



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

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

مصطفی سبزه کار^{۱*} و بنت الهدی مؤذنی^۲

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۲/۰۵/۱۰	در یک سیستم توصیه گر گروهی تلاش می شود ارائه توصیه به گروهی از افراد به جای یک فرد صورت پذیرد. در این سیستمها نظرات تمام اعضای گروه در تصمیم گیری مؤثر بوده و سعی می شود تا با وجود متفاوت بودن ترجیحات شخصی، بهترین انتخاب فراهم آید. این مقاله، سعی در ارائه یک سیستم توصیه گر گروهی دارد که بتواند ارتباط بین کاربران و در نهایت 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 می شود که با توجه به میزان اعتماد، شباهت و تعلق و وابستگی کاربران به گروه، رهبر آن گروه را مشخص نماید. علاوه، معیار جدیدی برای ارائه توصیه عادلانه به گروه ارائه شده که با استفاده از آن آیت‌هایی 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.
بازنگری مقاله: ۱۴۰۲/۰۹/۱۸	
پذیرش مقاله: ۱۴۰۲/۰۹/۲۲	
واژگان کلیدی: سیستم توصیه گر گروهی، عدالت، تابع تجمیع.	

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 توصیه گر می توان به استفاده آن در تشخیص‌های پزشکی مانند دیابت [۲]، گردشگری [۳]، مراقبت از سلامت [۴]، شبکه‌های اجتماعی [۵]، انرژی‌های تجدیدپذیر [۶] و... اشاره نمود. از ابتدای پیدایش سیستم‌های توصیه گر، تعاریف مختلفی برای آن ارائه شده است. در سال ۱۹۹۷، رسنیک و وارین

۱- مقدمه

سیستم‌های توصیه گر ابزارهای نرم‌افزاری هستند که مجموعه‌ای از آیت‌ها را در حوزه‌های مختلف، مطابق با سلیقه و ترجیحات کاربر انتخاب و پیشنهاد می‌نمایند. آیت‌های پیشنهادی، می‌تواند در مورد مسائل مختلف مانند خرید کالا، گوش دادن به موسیقی یا نمایش اخبار آنلاین باشد. با پیشرفت روزافزون فناوری اطلاعات، سیستم‌های توصیه گر 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، 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


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 در گذشته 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 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 علایق مشابه در یک گروه باعث توصیه‌های گروهی مؤثرتری می‌شود.

استراتژی‌های مورد استفاده 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 سابقه‌ای 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 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 (به طوری که $u: C \times S \Rightarrow R$ 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 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 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

² Aggregation Strategies


وجود ندارد [۱۵]. فارغ از نوع گروه، رویکردهای توصیه گروهی باید توصیه-ای را برای گروه ارائه دهند که نمایانگر علاقه‌مندی‌های تمام اعضای گروه باشد. در نتیجه 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 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 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 می‌گیرد. این استراتژی به‌عنوان تجمیع مدل‌ها نیز شناخته می‌شود [۱۸ و ۱۹]. شکل (۲) استراتژی مربوط به این رویکرد را نشان می‌دهد.



شکل ۳- رویکرد مبتنی بر یکپارچه‌سازی توصیه‌ها

یک چالش مهم در تمام سناریوهای توصیه گروه، چگونگی سازگار کردن گروه به‌عنوان 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. 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



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 می‌شود. 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. در نهایت

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 توصیه‌شده، 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 بگیرند [۲۰ و ۲۳]. توابع تجمیع خط مرزی، مکانیزم‌های تجمیعی را شامل می‌شوند که فقط زیرمجموعه‌ای از

جدول ۱- توابع تجمیع استفاده شده در منابع

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

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^۶ 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 آیت‌ها از کاربران مختلف در قالب K لیست برتر است. این سیستم، از دو مرحله تشکیل شده 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 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 تهیه یک لیست رتبه‌بندی استفاده کرده تا برای هر عضو گروه تا حد ممکن، توصیه، عادلانه باشد.

