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.Sc., 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 سبزه‌کار[۱،*] و بنت‌الهدی مؤذنی[۲]

اطلاعات مقاله

دریافت مقاله: ۱۴۰۲/۰۵/۱۰
بازنگری مقاله: ۱۴۰۲/۰۹/۱۸
پذیرش مقاله: ۱۴۰۲/۰۹/۲۲

واژگان کلیدی:
سیستم توصیه‌گر گروهی،
عدالت،
تابع تجمیع.

چکیده

در یک سیستم توصیه‌گر گروهی تلاش می‌شود ارائه توصیه به گروهی از افراد به‌جای یک فرد صورت پذیرد. در این سیستم‌ها نظرات تمام اعضای گروه در تصمیم‌گیری مؤثر بوده و سعی می‌شود تا باوجود 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 وابستگی کاربران به گروه، رهبر آن گروه را مشخص نماید. بعلاوه، معیار جدیدی برای ارائه توصیه عادلانه به گروه ارائه‌شده 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 بهبود ۵ درصدی را گزارش نمود. در بخش ارزیابی توصیه‌ها نیز از معیارهای شناخته شده nDCG ، رضایت گروهی 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٪ و ۳۸٪ بهبود یافته است.

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/)

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. آیتم های 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 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]، انرژهای تجدیدپذیر [۶] و... اشاره نمود.

از ابتدای پیدایش سیستم‌های توصیه‌گر، تعاریف مختلفی برای آن ارائه شده است. در سال ۱۹۹۷ ، رسنیک و وارین

* پست الکترونیک نویسنده مسئول: sabzekar@birjandut.ac.ir
۱. استادیار، گروه مهندسی کامپیوتر، دانشگاه صنعتی بیرجند، بیرجند، ایران
۲. کارشناس ارشد، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد بیرجند، بیرجند، ایران

استناد به این مقاله:
سبزه کار, مصطفی, و موذنی, بنت الهدی. (۱۴۰۳). ارائه سیستم جدید توصیه عادلانه گروهی مبتنی بر تأثیر اعضا و رهبر. مدل سازی در مهندسی, ۲۲(۷۷), ۲۲۱-۲۴۳.
doi: 10.22075/jme.2023.31390.2507

سیستم توصیه‌گر را به‌عنوان 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 علایق 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 (به‌طوری‌که $u: C \times S \Longrightarrow R$ و 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 به‌منظور تولید توصیه، از روش‌ها و الگوریتم‌های مختلفی استفاده می‌نمایند که در شکل (۱)، رایج‌ترین آن‌ها نمایش داده شده است.

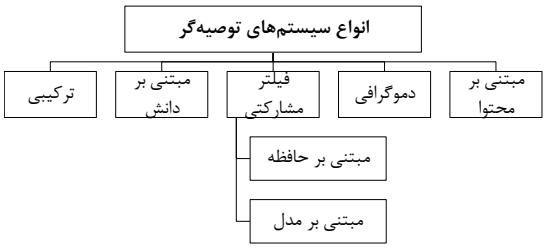

شکل ۱- انواع روش‌های تولید توصیه در سیستم توصیه‌گر

سیستم‌های مبتنی بر محتوا براساس سابقه علاقه‌مندی‌ها و ترجیحات کاربر، آموزش داده‌شده و درنهایت آیتم‌های مشابه با تاریخچه سابقه‌ی 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 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 برطرف 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 به‌صورت گروهی انجام می‌شود [۱۱]. با افزایش فعالیت‌های گروهی، نیاز به طراحی سیستم‌های توصیه‌گری است که به‌جای فرد، گروهی از افراد را برای ارائه یک توصیه واحد در نظر بگیرد. این سیستم‌ها به‌عنوان 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 به‌منظور 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 علایق 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، به‌صورت موقت تشکیل‌شده و کاربران ممکن است برای اولین بار در آن حضور یافته باشند و از این جهت، هیچ سابقه‌ای از تعاملات آن‌ها

[2] Aggregation Strategies

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 اعضای 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 مورداستفاده 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 اعضای گروه ایجاد کرده و گروه را به‌عنوان 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 می گیرد. این استراتژی به‌عنوان تجمیع مدل‌ها نیز شناخته می‌شود [۱۸ و ۱۹]. شکل (۲) استراتژی مربوط به این رویکرد را نشان می‌دهد.

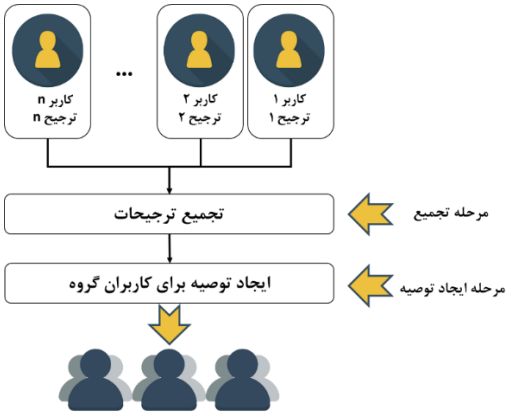

شکل ۲- رویکرد مبتنی بر یکپارچه‌سازی پروفایل گروه

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 اعضای گروه حاصل می‌شو. بنابراین این رویکرد ابتدا برای هر یک از اعضای گروه به‌طور مستقل و جداگانه، اقدام به ارائه توصیه کرده و سپس توصیه‌های ارائه‌شده به اعضای گروه، به‌صورت رتبه‌بندی شده در یک لیست قرار داده می‌شود. درنهایت 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 توصیه‌شده به اعضای گروه، به‌طور جداگانه، توصیه و سپس ارزیابی می‌شوند. این استراتژی به‌عنوان تجمیع پیش‌بینی‌ها شناخته می‌شود. شکل (۳) نمایانگر استراتژی مربوط به رویکرد مبتنی بر یکپارچه‌سازی توصیه‌ها می‌باشد [۱۶ و ۱۸].

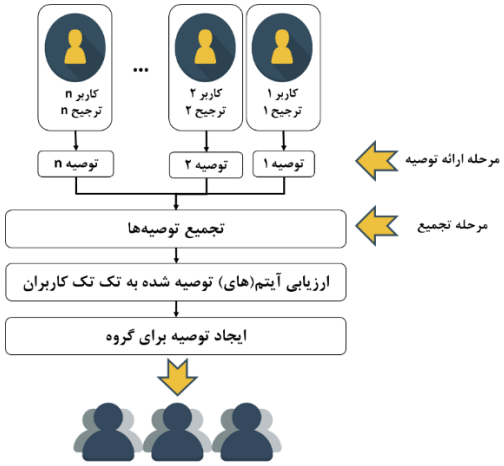

شکل ۳- رویکرد مبتنی بر یکپارچه‌سازی توصیه‌ها

یک چالش مهم در تمام سناریوهای توصیه گروه، چگونگی سازگار کردن گروه به‌عنوان یک کلیّت، 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. نظریه‌پردازان انتخاب اجتماعی، در اغلب موارد با مسائل مربوط به مرتب کردن رتبه‌ها درگیر 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 دهند، بسیار دشوار و حتی غیرممکن است. به‌منظور 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 اعضای گروه را در نظر بگیرد.

