

یک سامانه پیشنهاددهنده اجتماعی مبتنی بر

تجزیه ماتریس با در نظر گرفتن

پویایی علایق کاربران

حمیدرضا طهماسبی^۱، مهرداد جلالی^{۲*}، حسن شاکری^۳

^۱ گروه مهندسی کامپیوتر، واحد کاشمر، دانشگاه آزاد اسلامی، کاشمر، ایران

^۲ و ^۳ گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

چکیده

در سال‌های اخیر، استفاده از سامانه‌های پیشنهاددهنده در شبکه‌های اجتماعی رشد قابل توجهی داشته است. در این سامانه‌ها، رفتار و علایق کاربران در طول زمان تغییر می‌کند و تطبیق سامانه‌های پیشنهاددهنده با این پویایی علایق و نیازهای کاربران به منظور ارائه پیشنهادات دقیق‌تر به کاربران ضروری است. علی‌رغم اهمیت این موضوع، اغلب سامانه‌های پیشنهاددهنده، رفتار پویای کاربر را در نظر نمی‌گیرند. در این مقاله، یک سامانه پیشنهاددهنده اجتماعی با در نظر گرفتن پویایی علایق کاربران ارائه می‌شود که از روش تجزیه ماتریس استفاده می‌کند. در مدل پیشنهادی با در نظر گرفتن این‌که هر کاربر الگوی تغییر علایق خاص خود را دارد، فرض می‌شود که علایق فعلی کاربر به علایق او در دوره زمانی قبلی بستگی دارد، و یک ماتریس انتقال علایق برای هر کاربر به منظور مدل کردن پویایی علایق کاربر بین دو دوره متوالی آموزش داده می‌شود و با ترکیب امتیازات کاربران و اعتماد بین آن‌ها بر اساس روش تجزیه ماتریس، امتیازات کاربران به اقلام پیش‌بینی می‌شود. ارزیابی‌ها بر روی مجموعه داده Epinions نشان می‌دهند که مدل پیشنهادی نسبت به روش‌های مقایسه‌شده، منجر به بهبود بیشتر دقت در پیش‌بینی امتیازات می‌شود. همچنین تحلیل پیچیدگی زمانی مدل پیشنهادی بیان‌گر مقیاس پذیر بودن این مدل است.

واژگان کلیدی: سامانه پیشنهاددهنده اجتماعی، پیش‌بینی امتیازات، پویایی علایق، تجزیه ماتریس، اعتماد.

A social recommender system based on matrix factorization considering dynamics of user preferences

Hamidreza Tahmasbi¹, Mehrdad Jalali^{2*}, Hassan Shakeri³

¹ Department of Computer Engineering, Kashmar Branch, Islamic Azad University, Kashmar, Iran

^{2,3} Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran

Abstract

With the expansion of social networks, the use of recommender systems in these networks has attracted considerable attention. Recommender systems have become an important tool for alleviating the information that overload problem of users by providing personalized recommendations to a user who might like based on past preferences or observed behavior about one or various items. In these systems, the users' behavior is dynamic and their preferences change over time for different reasons. The adaptability of recommender systems to capture the evolving user preferences, which are changing constantly, is essential.

Recent studies point out that the modeling and capturing the dynamics of user preferences lead to significant improvements in recommendation accuracy. In spite of the importance of this issue, only a few approaches recently proposed that take into account the dynamic behavior of the users in making recommendations. Most of these approaches are based on the matrix factorization scheme. However, most of them assume that the preference dynamics are homogeneous for all users, whereas the changes in user preferences may be individual and the time change pattern for each user differs. In addition, because the amount of numerical ratings dramatically reduced in a specific time period, the sparsity problem in these approaches is more intense. Exploiting social information such as the trust relations

* Corresponding author

* نویسنده عهده‌دار مکاتبات

between users besides the users' rating data can help to alleviate the sparsity problem. Although social information is also very sparse, especially in a time period, it is complementary to rating information. Some works use tensor factorization to capture user preference dynamics. Despite the success of these works, the processing and solving the tensor decomposition is hard and usually leads to very high computing costs in practice, especially when the tensor is large and sparse.