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^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 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 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 حسادت^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 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

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 خوشه-بندی 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 استفاده شده است. این پژوهش، برای تشکیل گروه از ترجیحات مشترک بین اعضا استفاده کرده است. سپس یک گراف ترجیحات جهت‌دار برای تعیین رتبه‌بندی آیت‌ها توسط گروه کاربران استفاده شده که از آن برای تعیین وزن هر کاربر به آیت‌ها و در نهایت وزن گروه کاربران به یک آیت‌ها 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 مبتنی بر فاصله منتهن 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 آیت‌های 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 آیت‌ها 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.

نویسندگان در [۳۰] تلاش در ارائه یک سیستم توصیه‌گر گروه نمودند تا بتواند یک آیت‌ها یا بسته‌ای از آیت‌ها را به‌طور عادلانه به یک گروه از کاربران تخصیص دهند. این مطالعه دو رویکرد مختلف ارائه داده است. در رویکرد نخست ابتدا احتمال انتخاب آیت i توسط گروه u محاسبه شده سپس، احتمال‌های به‌دست آمده برای هر آیت‌ها بهم ترکیب شده تا احتمال بسته محاسبه شود. در این مدل فرض می‌شود آیت‌ها مستقل از هم هستند. در مدل دوم با فرض وابسته بودن آیت‌ها، ابتدا گروه با یک احتمال یکی از کاربران را به‌عنوان نماینده انتخاب می‌کند. این کاربر برای همه آیت‌ها تصمیم‌گیری می‌کند و آیت‌ها را انتخاب می‌کند. سپس احتمال اینکه آیت 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 قرار گرفته که در آن حداقل مطلوبیتی که عضو گروه دریافت می‌کند، به‌عنوان عدالت شناخته می‌شود. این مطالعه از مفهوم بهینگی پرتو^۱ استفاده نموده و آیت‌ها یا مجموعه آیت‌های 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. در نهایت بعد از تعیین میزان تأثیر رهبر و هر عضو در گروه، رتبه هر آیت‌ها 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 آیت‌های موردعلاقه 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 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 توصیه‌گر خود ترکیبی از سه زیرسیستم از نوع فیلتر مشارکتی، مبتنی بر محتوا و مبتنی بر دانش می‌باشد. این پژوهش به دلیل 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 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 مؤثر بودن 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 در نظر گرفتن مفاهیمی همچون عدالت، میزان رضایت کاربران از توصیه
[۳۲]	۲۰۲۱	نقاط قوت: - ساده بودن عملیات توصیه نقاط ضعف:

<p>– عدم توجه به تأثیر کاربران بر تصمیمات هم</p>		
<p>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: – زمان بر بودن تولید گراف ترجیحات برای هر کاربر و در نتیجه زمان بر بودن تعیین رتبه آیتم‌ها برای گروه</p>	۲۰۲۱	[۳۳]
<p>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</p>	۲۰۱۶	MC-GR [۳۴]
<p>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</p>	۲۰۱۶	Group-based Collaborative Filtering [۳۵]
<p>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 در نظر گرفتن ویژگی‌های شخصی‌تی کاربران درحالی‌که ممکن است کاربری تغییر نگرش دهد</p>	۲۰۲۲	[۳۶]
<p>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</p>	۲۰۲۳	[۳۷]
<p>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</p>	۲۰۲۳	[۳۸]
<p>نقاط قوت: – افزودن مفهوم اعتماد به سیستم توصیه‌گر گروهی</p>	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 رتبه‌ها و اطلاعات

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 سیستم‌های توصیه‌گر است. این استراتژی‌ها اغلب بازخورد تصمیمات قبلی را در نظر نمی‌گیرند. دوم اینکه اغلب