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

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

جدول ۱- توابع تجمیع استفاده شده در منابع

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

سیستم توصیه‌گر 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[1]، تساوی[2] و کارایی[3] 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 توصیه‌گر گروهی است و مقالات مختلفی به آن پرداخته‌اند. نویسندگان در [۱۵] عدالت را نشان‌دهنده میزان رضایت کاربران مختلف در یک گروه، در مورد آیتم توصیه‌شده تعریف نموده و بیان می‌نمایند که عدالت باید بازتاب‌دهنده مقایسه بین میزان مطلوبیت کاربرانِ 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 آیتمِ بعدی، اولویت بالاتری دارند. در [۲۶]، دو معیار به نام میزان تناسب[4] و آزاد از حسادت[5] 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 موردعلاقه کاربر در بسته پیشنهادی وجود دارد، این بسته برای کاربر عادلانه است. در مفهوم دوم، با در نظر گرفتن گروهی مانند G و مجموعه آیتمی مانند P ،کاربر u عضو G آزاد از حسادت است اگر حداقل m آیتم از آیتم‌های موردعلاقه کاربر در مجموعه P باشد. در این صورت کاربر احساس می‌کند که بسته منصفانه است. در غیر این صورت نسبت به سایر اعضای گروه حسادت می‌کند.

با توجه به مطالب فوق، می‌توان گفت که عدالت در سیستم توصیه‌گر گروه به معنای کسب رضایت همه اعضای گروه در زمان توصیه است اما عملی کردن این مفهوم در سیستم توصیه‌گر گروه، هنوز به‌عنوان یک چالش پابرجا است. در این مقاله قصد داریم روش جدیدی برای محاسبه تأثیر اعضا 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 توصیه‌گر گروهی انجام شده است. یکی از اولین تحقیقات در این زمینه در سال ۲۰۰۱ انجام شد یک سیستم توصیه‌گر گروهی به نام پلی‌لنز[6] به منظور پیشنهاد فیلم به گروهی از کاربران ارائه گردید [۲۷].

در [۲۸] یک سیستم توصیه‌گر 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 تشکیل‌شده است. در مرحله اول، لیست‌های توصیه‌ها برای اعضای گروه با استفاده از تکنیک فیلتر مشارکتی مبتنی بر کاربر تولید می‌شود. سپس، لیست توصیه‌های تولیدشده در مرحله قبل با استفاده از رأی‌گیری 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 جمع‌کردن 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 تهیه یک لیست رتبه‌بندی استفاده کرده تا برای هر عضو گروه تا حد ممکن، توصیه، عادلانه باشد.

[1] Fairness
[2] Equity
[3] Efficiency
[4] Proportionality
[5] Envy-Freeness
[6] Polylens

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

نویسندگان در [۳۰] تلاش در ارائه یک سیستم توصیه‌گر گروه نمودند تا بتواند یک آیتم یا بسته‌ای از آیتم‌ها را به‌طور عادلانه به یک گروه از کاربران تخصیص دهند. این مطالعه دو رویکرد مختلف ارائه داده است. در رویکرد نخست ابتدا احتمال انتخاب آیتم i توسط گروه u محاسبه شده سپس، احتمال‌های به‌دست‌آمده برای هر آیتم باهم ترکیب‌شده 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 به‌عنوان نماینده انتخاب می‌کند. این کاربر برای همه آیتم‌ها تصمیم‌گیری می‌کند و آیتم‌ها را انتخاب می‌کند. سپس احتمال اینکه آیتم i توسط کاربر u 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 قرارگرفته که در آن حداقل مطلوبیتی که عضو گروه دریافت می‌کند، به‌عنوان عدالت شناخته می‌شود. این مطالعه از مفهوم بهینگی پرتو[1] استفاده نموده و آیتم یا مجموعه آیتم‌های که برای همه اعضای گروه رتبه بالاتری را کسب کرده باشد، به‌عنوان 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 خوشه‌بندی 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.

نویسندگان در [۳۲] دو روش جدید تجمیع با ترکیبی از روش‌های رأی‌گیری تأییدی و سودمندی افزایشی ارائه نمودند تا آیتم‌های موردعلاقه اعضای گروه را مشخص و توصیه کنند. معیار سودمندی افزایشی، برای تعیین مجموع ترجیحات اعضای گروه و معیار رای گیری تأییدی، برای تعیین رتبه‌های بالا جهت رتبه‌بندی گروه استفاده می‌شود. در این مقاله، ابتدا گروه‌های کاربران با استفاده از خوشه‌بندی مشخص و شناسایی می‌شود. سپس، با استفاده از تکنیک‌های تجمیع 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 تجمیع ترجیحات نیز از طریق یک استراتژی تجمع وزن جدید استفاده‌شده 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 استفاده‌شده که از آن برای تعیین وزن هر کاربر به آیتم و درنهایت وزن گروه کاربران به یک آیتم استفاده می‌شود.

از سوی دیگر، نویسندگان در [۳۴] روشی به‌منظور 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 مبتنی‌بر 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 می شود.

در پژوهشی دیگر برای به دست آوردن یک سیستم توصیه گر 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 شده‌است. در گام دوم نمودار تاثیرگذاری شامل ویژگی‌ها شخصیتی از جمله قاطعیت و همکاری ایجاد شده و در نهایت یک مدل پویایی عقیده به

[1] Pareto Optimality

منظور تجمیع 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 ارائه گردید. استفاده از این الگوریتم سبب می‌شود تا نتایج مرتبط‌تری یافت شود. همچنین یکی از مزایای دیگر این روش، پشتیبانی از به‌روزرسانی پویای پیش بینی‌های رتبه بندی 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.

جدول ۲- خلاصه سیستم‌های توصیه‌گر گروهی

نام پروژه	سال	توضیحات
Top-K Lists [۲۸]	۲۰۱۷	نقاط قوت: –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. نقاط ضعف: –عدم مؤثربودن برای مقابله با شروع سرد، آیتم‌ها و کاربران جدید
PFGR [۲۹]	۲۰۲۰	نقاط قوت: –ارائه توصیه عادلانه برای همه اعضای یک گروه –استفاده از تئوری بازی و احتمالات که با داشتن پایه ریاضی توصیه‌های دقیق‌تری انجام می‌شود. نقاط ضعف: –زمان‌بر و پرهزینه بودن محاسبات
[۳۰]	۲۰۱۷	نقاط قوت: –استفاده از معیار عدالت برای توصیه گروهی، بررسی دقیق مفهوم عدالت نقاط ضعف: –زمان‌بر و پرهزینه بودن محاسبات
max-min fairness [۲۶]	۲۰۱۷	نقاط قوت: –استفاده از مفهوم عدالت نقاط ضعف: –زمان‌بر و پرهزینه بودن محاسبات
Pareto optimality [۱۷]	۲۰۱۹	نقاط قوت: –استفاده از مفهوم بهینگی پرتو، استفاده از مفهوم عدالت نقاط ضعف: –زمان‌بر و پرهزینه بودن محاسبات
[۳۱]	۲۰۲۰	نقاط قوت: –تعیین روابط کاربران بر هم در گروه و دخیل کردن این روابط در تصمیم‌گیری نهایی نقاط ضعف: –استفاده از معیار میانگین بدون درنظرگرفتن مفاهیمی همچون عدالت، میزان رضایت کاربران از توصیه
[۳۲]	۲۰۲۱	نقاط قوت: –ساده‌بودن عملیات توصیه نقاط ضعف:

