیاری جدید برای تعیین رهبر در گروه بوده که این معیار سعی می‌کند تا با توجه به میزان اعتماد، شباهت و تعلق و وابستگی کاربران به گروه، رهبر آن گروه را مشخص نماید. به همین منظور این معیار به این گونه تعریف شده است که اگر فردی شباهت او با افراد درون گروه نسبت به افراد موجود در سایر گروه‌ها بیشتر باشد، تعلق او به گروه مذکور بیشتر در نظر گرفته می‌شود. علاوه بر این هدف دیگر روش

جدول ۱۵- نتایج به دست آمده از معیار عادلانه بودن با ۱۰

توصیه

۱۵	۱۰	۵	تعداد گروه نام الگوریتم
0.5560	0.4562	0.4931	IBGR
0.3667	0.1545	0.2690	PLU
0.3384	0.4320	0.3438	MUL
0.3629	0.5373	0.3524	LMS
0.4897	0.4434	0.4537	MC-GR
0.4731	0.4402	0.4438	GCF
0.5747	0.5389	0.5375	ATL
0.5501	0.5146	0.5110	Fairness Package
0.5253	0.5606	0.5361	AwU
0.6265	0.6170	0.6172	FairILGRS

جدول ۱۶- نتایج به دست آمده از معیار عادلانه بودن با ۱۵

توصیه

۱۵	۱۰	۵	تعداد گروه نام الگوریتم
0.5078	0.6861	0.4193	IBGR
0.3168	0.3227	0.2299	PLU
0.4193	0.4438	0.5438	MUL
0.4269	0.4562	0.5088	LMS
0.5776	0.5918	0.5237	MC-GR
0.6700	0.5432	0.5248	GCF
0.6709	0.5518	0.5253	ATL
0.6454	0.6307	0.5957	Fairness Package
0.6398	0.6207	0.5976	AwU
0.6124	0.6070	0.6046	FairILGRS

جدول ۱۷- نتایج به دست آمده از معیار عادلانه بودن با ۲۰

توصیه

۱۵	۱۰	۵	تعداد گروه نام الگوریتم
0.4913	0.5210	0.3308	IBGR
0.3274	0.3823	0.2690	PLU
0.3730	0.4360	0.3438	MUL
0.4629	0.4017	0.4088	LMS
0.5422	0.6624	0.6881	MC-GR
0.6050	0.5227	0.5774	GCF
0.5708	0.5807	0.6295	ATL
0.6702	0.6669	0.5260	Fairness Package
0.6713	0.6690	0.6744	AwU
0.6099	0.6052	0.6008	FairILGRS

اعمال کند.

در معیار سود تجمعی تنزیل شده نرمال شده، رضایت گروهی و عدالت نیز الگوریتم پیشنهادی توانست در اغلب موارد نتایج بهتری را کسب نماید. دلیل این امر این است که در استراتژی پیشنهادی، رتبه های هر کاربر به طور مستقل مشخص شده و در نهایت آیتم های مورد علاقه کاربر براساس میانگین رتبه های خود او مشخص می شود. این امر می تواند سبب شود تا کاربرانی که سخت گیر هستند و رتبه های پایینی به آیتم ها می دهند، و یا برعکس، کاربرانی که آسان گیر بوده و به همه آیتم ها رتبه های بالا می دهند، روی آیتم (های) نهایی انتخاب شده برای گروه تاثیر کمتری داشته باشند. به عبارت بهتر، سعی می شود که برای گروه آیتم هایی انتخاب شود که برای هر فرد به طور مستقل از سایر افراد مناسب بوده است. در حالی که سایر استراتژی های تجمعی، اثرات ناشی از افراد سخت گیر و آسان گیر را در نظر نمی گرفتند و همین امر سبب می شود تا برخی آیتم ها در حالی که مطلوب هستند، به عنوان نامطلوب در نظر گرفته شوند و برعکس.