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

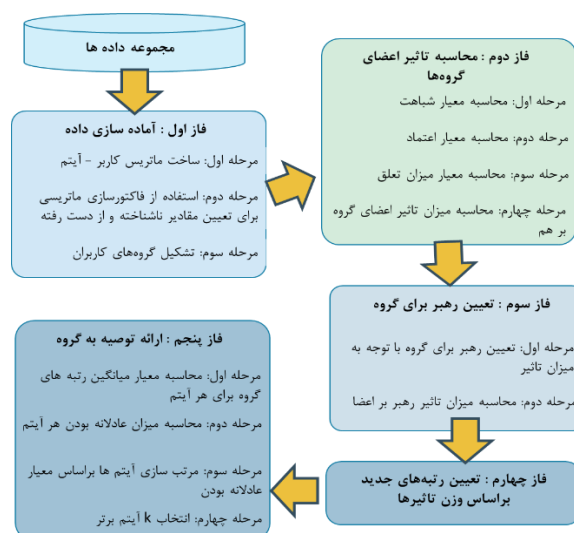
$$\text{user-item} \begin{bmatrix} r_{1,1} & r_{1,2} & r_{1,3} & \dots & r_{1,n} \\ r_{2,1} & r_{2,2} & r_{2,3} & \dots & r_{2,n} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ r_{m,1} & r_{m,2} & r_{m,3} & \dots & r_{m,n} \end{bmatrix} \quad (1)$$

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 داده‌شده 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 توصیه‌گر 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 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 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 تفصیل شرح می‌دهیم.



شکل ۴- روش کلی الگوریتم پیشنهادی FairLGRS

۳-۱- فاز اول: آماده‌سازی مجموعه داده

¹ Matrix factorization

گروه‌های کارمندان در مجموعه داده 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 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. با توجه به جدید بودن حیطه سیستم‌های توصیه‌گر، در اغلب موارد و تحقیقات، مجموعه داده‌ها 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 به اندازه‌ای از پیش تعیین شده، K گروه به عنوان مرکز خوشه انتخاب می‌شود. در اینجا، تعداد گروه-ها متناسب با مجموعه داده مشخص خواهد شد. سپس با توجه به میزان شباهت سایر گروه‌ها با مراکز خوشه، هر گروه به یک خوشه تخصیص می‌یابد. به منظور اندازه‌گیری شباهت کاربران از رابطه (۵) استفاده می‌شود [۳۱]:

$$similarity_{u,v} = \frac{(\sum_{i \in I} (r_{u,i} - \bar{r}_u)(r_{v,i} - \bar{r}_v))}{\sqrt{\sum_{i \in I} (r_{u,i} - \bar{r}_u)^2} \sqrt{\sum_{i \in I} (r_{v,i} - \bar{r}_v)^2}} \quad (5)$$

در رابطه فوق، $r_{u,i}$ رتبه کاربر u به آیت i است. \bar{r}_u نیز به میانگین رتبه‌هایی که کاربر u به همه آیت‌ها داده است، اشاره دارد. به طور مشابه $r_{v,i}$ رتبه کاربر v به آیت i است و \bar{r}_v میانگین رتبه‌هایی است که کاربر v به همه آیت‌ها داده است. عملیات انتخاب گروه و تشکیل خوشه، به تعداد تکرار معین انجام شده و در نهایت بهترین خوشه، به عنوان خوشه-های نهایی انتخاب می‌شوند.

۳-۲- فاز دوم: محاسبه‌ی تاثیر اعضای گروه

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

ورودی‌های مجهول در ماتریس اصلی کاربر-آیت 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.

$$R = W_1 W_2^T \quad (2)$$

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 آیت i را توصیف می‌کند، شامل می‌شود. فرض کنید که $W_{1,uk}$ و $W_{2,ik}$ در آیه‌ها و $W_{1,u}$ و $W_{2,i}$ به ترتیب بردارهای W_1 و W_2 باشند، رتبه r داده شده توسط کاربر u به آیت i با استفاده از رابطه‌ی (۳) پیش‌بینی می‌شود [۴۰]:

$$\hat{r}_{ui} = \sum_{k=1}^K W_{1,uk} W_{2,ik} = W_{1,u} W_{2,i}^T \quad (3)$$

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]:

$$O^{MF} = \sum_{(u,i) \in R} (R_{ui} - W_{1,u} W_{2,i}^T)^2 + \lambda (\|W_1\|_F^2 + \|W_2\|_F^2) \quad (4)$$

که در آن $\|W\|_F^2$ یک نرم فورینوس^۱ است و $0 < \lambda < 1$ یک عبارت منظم‌سازی است که مقداری بین صفر تا یک دارد و برای جلوگیری از بیش برآزش استفاده می‌شود. بعد از به دست آوردن رتبه‌های از دست‌رفته، 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 تعریف می‌شوند. برای مثال،

¹ Norm February

بودن علایق دو کاربر، می‌توان تعداد آیت‌ها موردعلاقه هر دو را مشخص کرد. برای این منظور، با فرض اینکه $r_{u,i}$ رتبه‌ای است که کاربر u به آیت i داده است، $categorize(r_{u,i})$ مطابق با رابطه (۷) مشخص می‌کند که آیت موردعلاقه کاربر بوده است یا خیر.