		– عدم توجه به تأثیر کاربران بر تصمیمات هم
[۳۳]	۲۰۲۱	نقاط قوت: – ارائه روش جدید برای تجمیع ترجیحات، استفاده از گراف ترجیحات برای رتبه‌بندی آیتم‌ها در گروه – تخمین مناسب رتبه‌های آیتم‌ها در گروه – نقاط ضعف: – زمان‌بر بودن تولید گراف ترجیحات برای هر کاربر و درنتیجه زمان‌بر بودن تعیین رتبه آیتم‌ها برای گروه
MC-GR [۳۴]	۲۰۱۶	نقاط قوت: – استفاده از تأثیر اعضا بر رتبه ارائه‌شده از سوی آن‌ها، – ارائه یک مدل جدید برای ترکیب رتبه‌های موجود در گروه نقاط ضعف: – استفاده از نمونه‌گیری تصادفی برای تعیین نماینده هر گروه
Group-based Collaborative Filtering [۳۵]	۲۰۱۶	نقاط قوت: – استفاده از فیلترینگ مشارکتی پیشرفته برای ارائه توصیه – استخراج موضوعات موردعلاقه کاربران قبل از ارائه توصیه و سپس استفاده از آن برای توصیه نقاط ضعف: – عدم توجه به رضایت‌بخش بودن آیتم توصیه‌شده نهایی برای کاربران
[۳۶]	۲۰۲۲	نقاط قوت: – اعمال اولویت‌های زوجی برای محاسبه‌ی دقیق‌تر رتبه‌بندی آیتم‌ها – استفاده از ویژگی‌های شخصیتی برای درک تأثیر کاربر بر تصمیم نهایی نقاط ضعف: – جمع‌آوری اطلاعات مربوط به ویژگی‌های شخصیتی کاربران با آزمون TKI – ثابت درنظرگرفتن ویژگی‌های شخصیتی کاربران درحالی‌که ممکن است کاربری تغییر نگرش دهد
[۳۷]	۲۰۲۳	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 ماژول خبره فازی که از رتبه‌بندی نهایی محصولات بر اساس پارامترهای مختلف اطمینان حاصل می‌نماید. نقاط ضعف: – عدم ارزیابی مستمر خروجی‌ها
[۳۸]	۲۰۲۳	نقاط قوت: – افزایش دقت توصیه گروهی در زمان کوتاه‌تر با استفاده از روش Slope One – پشتیبانی از به‌روزرسانی پویای پیش‌بینی‌های رتبه‌بندی در حالت آنلاین نقاط ضعف: – نیاز به استفاده از اطلاعات بیشتر در مورد کاربران
[۳۹]	۲۰۲۳	نقاط قوت: – افزودن مفهوم اعتماد به سیستم توصیه‌گر گروهی

بر اساس بررسی مطالعات موجود در این حوزه، مواردی هنوز به‌عنوان چالش مطرح است. اولین چالش ناقص بودن و مناسب نبودن استراتژی‌های تجمیع جاری برای سیستم های توصیه‌گر است. این استراتژی‌ها اغلب بازخورد تصمیمات قبلی را در نظر نمی‌گیرند. دوم اینکه اغلب الگوریتم‌ها به روابط کاربران در گروه و تأثیرات آن‌ها بر نظرات یکدیگر توجه نمی‌کنند. درصورتی‌که نظر کاربران در گروه می‌تواند تحت‌تأثیر سایرین تغییر کند. الگوریتم‌هایی هم که سعی در یافتن این روابط دارند، هنوز با چالش‌های بسیاری مواجه هستند. تخمین رتبه‌ها و اطلاعات

ازدست‌رفته، 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 نماید. 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، مورداعتماد و توجه هستند. ازاین‌رو، 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، باتوجه‌به سایر اعضای 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 توصیه‌گرِ 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.

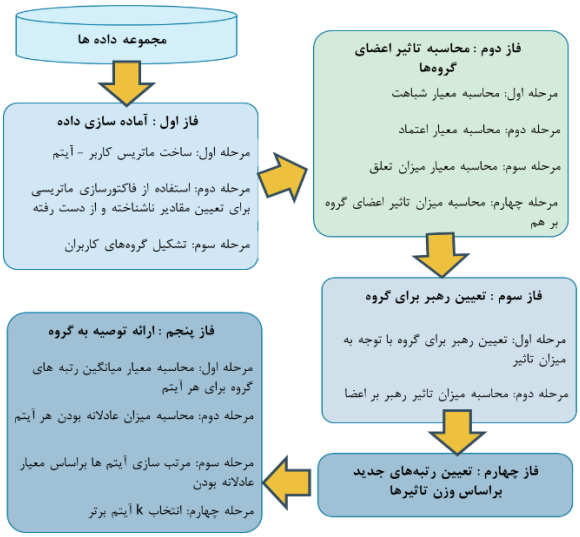

شکل ۴- روش کلی الگوریتم پیشنهادی FairILGRS

۳-۱- فاز اول: آماده‌سازی مجموعه داده

در هر سیستم توصیه‌گر، مجموعه‌ای از کاربران به‌صورت $U\{u_1, u_2, \ldots, u_n\}$ و همچنین مجموعه‌ای از آیتم‌ها به‌صورت $I\{I_1, I_2, \ldots, I_m\}$ 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 بهتر، 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 به‌صورت 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.

$$user-item \begin{bmatrix} r_{1,1} & r_{1,2} & r_{1,3} & \cdots & r_{1,n} \\ r_{2,1} & r_{2,2} & r_{2,3} & \cdots & r_{2,n} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ r_{m,1} & r_{m,2} & r_{m,3} & \cdots & r_{m,n} \end{bmatrix} \quad (۱)$$

در ماتریس یادشده، $r_{i,j}$ رتبه کاربر iام به آیتم jام 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 ازدست‌رفته، تلقی می‌شوند. حال‌آنکه یک سیستم توصیه‌گر، فارغ از گروهی بودن آن، بر اساس رتبه‌های داده‌شده به آیتم‌ها، اقدام به ارائه توصیه می‌کند، که عدم وجود رتبه می‌تواند بر کارایی و دقت سیستم تأثیر بگذارد. فاکتورسازی ماتریسی[1]، یک نوع مدل عامل پنهان و یکی از محبوب‌ترین روش‌های توصیه است که توانایی بالایی در مواجهه با داده‌های ناشناخته و ازدست‌رفته 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

[1] Matrix factorization

ورودی‌های 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 حاصل‌ضرب دو ماتریس کوچک‌تر W_1 و W_2 است.

$$R = W_1 W_2^T \qquad (۲)$$

که دراین‌رابطه، $W_1 \in \mathbb{R}^{|U|\times K}$ 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 iام را توصیف می‌کند، شامل می‌شود. فرض کنید که $w_{1_{uk}}$ و $w_{2_{ik}}$، درآیه‌ها و w_{1_u} و w_{2_i}، به ترتیب بردارهای W_1 و W_2 باشند، رتبه r داده‌شده توسط کاربر u به آیتم i با استفاده از رابطه‌ی (۳) پیش‌بینی می‌شود [۴۰]:

$$\hat{r}_{ui} = \sum_{k=1}^{k} W_{1_{uk}} W_{2_{ik}} = W_{1_u} W_{2_i}^T \qquad (۳)$$

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]:

$$O^{MF} = \sum_{(u,i)\in R} (R_{ui} - W_{1_u} W_{2_i}^T)^2 + \lambda(\|W_1\|_F^2 + \|W_2\|_F^2) \qquad (۴)$$

که در آن $\|w\|_F^2$ یک نُرم فورینوس[1] است و $0 < \lambda < 1$ یک عبارت منظم‌سازی است که مقداری بین صفر تا یک دارد و برای جلوگیری از بیش برازش 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 به‌عنوان 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 تعریف می‌شوند. برای مثال، 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 داده-های موجود در آن ایجاد می‌شوند. برای به‌دست‌آوردن این گروه‌ها از میزان شباهت افراد، شباهت ترجیحات افراد و... استفاده می‌شود. در گروه‌بندی تصادفی، گروه خاصی از پیش تعریف 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. باتوجه‌به 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 خوشه‌بندی K-means برای تشکیل گروه استفاده می‌شود.