In this paper, considering that user preferences change individually over time, and based on the intuition that social influence can affect the users' preferences in a recommender system, a social recommender system is proposed. In this system, the users' rating information and social trust information are jointly factorized based on a matrix factorization scheme. Based on this scheme, each users and items is characterized by a sets of features indicating latent factors of the users and items in the system. In addition, it is assumed that user preferences change smoothly, and the user preferences in the current time period depend on his/her preferences in the previous time period. Therefore, the user dynamics are modeled into this framework by learning a transition matrix of user preferences between two consecutive time periods for each individual user. The complexity analysis implies that this system can be scaled to large datasets with millions of users and items. Moreover, the experimental results on a dataset from a popular product review website, Epinions, show that the proposed system performs better than competitive methods in terms of MAE and RMSE.

Keywords: Social recommender system, rating prediction, preference dynamics, matrix factorization, trust.

مسأله خلوتی داده‌ها^۳ است که مورد توجه بسیاری از پژوهش‌گران در سامانه‌های پیشنهاددهنده اجتماعی قرار گرفته است. مسأله خلوتی داده‌ها زمانی اتفاق می‌افتد که بیش‌تر کاربران تعداد بسیار کمی از اقلام را امتیاز داده‌اند [45] و یکی از محدودیت‌های ذاتی سیستم‌های پیشنهاددهنده به‌شمار می‌رود [4]. یک کاربر برای انتخاب یک قلم محصول، تمایل دارد از نظرات افرادی که به آن‌ها اعتماد دارد، استفاده کند؛ بنابراین روابط اعتماد بین کاربران در علایق آن‌ها تأثیرگذار بوده [20] و یک وابستگی قوی بین اعتماد و شباهت بین علایق کاربران وجود دارد [31].

با توجه به قابلیت پیش‌بینی و مقیاس‌پذیری خوب روش‌های تجزیه ماتریس^۴ [26]، در اغلب الگوریتم‌های سامانه‌های پیشنهاددهنده از این روش‌ها استفاده می‌شود. روش تجزیه ماتریس، ویژگی‌های پنهان کاربران و اقلام را از طریق تجزیه ماتریس امتیازات استخراج می‌کند؛ به‌طوری‌که برای هر یک از کاربران و هر یک از اقلام، یک بردار مجزا به‌ترتیب به‌نام‌های بردار ویژگی کاربر و بردار ویژگی قلم استنتاج و با ضرب داخلی هر زوج بردار ویژگی کاربر و قلم، پیش‌بینی امتیازات نامشخص انجام می‌شود. رفتار کاربران در سامانه‌های پیشنهاددهنده، پویا است؛ به‌طوری‌که تمایل کاربران به دامنه وسیعی از اقلام در طول زمان تغییر می‌کند. این رفتارهای کاربران فقط از علایق شخصی آن‌ها تأثیر نمی‌پذیرد، بلکه به‌طورمعمول به دلایلی از قبیل ورود اقلام جدید، تجربه قبلی استفاده کاربر از برخی اقلام، محبوبیت برخی اقلام، تغییر سن کاربر، موقعیت مکانی، تأثیر دوستان، محیط و افراد قابل اعتماد کاربر می‌تواند باشد.

۱- مقدمه

در دو دهه اخیر، با رشد سریع و متنوع اطلاعات در محیط وب، کاربران با چالش‌های جدیدی مواجه شده‌اند. یکی از این چالش‌های مهم، مشکل جستجو و پیمایش این حجم انبوه از اطلاعات و یافتن اطلاعات دلخواه توسط کاربران است که در بسیاری از موارد منجر به سردرگمی و تصمیم‌های اشتباه توسط آن‌ها می‌شود. این مشکل تحت عنوان مسأله سربار اطلاعاتی^۱ شناخته می‌شود. سامانه‌های پیشنهاددهنده^۲ به‌عنوان ابزاری ارزشمند، می‌توانند برای مقابله با مشکل سربار اطلاعاتی، مفید واقع شوند و در سال‌های اخیر، به‌طور چشم‌گیری مورد توجه قرار گرفته‌اند. این سامانه‌ها با تحلیل رفتار و خصوصیات کاربران، و فیلترکردن بخش قابل توجهی از اطلاعات [1]، می‌توانند فهرست اقلامی را که ممکن است مورد علاقه کاربر باشد به او پیشنهاد کنند و یا این‌که یک قلم محصول را که به چه میزان مورد علاقه یک کاربر خواهد بود، پیش‌بینی کنند. مهم‌ترین نوع اطلاعاتی که اغلب در این سامانه‌ها استفاده می‌شود، اطلاعات مربوط به امتیازاتی است که کاربران به اقلام می‌دهند و به آن ماتریس امتیازات گفته می‌شود.