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

بعد از محاسبه آیت‌های موردعلاقه دو کاربر، با فرض اینکه $like_u$ و $like_v$ به ترتیب مجموعه آیت‌هایی باشند که کاربر u و کاربر v به آن‌ها علاقه داشته‌اند، می‌توان میزان اشتراک آیت‌ها 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]:

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

که $r_{u,i}$ و $r_{v,i}$ به ترتیب رتبه‌ای است که کاربر u و v به آیت i داده‌اند. $I_{u,v}$ نیز آیت‌هایی 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 به‌عنوان 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 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.

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

در سیستم توصیه‌گر، شباهت بین کاربران می‌تواند بر اساس رتبه‌ای که کاربران به هر آیت داده‌اند، محاسبه شود. بنابراین افرادی که به آیت‌های موجود رتبه یکسانی داده‌اند، سریع‌تر می‌توانند در مورد یک آیت 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 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 آیت با توجه به ترجیحات، وضعیت و علایق کاربر به او توصیه شود، یک کاربر مانند u زمانی می‌تواند به کاربر دیگر مانند v اعتماد کند که سلاقی 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) اندازه گیری کرد:

$$Weight_Inf_{u,v} = \frac{2 \times Trust_{v,u} \times similarity_{v,u} \times Dependency_u}{(Trust_{v,u} + similarity_{v,u} + Dependency_u)} \quad (14)$$

۳-۳- فاز سوم: تعیین رهبر برای هر گروه

رهبر برجسته ترین فرد در گروه های اجتماعی است. در فعالیت های گروهی، رهبر کسی است که اعضای گروه به او بیشترین اعتماد را داشته و تعلق بیشتری به گروه داشته باشد. علاوه بر این، رهبر می تواند نظرات مشابهی را برای اعضا ارائه دهد. از این رو، الگوریتم پیشنهادی، با توجه به سه معیار شباهت، تعلق به گروه و اعتماد، رهبر را تعیین می کند. در حقیقت کسی که بالاترین شباهت، سطح اعتماد و میزان تعلق را به گروه داشته باشد، به عنوان رهبر در نظر گرفته می شود. 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 می شود.

$$leader_{G_g} = \left\{ u: argmax \sum_{v \in G_g, v \neq u} similarity_{v,u} + Trust_{v,u} + Dependency_u \right\} \quad (15)$$

$$LeaderWeight_{Inf_{u,v}} = \frac{\sum_{L, u \in G_g, L \neq u} similarity_{u,L} + Trust_{v,u} + Dependency_u}{2 \times (N_{G_g} - 1)} \quad (16)$$

۳-۴- فاز چهارم: تعیین رتبه های جدید بر اساس

وزن تأثیرها

با توجه به تأثیری که یک کاربر می تواند بر کاربران دیگر بگذارد، رتبه های کاربران به آیتها تغییر می نماید. در این فاز رتبه ها بر اساس وزن تأثیر کاربران به روزرسانی می شوند. به منظور به روزرسانی رتبه های کاربران به هر آیت، مطابق رابطه (۱۷) عمل می شود.

$$new_{r_{u,i}} = r_{u,i} + \frac{\sum_{v=1}^{N_{G_g}} Weight_{Inf_{u,v}} \times (r_{v,i} - r_{u,i})}{|N_{G_g}|} \quad (17)$$

where $u, v \in G_g$

در این رابطه $Weight_{Inf_{u,v}}$ نشان دهنده میزان تأثیر کاربر v بر u است که از رابطه (۱۴) محاسبه می شود و اگر