در این مقاله، ابتدا به‌اندازه‌ای ازپیش‌تعیین‌شده، K گره به‌عنوان مرکز خوشه انتخاب می‌شود. در اینجا، تعداد گروه-ها متناسب با مجموعه‌داده مشخص خواهد شد. سپس باتوجه‌به میزان شباهت سایر گره‌ها با مراکز خوشه، هر گره به یک خوشه تخصیص می‌یابد. به‌منظور اندازه‌گیری شباهت کاربران از رابطه (۵) استفاده می‌شود [۳۱]:

$$simlarity_{u,v} = \frac{(\sum_{i\in I}(r_{u,i} - \overline{r_u})(r_{v,i} - \overline{r_v}))}{\sqrt{\sum_{i\in I}(r_{u,i} - \overline{r_u})^2}\sqrt{\sum_{i\in I}(r_{v,i} - \overline{r_v})^2}} \qquad (۵)$$

در رابطه فوق، $r_{u,i}$ رتبه کاربر u به آیتم iام است. $\overline{r_u}$ نیز به میانگین رتبه‌هایی که کاربر u به همه آیتم‌ها داده است، اشاره دارد. به‌طور مشابه $r_{v,i}$ رتبه کاربر v به آیتم iام و $\overline{r_v}$ میانگین رتبه‌هایی است که کاربر v به همه آیتم‌ها داده است. عملیات انتخاب گره و تشکیل خوشه، به تعداد تکرار معین انجام‌شده و درنهایت بهترین خوشه، به‌عنوان خوشه-های نهایی انتخاب می‌شوند.

۳-۲- 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.

[1] Norm February

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

$$simlarity_{u,v} = \frac{simlarity_{u,v} - \min(simlarity)}{\max(simlarity) - \min(simlarity)} \quad (۶)$$

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 نیست و در بیشتر موارد، به‌عنوان 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 به‌طور مستقیم توسط آن‌ها بیان می‌شود، درحالی‌که اعتماد ضمنی به‌صراحت توسط کاربران بیان نمی‌شود، بلکه بر اساس برخی شواهد، اسناد و شباهت‌ها به دست می‌آید.

در این مقاله، رابطه اعتماد بین کاربران به‌صورت ضمنی در نظر گرفته می‌شود، زیرا هیچ اعتماد صریحی در مجموعه‌داده مورداستفاده 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 باتوجه‌به 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 بودن علایق دو کاربر، می‌توان تعداد آیتم‌ها موردعلاقه هر دو را مشخص کرد. برای این منظور، با فرض اینکه $r_{u,i}$ رتبه‌ای است که کاربر uام به آیتم iام داده است، $categorize(r_{u,i})$ مطابق با رابطه (۷) مشخص می‌کند که آیتم موردعلاقه کاربر بوده است یا خیر.

$$categorize(r_{u,i}) = \begin{cases} like & if\ r_{u,i} \geq (0.5 \times r_{max}) \\ unlike & else \end{cases} \quad (۷)$$

بعد از محاسبه آیتم‌های موردعلاقه 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]:

$$Partnership_{u,v} = \frac{like_u \cap like_v}{like_u} \quad (۸)$$

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

$$Distance_{u,v} = \frac{1}{1 + \left(\sqrt{\sum_{i \in I_{u,v}} (r_{u,i} - r_{v,i})^2}\right)} \quad (۹)$$

که $r_{u,i}$ و $r_{v,i}$ به ترتیب رتبه‌ای است که کاربر u و v به آیتم iام 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]:

$$Trust_{u,v} = \frac{2 \times Partnership_{u,v} \times Distance_{u,v}}{Partnership_{u,v} + Distance_{u,v}} \quad (۱۰)$$

در رابطه (۱۰)، میزان اعتماد به‌صورت 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 به‌عنوان تشکیل‌دهنده گروهِ خانواده، تعلق بیشتری به این گروه دارند. در سیستم توصیه‌گر، اغلب

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 خوشه‌بندی به‌عنوان شاخص نیم‌رخ[1] مطرح است. شاخص نیم‌رخ، فاصله بین داده‌ها در خوشه‌های متفاوت را بررسی می‌کند و این هدف را دنبال می‌کند که خوشه نسبت‌داده‌شده به یک نمونه داده، تا چه میزان درست و مطلوب بوده است. این معیار به پیوستگی درون خوشه‌ها و به میزان تفکیک‌پذیری آن‌ها بستگی دارد. مقدار نیم‌رخ برای هر نقطه، میزان تعلق آن را به خوشه‌اش در مقایسه با خوشه مجاور اندازه می‌گیرد. به‌منظور محاسبه این معیار مطابق با رابطه (۱۱) ابتدا میزان شباهت یک کاربر مانند u به گروه تعیین می‌شود:

$$InSim(u) = \frac{1}{|C|-1}\sum_{v\in C} simlarity_{u,v} \qquad (۱۱)$$

در رابطه فوق، $simlarity_{u,v}$ 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. ازآنجاکه 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 می شود. درنهایت نیز کمترین میزان میانگین شباهت، مشخص می‌شود. رابطه (۱۲) این شباهت را محاسبه می‌کند.

$$OutSim(u) = \min_{k=1,\dots,N} \frac{1}{|C_k|}\sum_{v\in C_k} simlarity_{u,v} \qquad (۱۲)$$

در رابطه (۱۲) نیز، $simlarity_{u,v}$ شباهت دو کاربر u و v است، C_k گروه kام را نشان می‌دهد. $|C_k|$ تعداد اعضای گروه است. درنهایت، مقدار نهایی معیار وابستگی به‌صورت رابطه (۱۳) محاسبه می‌شود:

$$Dependency_u = 1 - \left|\frac{OutSim(u) - InSim(u)}{\max\{InSim(u), OutSim(u)\}}\right| \qquad (۱۳)$$

هر چه مقدار $Dependency_u$ به یک نزدیک‌تر باشد، وابستگی بیشتر است. حال با ترکیب این مقادیر می‌توان میزان تأثیر کاربر u بر کاربر v را با استفاده از رابطه (۱۴) اندازه‌گیری کرد:

$$Weight_Inf_{u,v} = \frac{2\times Trust_{v,u}\times simlarity_{v,u}\times Dependency_u}{(Trust_{v,u}+simlarity_{v,u}+Dependency_u)} \qquad (۱۴)$$

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. علاوه‌براین، رهبر می‌تواند نظرات مشابهی را برای اعضا ارائه دهد. ازاین‌رو، الگوریتم پیشنهادی، باتوجه‌به 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، به‌عنوان رهبر در نظر گرفته می‌شود. رابطه (۱۵) برای شناسایی رهبر در یک گروه تعریف‌شده است. پس از آن به‌منظور تعیین میزان تأثیر و نفوذ رهبر بر اعضای گروه از رابطه (۱۶) استفاده می‌شود.

$$leader_{G_g} = \left\{u: argmax \sum_{v\in G_g; v\neq u} simlarity_{v,u} + Trust_{v,u} + Dependency_u\right\} \qquad (۱۵)$$

$$LeaderWeight_{Inf_{u,v}} = \frac{\sum_{L,u\in G_g: L\neq u} simlarity_{u,L} + Trust_{v,u} + Dependency_u}{2\times(N_{G_g}-1)} \qquad (۱۶)$$

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

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

$$new_{r_{u,i}} = r_{u,i} + \frac{\sum_{v=1}^{N_{G_g}} WeightInf_{u,v}\times(r_{v,i}-r_{u,i})}{|N_{G_g}|}, \quad where\ u,v\in G_g \qquad (۱۷)$$

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

[1] Silhouette Index

v، رهبر گروه باشد از مقدار $LeaderWeight_Inf_{u,v}$ در رابطه (۱۶) استفاده می‌شود.