هر چند نتایج حاصل از این پژوهش مطلوب است اما هنوز چالش ها و مواردی وجود دارد که رسیدگی به آن می تواند سبب کاربردی تر شدن الگوریتم پیشنهادی گردد. الگوریتم پیشنهادی بر روی مجموعه داده های معمولی و سنتی کار می کند و گروه را بر اساس روش های ضمنی پیدا می کند. برای رسیدن به عملکرد بهتر می توان الگوریتم پیشنهادی را بر روی مجموعه داده های صریح که در آن گروه ها از پیش تعیین شده هستند نیز اجرا کرده و نتایج آن را بررسی نمود. همچنین در مرحله آماده سازی، تنها از فاکتور سازی ماتریس، استفاده شده است. با استفاده از اطلاعات اضافی می توان، عملکرد تخمین رتبه های از دست رفته را بهبود داد و پیش بینی ها و تخمین های دقیق تری را مشخص نمود. علاوه بر این استفاده از باز خورد های کاربران نسبت به یک توصیه، می تواند عملکرد این سیستم ها را ارتقا بخشد. لذا تخمین و پیش بینی باز خورد کاربران نسبت به آیتم های توصیه شده موضوعی دیگر است که در این زمینه مطرح است.

پیشنهادی این است که تأثیر افراد موجود در گروه، به طور مناسب اندازه گیری و تعیین شود. برای رسیدن به این اهداف، الگوریتمی ارائه دادیم که دارای پنج فاز اصلی است. فاز اول آماده سازی مجموعه داده می باشد که در آن به منظور تخمین رتبه های از دست رفته یا بدون مقدار از روش فاکتور سازی ماتریسی استفاده شده است. بعد از به دست آوردن رتبه های از دست رفته، اقدام به گروه بندی کاربران با استفاده از K-means می شود. در فاز دوم تأثیر هر عضو بر سایر اعضای گروه محاسبه می شود. برای این کار از ترکیب معیار شباهت، معیار اعتماد و معیار تعلق استفاده می شود. در فاز سوم در این فاز برای هر گروه، یک رهبر در نظر گرفته می شود. فردی که در گروه بیشترین مقدار را در معیار های شباهت، اعتماد و تعلق کسب کند، به عنوان رهبر در نظر گرفته می شود. فرد رهبر، دارای تاثیر گذاری بیشتری نسبت به سایرین است. البته، خود نیز از سایر افراد در گروه می تواند تأثیر بگیرد. در فاز چهارم رتبه هر یک از کاربران با توجه به میزان تأثیر پذیری از دیگر افراد موجود در گروه، محاسبه می شود و در نهایت در فاز آخر توصیه ای که عادلانه و منصفانه باشد، به کاربران داده می شود.

در ادامه الگوریتم پیشنهادی از دو جنبه، مورد ارزیابی قرار گرفت. جنبه اول به ارزیابی تخمین رتبه ها با توجه به تاثیر گذاری رتبه ها پرداخته که طی آن از معیار های میانگین خطای مطلق، ریشه میانگین مربعات خطای مطلق و دقت استفاده شده است. بر اساس نتایج به دست آمده، الگوریتم پیشنهادی توانسته است عملکرد بهتر و مطلوب تری را کسب کند. براساس معیار میانگین خطای مطلق و معیار ۱۵ ریشه میانگین مربعات خطای مطلق، با در نظر گرفتن ۵، ۱۰ و ۱۵ گروه، الگوریتم پیشنهادی توانسته است عملکرد مناسبی نسبت به سایرین کسب نماید. در خصوص معیار دقت، نتایج حاصل از هر الگوریتم، بسیار نزدیک به هم بوده و در نتیجه این معیار را برای هر سه می توان برابر در نظر گرفت. دلیل کسب این نتایج را می توان ناشی از نحوه محاسبه تاثیر کاربران برهم دانست. الگوریتم پیشنهادی سعی کرده است تا حفظ رتبه های اصلی کاربران داشته و تلاش می کند تا تاثیر کاربران و رهبر را به طور معقولانه تری بر رتبه کاربر