نمی توان افراد تشکیل دهنده گره را مشخص کرد. اما می توان گفت کسانی که بیشترین تعلق را به یک گروه دارند، نسبت به سایر گروه ها گرایش کمتری دارند. این مفهوم، در خوشه بندی به عنوان شاخص نیم رخ^۱ مطرح است. شاخص نیم رخ، فاصله بین داده ها در خوشه های متفاوت را بررسی می کند و این هدف را دنبال می کند که خوشه نسبت داده شده به یک نمونه داده، تا چه میزان درست و مطلوب بوده است. این معیار به پیوستگی درون خوشه ها و به میزان تفکیک پذیری آن ها بستگی دارد. مقدار نیم رخ برای هر نقطه، میزان تعلق آن را به خوشه اش در مقایسه با خوشه مجاور اندازه می گیرد. به منظور محاسبه این معیار مطابق با رابطه (۱۱) ابتدا میزان شباهت یک کاربر مانند u به گروه تعیین می شود:

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

در رابطه فوق، $similarity_{u,v}$ میزان شباهت دو کاربر را نشان می دهد که مطابق با رابطه (۵) محاسبه می شود. $|C|$ تعداد اعضای گروه C است.

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

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

در رابطه (۱۲) نیز، $similarity_{u,v}$ شباهت دو کاربر u و v است، C_k گروه k ام را نشان می دهد. $|C_k|$ تعداد اعضای گروه است. در نهایت، مقدار نهایی معیار وابستگی به صورت رابطه (۱۳) محاسبه می شود:

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

هر چه مقدار $Dependency_u$ به یک نزدیک تر باشد، وابستگی بیشتر است. حال با ترکیب این مقادیر می توان

¹ Silhouette Index

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

$$average_{item}(i) = \frac{\sum_{u \in g} new_{rate_{u,i}}}{N_g}, i \in I \quad (20)$$

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

د) در گام چهارم، حاصل ضرب میانگین رتبه‌های کسب شده برای هر آیت ($average_{item}(i)$) در مجموع رتبه ($rank$) به دست آمده برای هر آیت محاسبه می‌گردد. در نهایت، آیت‌ها بر اساس این رتبه مرتب شده و k آیت 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. به منظور پیاده‌سازی الگوریتم پیشنهادی از زبان برنامه‌نویسی پایتون، در محیط Anaconda استفاده شده است. بر اساس بررسی‌ها و تحقیقات انجام شده، در اغلب تحقیقات، به منظور پیاده‌سازی و ارزیابی الگوریتم سیستم توصیه‌گر گروهی، از مجموعه داده‌های معمول در سیستم توصیه‌گر سنتی استفاده شده است و مجموعه داده مشخص و معینی باهدف سیستم توصیه‌گر گروهی تعیین نشده است. بر این اساس، ما از مجموعه داده MovieLens به منظور ارزیابی و پیاده‌سازی الگوریتم خود استفاده می‌کنیم. این مجموعه یکی از مجموعه داده‌های 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 توصیه‌کننده آنلاین فیلم جمع‌آوری شده است. در این مقاله ما از مجموعه داده ml-latest-small که یکی از نسخه‌های کم‌حجم از این مجموعه داده است، استفاده می‌کنیم. این مجموعه داده 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. مجموعه داده، فاقد اطلاعات

۷، 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 رتبه‌های کاربران گروه است. به همین منظور در این مقاله ترکیبی از استراتژی‌های تجمیع موجود مورد استفاده قرار گرفته به گونه‌ای که عدالت در توصیه‌ها، بیشینه شود. همچنین آیتمی که اکثر افراد از آن راضی باشند، به عنوان آیت 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 آیت‌ها 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 آیت داده‌اند مشخص می‌کند. در حالی که در این مقاله، میانگین رتبه‌هایی که یک کاربر به همه آیت‌ها 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.

$$average_user(u) = \frac{\sum_{i \in I} new_rate_{u,i}}{|I|} \quad (18)$$

که در این رابطه u یک کاربر و i یک آیت از مجموعه آیت‌ها یعنی I بوده و $new_rate_{u,i}$ رتبه‌ای است که کاربر u به آیت i داده و $|I|$ تعداد آیت‌های موجود برای توصیه می‌باشد.