با گسترش شبکه‌های اجتماعی، استفاده از سامانه‌های پیشنهاددهنده در این شبکه‌ها مورد توجه زیادی قرار گرفته است و در سال‌های اخیر، سامانه‌های پیشنهاددهنده اجتماعی، هم از نظر تعداد کاربران و هم میزان اطلاعاتی که به اشتراک می‌گذارند، رشد قابل توجهی داشته‌اند. اطلاعات مربوط به اعتماد بین کاربران در شبکه‌های اجتماعی، یک منبع با ارزش برای مقابله با

³ Data sparsity

⁴ Matrix Factorization

¹ Information Overload Problem

² Recommender Systems

با توجه به تغییر رفتار و علایق کاربران در طول زمان، حفظ دقت، همراه با برآورده کردن نیازهای در حال تغییر کاربران مشکل و یکی از چالش‌های اساسی در سیستم‌های پیشنهاددهنده، ایجاد مدلی دقیق با توجه به تغییر علایق کاربران در طول زمان است [16, 24]. مدل کردن پویایی زمانی علایق کاربران در این سامانه‌ها، خود با چالش‌هایی از قبیل چگونگی مشارکت بعد زمان و استخراج تغییر علایق در دوره‌های زمانی مختلف، و مدل کردن این نوع تغییرات برای هر کاربر به منظور پیش‌بینی دقیق‌تر علایق او [15] مواجه است. همچنین در این نوع مدل‌سازی، مقدار داده موجود در یک دوره زمانی به‌طور قابل توجهی کاهش می‌یابد و در نتیجه مسأله خلوتی داده‌ها در این حالت شدیدتر است [15]. دقت سامانه‌های پیشنهاددهنده معمولی پس از مدتی به دلیل عدم در نظر گرفتن پویایی علایق کاربران، کاهش می‌یابد. مطالعات انجام شده نشان می‌دهند که تطبیق سامانه‌های پیشنهاددهنده با علایق و نیازهای کاربر که به‌طور مدام در حال تغییر هستند، باعث بهتر شدن کارایی پیشنهادها می‌شود [5, 6, 17, 29]؛ بنابراین استخراج الگوهای تغییر در رفتار کاربران ضروری بوده و باعث ارائه پیشنهادهایی نزدیک‌تر به شرایط و علایق فعلی آن‌ها می‌شود [12]. در حال حاضر، اغلب سامانه‌های پیشنهاددهنده امکان ارائه سطح مناسبی از واکنش‌پذیری را که کاربران انتظار دارند، ندارند [9]. این سیستم‌ها توانایی شناسایی و ترکیب تغییرات در نیازها، علایق و محبوبیت‌ها در کاربران را ندارند و تأثیر زمان در علایق کاربر را نادیده می‌گیرند.

در این مقاله، با در نظر گرفتن پویایی علایق کاربران در طول زمان، یک سامانه پیشنهاددهنده اجتماعی به‌منظور تولید پیشنهادهای بهتر و دقیق‌تر به کاربران ارائه می‌شود. مدل پیشنهادی مبتنی بر این واقعیت‌ها است که روند تغییر علایق برای همه کاربران در طول زمان یکسان نیست و هر کاربر الگوی تغییر علایق خاص خود را دارد، و همچنین روابط اجتماعی می‌توانند بر علایق کاربران در یک سامانه پیشنهاددهنده، تأثیرگذار باشند. در این رویکرد، فرض می‌شود که علایق کاربران به‌صورت هموار تغییر می‌کنند [13, 15, 31] و علایق دوره زمانی فعلی کاربر به علایق او در دوره زمانی قبلی بستگی دارد، و یک ماتریس انتقال علایق برای هر کاربر به‌منظور مدل کردن پویایی علایق او بین دو دوره متوالی آموزش داده می‌شود و با ترکیب امتیازات کاربران و اعتماد بین آن‌ها مبتنی بر روش تجزیه ماتریس، امتیازات کاربران به اقلام را پیش‌بینی می‌کند. هرچند در همین اواخر چندین سامانه پیشنهاددهنده مبتنی بر ترکیب اطلاعات امتیازات و