مراجع

- [1] Linas Baltrunas, Tadas Makcinskas, and Francesco Ricci, “Group Recommendations with Rank Aggregation and Collaborative Filtering”, in ACM Conference on Recommender Systems, 2010.
- [2] Palanigurupackiam Nagaraj and Perumalsamy Deepalakshmi, “An Intelligent Fuzzy Inference Rule-Based Expert Recommendation System for Predictive Diabetes Diagnosis”, International Journal of Imaging Systems and Technology 32, no. 4 (1 July 2022): 1373–96.
- [3] Leyla Gamidullaeva et al., “A Design Concept for a Tourism Recommender System for Regional Development”, Algorithms 16, no. 1 (2023).
- [4] Alwin Poulose, Anusha Palli Valappil, and Josy Sebastian, “Medication Recommender System for Healthcare Solutions”, Journal of Information and Optimization Sciences 43, no. 5 (4 July 2022): 1073–80.
- [5] Wai Khuen Cheng et al., “Affective Recommender System for Pet Social Network”, Sensors 22, no. 18 (2022).
- [6] Rushil Kaushikkumar Patel et al., “AI-Empowered Recommender System for Renewable Energy Harvesting in Smart Grid System”, IEEE Access 10 (2022): 24316–26.
- [7] Robin Burke, Alexander Felfernig, and Mehmet H Göker, “Recommender Systems: An Overview”, AI Magazine 32, no. 3 (June 2011): 13–18.
- [8] Robin Burke, “Hybrid Recommender Systems: Survey and Experiments”, User Modeling and User-Adapted Interaction 12, no. 4 (2002): 331–70.
- [9] Sriharsha Dara, C Ravindranath Chowdary, and Chintoo Kumar, “A Survey on Group Recommender Systems”, Journal of Intelligent Information Systems 54, no. 2 (2020): 271–95.
- [10] Shuai Zhang et al., “Deep Learning Based Recommender System: A Survey and New Perspectives”, ACM Computing Surveys (CSUR) 52, no. 1 (2019): 1–38.
- [11] V Ramanjaneyulu Yannam et al., “Improving Group Recommendation Using Deep Collaborative Filtering Approach”, International Journal of Information Technology 15, no. 3 (2023): 1489–97.
- [12] Amra Delic et al., “An Observational User Study for Group Recommender Systems in the Tourism Domain”, Information Technology & Tourism 19, no. 1 (2018): 87–116.
- [13] Amra Delic et al., “Research Methods for Group Recommender System.”, in RecTour@ RecSys, 2016, 30–37.
- [14] Judith Masthoff, “Group Recommender Systems: Aggregation, Satisfaction and Group Attributes”, Recommender Systems Handbook, 2015, 743–76.
- [15] Lin Xiao et al., “Fairness-Aware Group Recommendation with Pareto-Efficiency”, in Proceedings of the Eleventh ACM Conference on Recommender Systems, 2017, 107–15.
- [16] A Jameson and B Smyth, Recommendation to Groups. In (Brusilovsky, P.; Kobsa, A.; Nejdl, W., Eds.): The Adaptive Web, LNCS 4321 (Springer Verlag, Berlin/Heidelberg, 2007).
- [17] Dimitris Sacharidis, “Top-n Group Recommendations with Fairness”, in Proceedings of the 34th ACM/SIGAPP Symposium on Applied Computing, 2019, 1663–70.
- [18] Shlomo Berkovsky and Jill Freyne, “Group-Based Recipe Recommendations: Analysis of Data Aggregation Strategies”, in Proceedings of the Fourth ACM Conference on Recommender Systems, 2010, 111–18.
- [19] Venkateswara Rao Kagita, Arun K Pujari, and Vineet Padmanabhan, “Group Recommender Systems: A Virtual User Approach Based on Precedence Mining”, in AI 2013: Advances in Artificial Intelligence: 26th Australasian Joint Conference, Dunedin, New Zealand, December 1–6, 2013. Proceedings 26 (Springer, 2013), 434–40.
- [20] Judith Masthoff, “Group Recommender Systems: Combining Individual Models”, in Recommender Systems Handbook (Springer, 2010), 677–702.
- [21] Alexander Felfernig et al., Group Recommender Systems: An Introduction (Springer, 2024).
- [22] Judith Masthoff, “Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers”, Personalized Digital Television: Targeting Programs to Individual Viewers, 2004, 93–141.
- [23] Christophe Senot et al., “Evaluation of Group Profiling Strategies”, in Twenty-Second International Joint

Conference on Artificial Intelligence, 2011.