ب) در گام دوم، برای هر کاربر آیت‌هایی که رتبه آن بیشتر از میانگین باشد، مشخص می‌شود. سپس آیت‌های بر اساس میانگین رتبه کاربر جدا می‌شوند. آیت‌هایی که بالاتر از میانگین رتبه کاربر باشند، به عنوان آیت قابل قبول و در غیر این صورت به عنوان آیت‌های غیر قابل قبول لحاظ می‌شوند.

$$rank(u, i) = |new_rate_{u,i} > average_user(u)| \quad (19)$$

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

¹ <http://www.grouplens.org>

روش پیشنهادی و الگوریتم‌های ارائه شده در [31] IBGR و [34] MC-GR 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 خطا

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

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

که Pr_i مقدار پیش‌بینی شده توسط الگوریتم و Acr_i مقدار واقعی برای آیت i ام و N نیز تعداد کل آیت‌ها است. هرچه 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.

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 اخیراً 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 آیت 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 مقیاس پذیر 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 خطا و دقت استفاده شده 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 آیت 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 Pr_i مقدار پیش‌بینی شده توسط الگوریتم و Acr_i مقدار واقعی برای آیت i ام است. N نیز تعداد کل آیت‌ها 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

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 [۳۱] IBGR، [۳۴] MC-GR، [۳۵] Collaborative Filtering (GCF)، [۲۸] Aggregating-top-list (ATL) Fairness، [۳۰] Package و همچنین [۳۲] AwU 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 تنزیل شده نرمال شده، رضایت گروهی و عدالت استفاده شده است.

الف) 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]:

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

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

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




شکل ۶- مقایسه معیار ریشه میانگین مربعات خطا

مطابق 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 منعکس شده و طبق رابطه (۲۳) محاسبه می‌شود.

$$Precision \quad (23) \\ = 1 - \frac{\sum_{i=1}^I \frac{|Pr_i - Act_i|}{\max(|Rmax - Act_i|, |Rmin - Act_i|)}}{I}$$

که Pr_i مقدار پیش‌بینی شده توسط الگوریتم، Act_i مقدار واقعی برای آیتم i ام، $Rmax$ 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، IBGR 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

تعداد گروه نام الگوریتم	5	10	15
IBGR	0.6214	0.3574	0.3595
PLU	0.5989	0.5221	0.4474
MUL	0.3227	0.4252	0.4279
LMS	0.4169	0.4234	0.3248
MC-GR	0.6150	0.6320	0.6899
GCF	0.6384	0.6507	0.6975
ATL	0.6983	0.6328	0.6850
Fairness Package	0.7171	0.6347	0.7243
AwU	0.7204	0.7347	0.7347
FairILGRS	0.7211	0.7211	0.7211

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

تعداد گروه نام الگوریتم	5	10	15
IBGR	0.3118	0.3522	0.3478
PLU	0.4022	0.5168	0.5438
MUL	0.3227	0.4252	0.4279
LMS	0.3169	0.3234	0.3248
MC-GR	0.6384	0.6044	0.4111
GCF	0.6451	0.6174	0.6269
ATL	0.6308	0.6226	0.6977
Fairness Package	0.6128	0.6344	0.6301
AwU	0.6471	0.6777	0.6823
FairILGRS	0.7201	0.7201	0.7201

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 رضایت مندی کاربران، مقدار این معیار محاسبه می‌گردد. 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 به دست آمده از معیار nDOG با یک توصیه

تعداد گروه نام الگوریتم	5	10	15
IBGR	0.4387	0.4328	0.4578
PLU	0.4493	0.4360	0.4293
MUL	0.5227	0.3252	0.3279
LMS	0.4169	0.3234	0.4248
MC-GR	0.5963	0.5949	0.5607
GCF	0.5787	0.5811	0.5711
ATL	0.5973	0.5998	0.5855
Fairness Package	0.6908	0.6919	0.6724
AwU	0.6512	0.6807	0.6854
FairILGRS	0.7230	0.7230	0.7230

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

تعداد گروه نام الگوریتم	5	10	15
IBGR	0.3450	0.3585	0.3721
PLU	0.3149	0.6085	0.6769
MUL	0.3279	0.5252	0.5227
LMS	0.4248	0.5234	0.5169
MC-GR	0.5558	0.5214	0.5722
GCF	0.6695	0.5336	0.5373
ATL	0.6834	0.5364	0.5421
Fairness Package	0.6696	0.6408	0.6505
AwU	0.6504	0.6784	0.6819
FairILGRS	0.7217	0.7217	0.7218