اعتماد به‌منظور ارائه پیشنهادهای دقیق‌تر به کاربران ارائه شده است [10, 34]، ولی پویایی علایق کاربران در این سامانه‌ها نادیده گرفته شده است. مهم‌ترین ویژگی روش تجزیه ماتریس که باعث استفاده آن در رویکرد پیشنهادی شده است، امکان ترکیب راحت‌تر اطلاعات جانبی مختلف در مدل است [35]. به‌اختصار، نوآوری‌های این مقاله عبارتند از:

- ارائه یک مدل مقیاس‌پذیر با استفاده از روش تجزیه ماتریس برای ترکیب پویایی زمانی علایق کاربران، امتیازات و اعتماد بین کاربران به‌منظور بهبود دقت پیش‌بینی امتیازات کاربران.
 - استخراج و مدل‌سازی الگوی تغییر علایق هر کاربر در سامانه پیشنهاددهنده اجتماعی با ارائه یک ماتریس انتقال برای نگاشت تغییر علایق بین دو دوره زمانی متوالی برای هر کاربر خاص.
- در ادامه این مقاله و در بخش دوم، مروری بر پژوهش‌های پیشین می‌شود. بخش سوم مسأله هدف طرح می‌شود. بخش چهارم به معرفی مدل پیشنهادی اختصاص دارد. در بخش پنجم نتایج ارزیابی ارائه شده و در نهایت در بخش ششم، نتیجه‌گیری و پیشنهادهای کارهای آینده مطرح می‌شوند.

۲- پیشینه پژوهش

بسیاری از سامانه‌های پیشنهاددهنده که پویایی علایق کاربران را در نظر می‌گیرند، از روش تجزیه ماتریس استفاده می‌کنند [39]. معروف‌ترین سامانه پیشنهاددهنده زمانی مبتنی بر تجزیه ماتریس به نام TimeSVD++ در [12] پیشنهاد شده است. این مدل با معرفی یک میزان تمایل^۱ برای هر کاربر و هر قلم محصول در هر زمان خاص، تغییرات محلی علایق کاربران را استخراج و مدل می‌کند. این روش، تجزیه ماتریس را بر اساس روش تجزیه مقدار تکین^۲ (SVD) انجام می‌دهد. یادگیری هر پارامتر در روش TimeSVD++، در هر مرحله به‌صورت مجزا انجام می‌شود که در نتیجه تلاش بسیار زیادی برای تنظیم‌سازی پارامترها صورت می‌گیرد [15].

یک مدل مبتنی بر تجزیه ماتریس نیز در [15] پیشنهاد شده است که روش کاهش گرادین را برای یادگیری بردار ویژگی‌های پنهان هر کاربر در هر دوره زمانی با استفاده از امتیازات داده‌شده در همه دوره‌های زمانی قبلی، توسعه می‌دهد؛ سپس با استفاده از رگرسیون لاسو^۳ برای بردار پنهان کاربر در هر بازه زمانی، یک مدل

¹ Bias

² Singular Value Decomposition

³ Lasso

خطی برای مدل‌سازی الگوی تغییر علائق آموزش داده می‌شود. روش گرادین ارائه شده در این روش باعث کاهش مشکل خلوتی داده‌ها می‌شود. با این وجود، تأثیر کاربرانی که تعداد بسیار کمی از اقلام را امتیاز داده‌اند و به کاربران شروع سرد^۱ معروف هستند، در این روش نادیده گرفته شده است و این قبیل کاربران در مرحله پیش‌پردازش حذف می‌شوند. درحالی‌که امتیازات کاربران شروع سرد می‌تواند به نوبه خود در دقت تخمین بردارهای پنهان سایر کاربران تأثیر داشته باشد [15].