۳-۵- فاز پنجم: ارائه‌ی توصیه به گروه

در این مرحله، توصیه به گروه ارائه می‌شود. برای ارائه توصیه نیاز به استفاده از یک معیار جهت تجمیع آرا و رتبه-های کاربران گروه است. به همین منظور در این مقاله ترکیبی از استراتژی‌های تجمیع موجود مورد استفاده قرار گرفته به‌گونه‌ای که عدالت در توصیه‌ها، بیشینه شود. همچنین آیتمی که اکثر افراد از آن راضی باشند، به‌عنوان آیتم عادلانه در نظر گرفته می‌شود. با داشتن این تعریف، مراحل تجمیع 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. درحالی‌که 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 می توان تعیین کرد که هر کاربر در زمان رتبه دهی چه میزان سخت‌گیر و حساس است. رابطه (۱۸) نحوه محاسبه این معیار را نشان می‌دهد.

$$average_user\ (u) = \frac{\sum_{i \in I} new_rate_{u,i}}{|I|} \qquad (۱۸)$$

که دراین‌رابطه u یک کاربر و i یک آیتم از مجموعه آیتم‌ها یعنی I بوده و $new_rate_{u,i}$ رتبه‌ای است که کاربر u به آیتم i داده و $|I|$ تعداد آیتم‌های موجود برای توصیه می باشد.

ب) در گام دوم، برای هر کاربر آیتم‌هایی که رتبه آن بیشتر از میانگین باشد، مشخص می‌شود. سپس آیتم‌های بر اساس میانگین رتبه کاربر جدا می‌شوند. آیتم‌هایی که بالاتر از میانگین رتبه کاربر باشند، به‌عنوان آیتم قابل‌قبول و در غیر این صورت به‌عنوان آیتم‌های غیرقابل‌قبول لحاظ می‌شوند.

$$rank(u,i) = \left|new_rate_{u,i} > average_user\ (u)\right| \qquad (۱۹)$$

ج) در گام سوم، با استفاده از استراتژی میانگین سنتی، میانگین رتبه‌های کسب شده برای هر آیتم در گروه محاسبه می‌شود. با فرض اینکه g گروهی از مجموعه گروه‌ها یعنی G باشد.

$$average_{item}(i) = \frac{\sum_{u \in g} new_{rate_{u,i}}}{N_g}, i \in I \qquad (۲۰)$$

در رابطه (۲۰) ، $average_{item}(i)$ میانگین رتبه‌هایی است که به آیتم i داده‌شده است. $new_rate_{u,i}$ رتبه‌ای است که کاربر u به آیتم i داده است. N_g تعداد کاربران موجود در گروه g است.

د) در گام چهارم، حاصل‌ضرب میانگین رتبه‌های کسب شده برای هر آیتم $(average_{item}(i))$ در مجموع رتبه $(rank)$ به‌دست‌آمده برای هر آیتم محاسبه می‌گردد. درنهایت، آیتم‌ها بر اساس این رتبه مرتب شده و k آیتم برتر 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 استفاده‌شده است. بر اساس بررسی‌ها و تحقیقات انجام‌شده، در اغلب تحقیقات، به‌منظور پیاده‌سازی و ارزیابی الگوریتم سیستم توصیه‌گر گروهی، از مجموعه‌داده‌های معمول در سیستم توصیه‌گر سنتی استفاده‌شده 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 می-کنیم. این مجموعه یکی از مجموعه‌داده‌های مشهور و محبوب در زمینه سیستم توصیه‌گر است که به شکل آنلاین قابل‌دسترسی است[1]. مجموعه داده‌ای شامل رتبه‌بندی‌ها و برچسب‌های عددی است که بر اساس رتبه‌های داده‌شده به فیلم‌های مختلف توسط کاربران یک سرویس توصیه‌کننده آنلاین فیلم جمع‌آوری‌شده است. در این مقاله ما از مجموعه داده ml-latest-small که یکی از نسخه‌های کم‌حجم 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 ایجادشده است. همه کاربران منتخب حداقل به ۲۰ فیلم امتیاز داده بودند. مجموعه‌داده، فاقد اطلاعات

[1] http://www.grouplens.org

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

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

۴-۱- ارزیابی رتبه‌های تعیین‌شده

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

الف) میانگین خطای مطلق

سنتی‌ترین 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 پیش‌بینی‌شده را با استفاده از رابطه (۲۱) اندازه‌گیری می کند.

$$MAE = \frac{\sum_{i=1}^{n}|Pr_i - Acr_i|}{N} \qquad (۲۱)$$

که Pr_i مقدار پیش‌بینی‌شده 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 خطا کمتر بوده و نتایج مطلوب‌تر است. شکل (۵) نتایج حاصل از این معیار را برای روش پیشنهادی و الگوریتم‌های ارائه شده در IBGR [31] 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 رتبه های تخمین زده شده اندازه‌گیری شود.

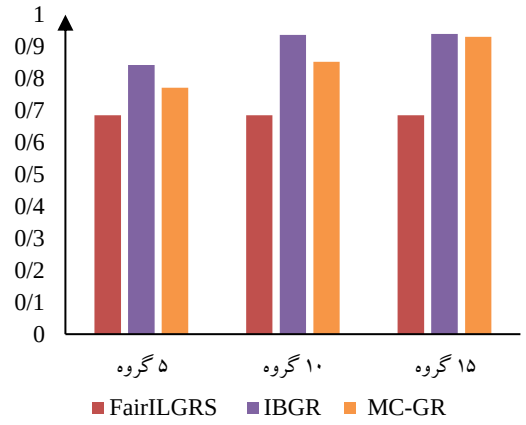

شکل ۵- مقایسه معیار میانگین خطای مطلق

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 خطا

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

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}|Pr_i - Acr_i|^2}{N}} \qquad (۲۲)$$

که Pr_i مقدار پیش‌بینی‌شده 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 خطا کمتر بوده و نتایج مطلوب‌تر است. شکل (۶) نتایج به دست آمده از محاسبه معیار ریشه میانگین مربعات خطا را برای سه روش FairILGRS، IBGR و MC-GR بر روی مجموعه داده نشان می‌دهد.

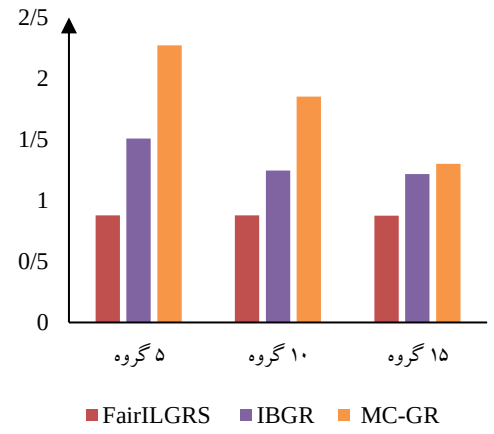

شکل ۶- مقایسه معیار ریشه میانگین مربعات خطا

مطابق با نتایج به‌دست‌آمده در شکل (۶)، براساس این معیار نیز روش پیشنهادی خطای کمتری را گزارش نموده است.