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

تعداد گروه	۵	۱۰	۱۵	نام الگوریتم
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 به دست آمده از معیار GSM با ۵ توصیه

تعداد گروه	۵	۱۰	۱۵	نام الگوریتم
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 به دست آمده از معیار GSM با ۱۰ توصیه

تعداد گروه	۵	۱۰	۱۵	نام الگوریتم
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 ۷- نتایج به دست آمده از معیار nDOG با ۲۰ توصیه

تعداد گروه	۵	۱۰	۱۵	نام الگوریتم
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 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.

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

در معادله فوق، I_u^S نشان دهنده آیت‌هایی است که کاربر u به آن‌ها رتبه‌ای بالاتر از $0.5 \times R_{max}$ است. I_R مجموعه آیت‌های توصیه شده به کاربر، N_{Gg} تعداد اعضای گروه و N_{I_R} تعداد آیت‌های توصیه شده به گروه است. هر چه مقدار این معیار بیشتر باشد، نشان دهنده مطلوب بودن عملکرد الگوریتم است. جداول ۸ تا ۱۲ نشان دهنده 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	تعداد گروه	تعداد گروه	نام الگوریتم
15	10	5	
0.5667	0.5210	0.5101	IBGR
0.3279	0.3234	0.2299	PLU
0.4248	0.3252	0.2585	MUL
0.3721	0.3474	0.2227	LMS
0.4861	0.4596	0.4464	MC-GR
0.4659	0.4443	0.4305	GCF
0.5720	0.5440	0.3324	ATL
0.5467	0.5210	0.4045	Fairness Package
0.5990	0.6247	0.6279	AwU
0.7011	0.6360	0.6438	FairILGRS

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

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

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

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

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

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

پ) عادلانه بودن توصیه:

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

$$\text{fairness}_{\text{package}}(g) = \frac{|g_N|}{|g|} \quad (26)$$

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

معیار ذکر شده، عادلانه بودن توصیه‌ها را در نظر می‌گیرد. در واقع برای هر کاربر بررسی 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 رتبه‌نهایی داده شده به آیتم توسط یک کاربر توجه می‌شد. 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 برعکس، کاربرانی که آسان‌گیر بوده و به همه آیتم‌ها رتبه‌های بالا می‌دهند، روی آیتم‌های (های) نهایی انتخاب شده برای گروه تأثیر 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 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 بیشتر در نظر گرفته می‌شود. علاوه بر این هدف دیگر روش

جدول ۱۵- نتایج به‌دست‌آمده از معیار عادلانه بودن با ۱۰

توصیه			تعداد گروه
15	10	5	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 به‌دست‌آمده از معیار عادلانه بودن با ۱۵

توصیه			تعداد گروه
15	10	5	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 به‌دست‌آمده از معیار عادلانه بودن با ۲۰

توصیه			تعداد گروه
15	10	5	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، رتبه‌های هر کاربر به طور مستقل مشخص شده و در نهایت آیت‌های مورد علاقه کاربر براساس میانگین رتبه‌های خود او مشخص می‌شود. این امر می‌تواند سبب شود تا کاربرانی که سخت‌گیر هستند و رتبه‌های پایینی به آیت‌ها می‌دهند، و یا برعکس، کاربرانی که آسان‌گیر بوده و به همه آیت‌ها رتبه‌های بالا می‌دهند، روی آیت‌ها (های) نهایی انتخاب شده برای گروه تاثیر کمتری داشته باشند. به عبارت بهتر، سعی می‌شود که برای گروه آیت‌هایی 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 آیت‌ها 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 تعیین شده 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 آیت‌های توصیه‌شده موضوعی دیگر است که در این زمینه مطرح است.

پیشنهادی این است که تأثیر افراد موجود در گروه، به طور 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، به عنوان 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 قرار گرفت. 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 به دست آمده، 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 در نتیجه 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 به طور معقولانه‌تری 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] Sabrina 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.