- [24] Felix Brandt, Vincent Conitzer, and Ulle Endriss, “Computational Social Choice”, *Multiagent Systems* 2 (2012): 213–84.
- [25] Martin Stettinger, “Choicla: Towards Domain-Independent Decision Support for Groups of Users”, in *Proceedings of the 8th ACM Conference on Recommender Systems*, 2014, 425–28.
- [26] Lin Xiao and Gu Zhaoquan, “How Does Fairness Matter in Group Recommendation”, in *Web Information Systems Engineering-WISE 2017: 18th International Conference*, Puschino, Russia, October 7-11, 2017, *Proceedings, Part II* 18 (Springer, 2017), 458–66.
- [27] Mark O’Connor et al., “PolyLens: A Recommender System for Groups of Users”, in *ECSCW 2001: Proceedings of the Seventh European Conference on Computer Supported Cooperative Work* 16–20 September 2001, Bonn, Germany (Springer, 2001), 199–218.
- [28] Sabrine Ben Abdabbah et al., “Aggregating Top-k Lists in Group Recommendation Using Borda Rule”, in *Advances in Artificial Intelligence: From Theory to Practice: 30th International Conference on Industrial Engineering and Other Applications of Applied Intelligent Systems, IEA/AIE 2017*, Arras, France, June 27-30, 2017, *Proceedings, Part I* 30 (Springer, 2017), 325–34.
- [29] Yang Xiao et al., “An Enhanced Probabilistic Fairness-Aware Group Recommendation by Incorporating Social Activeness”, *Journal of Network and Computer Applications* 156 (2020): 102579.
- [30] Dimitris Serbos et al., “Fairness in Package-to-Group Recommendations,” in *Proceedings of the 26th International Conference on World Wide Web*, 2017, 371–79.
- [31] Reza Barzegar Nozari and Hamidreza Koohi, “A Novel Group Recommender System Based on Members’ Influence and Leader Impact,” *Knowledge-Based Systems* 205 (2020): 106296.
- [32] Emre Yalcin, Firat Ismailoglu, and Alper Bilge, “An Entropy Empowered Hybridized Aggregation Technique for Group Recommender Systems,” *Expert Systems with Applications* 166 (2021): 114111.
- [33] Abinash Pujahari and Dilip Singh Sisodia, “Preference Relation Based Collaborative Filtering with Graph Aggregation for Group Recommender System,” *Applied Intelligence* 51 (2021): 658–72.
- [34] Wei Wang, Guangquan Zhang, and Jie Lu, “Member Contribution-Based Group Recommender System,” *Decision Support Systems* 87 (2016): 80–93.
- [35] Arthur F Da Costa, Marcelo G Manzato, and Ricardo J G B Campello, “Group-Based Collaborative Filtering Supported by Multiple Users” Feedback to Improve Personalized Ranking,” in *Proceedings of the 22nd Brazilian Symposium on Multimedia and the Web*, 2016, 279–86.
- [36] Roza Abolghasemi et al., “A Personality-Aware Group Recommendation System Based on Pairwise Preferences,” *Information Sciences* 595 (2022): 1–17.
- [37] Bogdan Walek and Petr Fajmon, “A Hybrid Recommender System for an Online Store Using a Fuzzy Expert System,” *Expert Systems with Applications* 212 (2023): 118565.
- [38] V Ramanjaneyulu Yannam et al., “Enhancing the Accuracy of Group Recommendation Using Slope One,” *The Journal of Supercomputing* 79, no. 1 (2023): 499–540.
- [39] Jitendra Kumar et al., “Improve the Recommendation Using Hybrid Tendency and User Trust,” *International Journal of Information Technology* 15, no. 6 (2023): 3147–56.
- [40] Yehuda Koren, Robert Bell, and Chris Volinsky, “Matrix Factorization Techniques for Recommender Systems,” *Computer* 42, no. 8 (2009): 30–37.