ج) دقت

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

$$Precision = 1 - \frac{\sum_{i=1}^{I} \frac{|Pr_i - Acr_i|}{\max(|Rmax - Acr_i|, |Rmin - Acr_i|)}}{I} \quad (۲۳)$$

که Pr_i مقدار پیش‌بینی شده توسط الگوریتم، Acr_i مقدار واقعی برای آیتم iام، $Rmax$ حداکثر مقدار رتبه، $Rmin$ حداقل مقدار رتبه و I نیز تعداد کل آیتم‌هاست. 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.

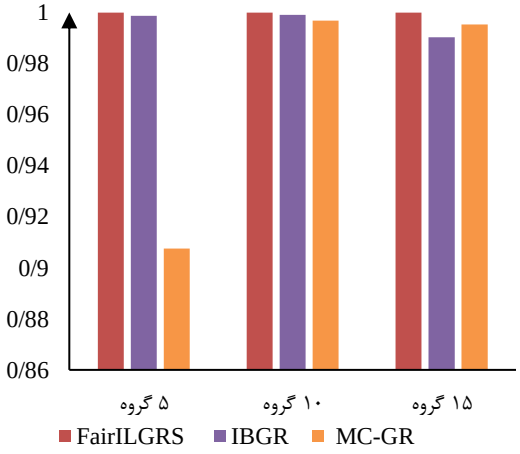

شکل ۷- مقایسه معیار دقت

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 برهم 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- ارزیابی توصیه‌ها

در این بخش به بررسی توصیه‌های داده شده به کاربران پرداخته و مشخص می‌شود که استراتژی تجمیع 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]، Group Collaborative Filtering (GCF) [۳۵]، Aggregating-top-list (ATL) [۲۸]، Fairness Package [۳۰] و همچنین AwU [۳۲] روش‌های تجمیع ضرب رتبه‌های تخصیص داده شده به آیتم‌ها (MUL)، رای‌گیری (PLU) و پایین‌ترین رتبه (LMS) که در فصل یک عنوان شدند، مقایسه نموده‌ایم. برای این منظور از معیارهای سود تجمعی تنزیل‌شده 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 $p_1, \dots, p_l$ لیست رتبه‌بندی شده از آیتم‌ها برای توصیه به گروه داشته باشیم؛ u یک کاربر و r_{upi} امتیاز او به آیتم i است. براین اساس، معیار DCG و nDCG از رابطه (۲۴) محاسبه می‌شود [1]:

$$DCG_k^u = r_{up1} + \sum_{i=2}^{k} \frac{r_{upi}}{\log_2(i)}$$
$$nDOG_k^u = \frac{DCG_k^u}{IDCG_k^u} \quad (۲۴)$$

مقدار $IDCG_k^u$ حداکثر مقدار DCG است که برای کاربر u به‌دست‌آمده است. معیار ذکر شده، میزان مناسب بودن

توصیه‌ها را نشان می‌دهد. این معیار، برای هر کاربر به طور مجزا، بررسی می‌کند 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 روش‌ها مورد مقایسه، با تعداد گروه‌های ۵، ۱۰ و ۱۵ و همچنین تعداد توصیه‌های ۱، ۵، ۱۰، ۱۵ و ۲۰ نشان می‌دهد.

جدول ۳- نتایج به‌دست‌آمده از معیار nDOG با یک توصیه

15	10	5	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 به‌دست‌آمده از معیار nDOG با ۵ توصیه

15	10	5	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 ۵- نتایج به‌دست‌آمده از معیار nDOG با ۱۰ توصیه

15	10	5	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 به‌دست‌آمده از معیار nDOG با ۱۵ توصیه

15	10	5	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

جدول ۷- نتایج به‌دست‌آمده از معیار nDOG با ۲۰ توصیه

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

بر اساس نتایج نشان‌داده‌شده 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 ارائه‌شده به گروه‌ها، استفاده می‌شود و طی آن سعی می‌شود تا میزان رضایت گروه‌ها را بر اساس هر عضو بسنجد. رضایت گروهی را می توان با رابطه (۲۵) تخمین زد.

$$GSM_{G_g} = \frac{\sum_{u \in G_g} I_u^s \cap I_R}{N_{G_g} * N_{I_R}} \qquad (۲۵)$$

در معادله فوق، I_u^s نشان‌دهنده آیتم‌هایی است که کاربر u به آن‌ها رتبه‌ای بالاتر از $0.5 \times \text{Rmax}$ است. I_R مجموعه آیتم‌های توصیه‌شده 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 درحقیقت 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.

جدول ۸- نتایج به‌دست‌آمده از معیار GSM با یک توصیه

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

جدول ۹- نتایج به‌دست‌آمده از معیار GSM با ۵ توصیه

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

جدول ۱۰- نتایج به‌دست‌آمده از معیار GSM با ۱۰ توصیه

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

جدول ۱۱- نتایج به‌دست‌آمده از معیار GSM با ۱۵ توصیه

نام الگوریتم / تعداد گروه	5	10	15
IBGR	0.5743	0.5462	0.4134
PLU	0.0444	0.0286	0.0281
MUL	0.5438	0.4809	0.4730
LMS	0.5088	0.5539	0.4629
MC-GR	0.5657	0.5545	0.3213
GCF	0.5263	0.5174	0.5680
ATL	0.5088	0.5539	0.5629
Fairness Package	0.5728	0.5631	0.5191
AwU	**0.6070**	0.5911	0.5646
FairILGRS	0.5877	**0.5920**	**0.5872**

جدول ۱۲- نتایج به‌دست‌آمده از معیار GSM با ۲۰ توصیه

نام الگوریتم / تعداد گروه	5	10	15
IBGR	0.5539	0.5210	0.5022
PLU	0.0473	0.0303	0.0278
MUL	0.5438	0.5743	0.4385
LMS	0.5088	0.4681	0.5214
MC-GR	0.5667	0.5576	0.5292
GCF	0.5263	0.5212	0.5799
ATL	**0.5888**	0.5681	0.5214
Fairness Package	0.5673	0.5490	0.5435
AwU	0.5767	0.5741	**0.5812**
FairILGRS	0.5809	**0.5862**	0.5775

پ) عادلانه بودن توصیه:

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

$$fairness_{package}(g) = \frac{|g_N|}{|g|} \qquad (۲۶)$$

در رابطه (۲۶)، $|g_N|$ تعداد اعضایی از گروه را نشان می‌دهد که حداقل به m آیتم از مجموعه آیتم‌های توصیه شده، علاقه داشتند. $|g|$ نشان دهنده تعداد همه اعضای گروه است. در اینجا، بسته به اندازه توصیه‌ها، مقدار m را به‌صورت زیر در نظر می‌گیریم:

$$m = \left\lceil \frac{recommend_package}{5} \right\rceil \qquad (۲۷)$$

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

جدول ۱۳- نتایج به‌دست‌آمده از معیار عادلانه بودن با یک توصیه

نام الگوریتم / تعداد گروه	5	10	15
IBGR	0.5101	0.5210	0.5667
PLU	0.2299	0.3234	0.3279
MUL	0.2585	0.3252	0.4248
LMS	0.2227	0.3474	0.3721
MC-GR	0.4464	0.4596	0.4861
GCF	0.4305	0.4443	0.4659
ATL	0.3324	0.5440	0.5720
Fairness Package	0.4045	0.5210	0.5467
AwU	0.6279	0.6247	0.5990
FairILGRS	**0.6438**	**0.6360**	**0.7011**

جدول ۱۴- نتایج به‌دست‌آمده از معیار عادلانه بودن با ۵ توصیه

نام الگوریتم / تعداد گروه	5	10	15
IBGR	0.5686	0.5981	0.5227
PLU	0.3695	0.2573	0.2607
MUL	0.3438	0.3695	0.4174
LMS	0.4088	0.3384	0.3279
MC-GR	0.5477	0.5318	0.4980
GCF	0.5425	0.5153	0.4918
ATL	0.5857	0.5798	0.5814
Fairness Package	0.5712	0.5657	0.5585
AwU	**0.6945**	**0.6870**	0.6639
FairILGRS	0.6685	0.6549	**0.7244**

جدول ۱۵- نتایج به‌دست‌آمده از معیار عادلانه بودن با ۱۰ توصیه

تعداد گروه / نام الگوریتم	5	10	15
IBGR	0.4931	0.4562	0.5560
PLU	0.2690	0.1545	0.3667
MUL	0.3438	0.4320	0.3384
LMS	0.3524	0.5373	0.3629
MC-GR	0.4537	0.4434	0.4897
GCF	0.4438	0.4402	0.4731
ATL	0.5375	0.5389	0.5747
Fairness Package	0.5110	0.5146	0.5501
AwU	0.5361	0.5606	0.5253
FairILGRS	**0.6172**	**0.6170**	**0.6265**

جدول ۱۶- نتایج به‌دست‌آمده از معیار عادلانه بودن با ۱۵ توصیه

تعداد گروه / نام الگوریتم	5	10	15
IBGR	0.4193	0.6861	0.5078
PLU	0.2299	0.3227	0.3168
MUL	0.5438	0.4438	0.4193
LMS	0.5088	0.4562	0.4269
MC-GR	0.5237	0.5918	0.5776
GCF	0.5248	0.5432	0.6700
ATL	0.5253	0.5518	**0.6709**
Fairness Package	0.5957	**0.6307**	0.6454
AwU	0.5976	0.6207	0.6398
FairILGRS	**0.6046**	0.6070	0.6124

جدول ۱۷- نتایج به‌دست‌آمده از معیار عادلانه بودن با ۲۰ توصیه

تعداد گروه / نام الگوریتم	5	10	15
IBGR	0.3308	0.5210	0.4913
PLU	0.2690	0.3823	0.3274
MUL	0.3438	0.4360	0.3730
LMS	0.4088	0.4017	0.4629
MC-GR	**0.6881**	0.6624	0.5422
GCF	0.5774	0.5227	0.6050
ATL	0.6295	0.5807	0.5708
Fairness Package	0.5260	**0.6669**	0.6702
AwU	0.6744	0.6690	**0.6713**
FairILGRS	0.6008	0.6052	0.6099

معیار ذکر شده، عادلانه بودن توصیه‌ها را در نظر می‌گیرد. درواقع برای هر کاربر بررسی می‌کند که در هر بسته توصیه شده چند آیتم مورد علاقه آن کاربر بوده است. در صورتی‌که تعداد این آیتم‌ها از حد آستانه بیشتر باشد، یعنی رضایت آن کاربر برآورده شده است. در غیر این صورت، کاربر ناراضی خواهد بو. 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 رتبه‌نهایی داده شده به آیتم توسط یک کاربر توجه می‌شد. اما در استراتژی پیشنهادی، رتبه-های 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 برعکس، کاربرانی که آسان گیر بوده و به همه آیتم‌ها رتبه‌های بالا می‌دهند، روی آیتم(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 سخت گیر 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 برعکس.

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 بیشتردر نظر گرفته می‌شود. علاوه بر این هدف دیگر روش

پیشنهادی این است که تأثیر افراد موجود در گروه، به‌طور مناسب اندازه‌گیری و تعیین شود. برای رسیدن به این اهداف، الگوریتمی ارائه دادیم که دارای پنج فاز اصلی است. فاز اول آماده‌سازی مجموعه داده می‌باشد که در آن به منظور تخمین رتبه‌های از دست رفته یا بدون مقدار از روش فاکتورسازی ماتریسی استفاده شده است. بعد از به دست آوردن رتبه‌های از دست رفته، اقدام به گروه‌بندی کاربران با استفاده از K-means می‌شود. در فاز دوم تأثیر هر عضو بر سایر اعضای گروه محاسبه می‌شود. برای این کار از ترکیب معیار شباهت، معیار اعتماد و معیار تعلق استفاده می‌شود. در فاز سوم در این فاز برای هر گروه، یک رهبر در نظر گرفته می‌شود. فردی که در گروه بیشترین مقدار را در معیارهای شباهت، اعتماد و تعلق کسب کند، به‌عنوان رهبر در نظر گرفته می‌شود. فرد رهبر، دارای تاثیرگذاری بیشتری نسبت به سایرین است. البته، خود نیز از سایر افراد در گروه می‌تواند تأثیر بگیرد. در فاز چهارم رتبه هر یک از کاربران با توجه به میزان تأثیرپذیری از دیگر افراد موجود در گروه، محاسبه می‌شود و در نهایت در فاز آخر توصیه‌ای که عادلانه و منصفانه باشد، به کاربران داده می‌شود.

در ادامه الگوریتم پیشنهادی از دو جنبه، مورد ارزیابی قرارگرفت. جنبه اول به ارزیابی تخمین رتبه‌ها با توجه به تاثیرگذاری رتبه‌ها پرداخته که طی آن از معیارهای میانگین خطای مطلق، ریشه میانگین مربعات خطا و دقت استفاده شده است. بر اساس نتایج به‌دست‌آمده، الگوریتم پیشنهادی توانسته است عملکرد بهتر و مطلوب‌تری را کسب کند. براساس معیار میانگین خطای مطلق و معیار ریشه میانگین مربعات خطا، 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 درنتیجه این معیار را برای هر سه می‌توان برابر در نظر گرفت. دلیل کسب این نتایج را می‌توان ناشی از نحوه محاسبه تاثیر کاربران برهم دانست. الگوریتم پیشنهادی سعی کرده است تا حفظ رتبه‌های اصلی کاربران داشته و تلاش می‌کند تا تاثیر کاربران و رهبر را به‌طور معقولانه‌تری بر رتبه کاربر اعمال کند.

در معیار سود تجمعی تنزیل‌شده 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، 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 رتبه-های پایینی به آیتم‌ها می‌دهند، و یا برعکس، کاربرانی که آسان گیر بوده و به همه آیتم‌ها رتبه‌های بالا می‌دهند، روی آیتم(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 استراتژی های 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 برعکس.

هرچند نتایج حاصل از این پژوهش مطلوب است اما هنوز چالش‌ها و مواردی وجود دارد که رسیدگی به آن می‌تواند سبب کاربردی‌تر شدن الگوریتم پیشنهادی گردد. الگوریتم پیشنهادی بر روی مجموعه داده‌های معمولی و سنتی کار می‌کند و گروه را بر اساس روش‌های ضمنی پیدا می‌کند. برای رسیدن به عملکرد بهتر می‌توان الگوریتم پیشنهادی را بر روی مجموعه داده‌های صریح که در آن گروه‌ها از پیش تعیین‌شده هستند نیز اجرا کرده و نتایج آن را بررسی نمود. همچنین در مرحله آماده‌سازی، تنها از فاکتورسازی ماتریس، استفاده شده است. با استفاده از اطلاعات اضافی می‌توان، عملکرد تخمین رتبه‌های از دست رفته را بهبود داد و پیش‌بینی‌ها و تخمین‌های دقیق‌تری را مشخص نمود. علاوه بر این استفاده از بازخوردهای کاربران نسبت به یک توصیه، می‌تواند عملکرد این سیستم‌ها را ارتقا بخشد. لذا تخمین و پیش‌بینی بازخورد کاربران نسبت به آیتم‌های توصیه‌شده موضوعی دیگر است که در این زمینه مطرح است.

مراجع

[1] L. Baltrunas, T. Makcinskas, and F. Ricci. "Group recommendations with rank aggregation and collaborative filtering." *In Proceedings of the fourth ACM conference on Recommender systems*, pp. 119-126. 2010.

[2] P. Nagaraj, and P. Deepalakshmi. "An intelligent fuzzy inference rule-based expert recommendation system for predictive diabetes diagnosis." *International Journal of Imaging Systems and Technology* 32, no. 4 (2022): 1373-1396.

[3] Le. Gamidullaeva, A. Finogeev, M. Kataev, and L. Bulysheva. "A design concept for a tourism recommender system for regional development." *Algorithms* 16, no. 1 (2023): 58.

[4] A. Poulose, A.P. Valappil, and J. Sebastian. "Medication recommender system for healthcare solutions." *Journal of Information and Optimization Sciences* 43, no. 5 (2022): 1073-1080.

[5] W.K. Cheng, W.C. Leong, J.S. Tan, Z.W. Hong, and Y.L. Chen. "Affective recommender system for pet social network." *Sensors* 22, no. 18 (2022): 6759.

[6] R.K. Patel, K. Aparna, S. Tanwar, W.C. Hong, and R. Sharma. "AI-empowered recommender system for renewable energy harvesting in smart grid system." *IEEE Access* 10 (2022): 24316-24326..

[7] R. Burke, A. Felfernig, and M.H. Göker. "Recommender systems: An overview." *Ai Magazine* 32, no. 3 (2011): 13-18.

[8] R. Burke. "Hybrid recommender systems: Survey and experiments." *User modeling and user-adapted interaction* 12 (2002): 331-370.

[9] S. Dara, C.R. Chowdary, and C. Kumar. "A survey on group recommender systems." *Journal of Intelligent Information Systems* 54, no. 2 (2020): 271-295.

[10] S. Zhang, L. Yao, A. Sun, and Y. Tay. "Deep learning based recommender system: A survey and new perspectives." *ACM computing surveys (CSUR)* 52, no. 1 (2019): 1-38.

[11] V.R. Yannam, J. Kumar, K.S. Babu, and B. Sahoo. "Improving group recommendation using deep collaborative filtering approach." *International Journal of Information Technology* 15, no. 3 (2023): 1489-1497.

[12] A. Delic, J. Neidhardt, T.N. Nguyen, and F. Ricci. "An observational user study for group recommender systems in the tourism domain." *Information Technology & Tourism* 19 (2018): 87-116.

[13] A. Delic, J. Neidhardt, T.N. Nguyen, and F. Ricci. "Research Methods for Group Recommender System." *In RecTour@ RecSys*, pp. 30-37. 2016.

[14] J. Masthoff. "Group recommender systems: aggregation, satisfaction and group attributes." *recommender systems handbook* (2015): 743-776.

[15] L. Xiao, Z. Min, Z. Yongfeng, G. Zhaoquan, L. Yiqun, and M. Shaoping. "Fairness-aware group recommendation with pareto-efficiency." *In Proceedings of the eleventh ACM conference on recommender systems*, pp. 107-115. 2017.

[16] A. Jameson, and B. Smyth. "Recommendation to groups." *In The adaptive web: methods and strategies of web personalization*, pp. 596-627. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007.

[17] D. Sacharidis. "Top-n group recommendations with fairness." *In Proceedings of the 34th ACM/SIGAPP symposium on applied computing*, pp. 1663-1670. 2019.

[18] S. Berkovsky, and J. Freyne. "Group-based recipe recommendations: analysis of data aggregation strategies." *In Proceedings of the fourth ACM conference on Recommender systems*, pp. 111-118. 2010.

[19] V.R. Kagita, A.K. Pujari, and V. 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, pp. 434-440. Springer International Publishing, 2013.

[20] J. Masthoff. "Group recommender systems: Combining individual models." *In Recommender systems handbook*, pp. 677-702. Boston, MA: Springer US, 2010.

[21] A. Felfernig, L. Boratto, M. Stettinger, and M. Tkalčič, eds. Group recommender systems: an introduction. Cham: Springer, 2024.

[22] J. 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] C. Senot, D. Kostadinov, M. Bouzid, J. Picault, and A. Aghasaryan. "Evaluation of group profiling strategies." *In Twenty-Second International Joint Conference on Artificial Intelligence*. 2011.

[24] F. Brandt, V. Conitzer, and U. Endriss. "Computational social choice." *Multiagent systems* 2 (2012): 213-284.

[25] M. Stettinger. "Choicla: Towards domain-independent decision support for groups of users." *In Proceedings of the 8th ACM Conference on Recommender systems*, pp. 425-428. 2014.

[26] L. Xiao, and G. 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, pp. 458-466. Springer International Publishing, 2017.

[27] M. O'connor, D. Cosley, J.A. Konstan, and J. Riedl. "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, pp. 199-218. Springer Netherlands, 2001.

[28] S. Ben Abdrabbah, M. Ayadi, R. Ayachi, and N. Ben Amor. "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, pp. 325-334. Springer International Publishing, 2017.

[29] Y. Xiao, Q. Pei, L. Yao, S. Yu, L. Bai, and X. Wang. "An enhanced probabilistic fairness-aware group recommendation by incorporating social activeness." *Journal of Network and Computer Applications* 156 (2020): 102579.

[30] D. Serbos, S. Qi, N. Mamoulis, E. Pitoura, and P. Tsaparas. "Fairness in package-to-group recommendations." *In Proceedings of the 26th international conference on world wide web*, pp. 371-379. 2017.

[31] R.B. Nozari, and H. Koohi. "A novel group recommender system based on members' influence and leader impact." Knowledge-Based Systems 205 (2020): 106296.

[32] E. Yalcin, Fi. Ismailoglu, and A. Bilge. "An entropy empowered hybridized aggregation technique for group recommender systems." *Expert Systems with Applications* 166 (2021): 114111.

[33] A. Pujahari, and D.S. Sisodia. "Preference relation based collaborative filtering with graph aggregation for group recommender system." *Applied Intelligence* 51 (2021): 658-672.

[34] W.Wang, G. Zhang, and J. Lu. "Member contribution-based group recommender system." *Decision Support Systems* 87 (2016): 80-93.

[35] A.F. Da Costa , M.G. Manzato, and R.J. 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*, pp. 279-286. 2016.

[36] R. Abolghasemi, P. Engelstad, E. Herrera-Viedma, and A. Yazidi. "A personality-aware group recommendation system based on pairwise preferences." *Information Sciences* 595 (2022): 1-17.

[37] B. Walek, and P. Fajmon. "A hybrid recommender system for an online store using a fuzzy expert system." *Expert Systems with Applications* 212 (2023): 118565.

[38] V.R. Yannam, J. Kumar, K.S. Babu, and B.K. Patra. "Enhancing the accuracy of group recommendation using slope one." *The journal of supercomputing* 79, no. 1 (2023): 499-540.

[39] J.a Kumar, V.R. Yannam, H. Prajapati, B. Sahoo, and K.S. Babu. "Improve the recommendation using hybrid tendency and user trust." *International Journal of Information Technology* 15, no. 6 (2023): 3147-3156..

[40] Y. Koren, R. Bell, and C. Volinsky. "Matrix factorization techniques for recommender systems." *Computer* 42, no. 8 (2009): 30-37.