در [44] با یادگیری یک ماتریس انتقال برای بردار ویژگی‌های هر کاربر در دو دوره‌ی زمانی متوالی به‌منظور استخراج پویایی علائق کاربر، الگوریتم تجزیه احتمالاتی ماتریس توسعه داده می‌شود. در این طرح، فرض می‌شود که علائق کاربران به‌صورت تدریجی تغییر می‌کنند و علائق کاربر در دوره زمانی فعلی به دوره زمانی قبلی وابسته است. این روش برای آموزش پارامترها و همچنین ماتریس انتقال از گرادین نزولی استفاده می‌کند. برای رفع مشکل دشواری بودن تخمین مقادیر مناسب برای پارامترها، روش یادشده به مدلی مبتنی بر بیزین به نام BTMF^۲ توسعه داده شد که از زنجیره مارکف مونت کارلو^۳ برای تخمین پارامترها و آموزش ماتریس انتقال استفاده می‌کند. کار اصلی این روش، آموزش ماتریس‌های انتقال علائق است که باعث می‌شود برای هر کاربر، الگوی تغییر علائق مخصوص او استخراج شود و به‌عنوان مزیت روش یادشده محسوب می‌شود. در این روش مشکل کاربران شروع سرد وجود دارد و کاربرانی که تعداد کمی از اقلام را امتیاز داده‌اند (کمتر از ۲۰ امتیازدهی) در مرحله پیش‌پردازش حذف می‌شوند. در [35] با مدل‌کردن پویایی علائق کاربران و در نظر گرفتن هم‌بستگی بین اقلام و همچنین توضیحات متنی که کاربران درباره اقلام می‌دهند، و ترکیب همه آنها در مدل تجزیه ماتریس، امتیازات کاربران پیش‌بینی می‌شوند. اگر چه استفاده از توضیحات متنی در این طرح به کاهش مشکل خلوتی داده‌ها در ماتریس حاوی امتیازات کمک می‌کند، ولی ارائه‌دهندگان طرح یاشده اذعان می‌کنند که روش آن‌ها توانایی پیش‌بینی امتیازات کاربران جدید را ندارد.

یک روش مبتنی بر تجزیه احتمالاتی ماتریس برای پیش‌بینی علائق پویای کاربران در میکرو بلاگ‌نویسی در [3] پیشنهاد شده است. در این مدل، در هر دوره زمانی، علاوه بر ماتریس امتیازات و اعتماد مربوط به آن دوره، ماتریس میانگین ویژگی‌های کاربران و اقلام در دوره‌های

زمانی قبلی نیز در پیش‌بینی امتیازات نقش دارند و با استفاده از یک تابع کاهش نمایی به امتیازات قبلی کاربر وزن داده می‌شود؛ به‌طوری‌که هر چه امتیازات کاربر قدیمی‌تر باشند، تأثیر کمتری در محاسبه علائق و امتیازات فعلی او خواهند گذاشت. با این وجود، در این روش وزن انتساب‌شده به امتیازات همه کاربران در یک دوره زمانی خاص، یکسان است و این واقعیت که تغییرات علائق در طول زمان برای هر کاربر می‌تواند متفاوت باشد [23, 31]، نادیده گرفته می‌شود. در [28] با توسعه روش تجزیه احتمالاتی ماتریس بر اساس فیلترینگ کالمن در سامانه‌های پیشنهاددهنده، علائق پویای کاربران استخراج می‌شود. این روش با توجه به مدل فضای حالت پویا، از یک ماتریس انتقال ویژگی‌ها و علائق کاربران استفاده می‌کند. از آنجایی که الگوی تغییر علائق برای هر کاربر متفاوت است، محدودیت اصلی این روش در عمل، این است که فرض می‌کند ماتریس انتقال برای همه کاربران یکسان است [15]. در [32] یک روش تجزیه ماتریس بر اساس تجزیه مقدار تکیین ارائه شده که علاوه بر امتیازات، از اطلاعات زمانی و روابط اعتماد بین کاربران نیز در پیش‌بینی امتیازات کاربران استفاده می‌کند. ارائه‌دهندگان این روش با تحلیل یک مجموعه داده مربوط به امتیازدهی فیلم‌ها نشان دادند که استخراج پویایی علائق کاربران در طول زمان برای بهبود دقت پیشنهادات ضروری است. استفاده از اعتماد در این روش باعث کاهش مشکل خلوتی داده‌ها می‌شود. در این روش، دو مدل خطی و نمایی برای روند تغییر تمایل کاربران به محصولات ارائه شده است. درحالی‌که در عمل، روند تغییر تمایل هر کاربر برای اقلام مختلف، ممکن است، متفاوت باشد [23, 25].

در حالتی از روش تجزیه ماتریس، ماتریس امتیازات به دو ماتریس نامنفی شامل بردارهای ویژگی‌های کاربران و اقلام تجزیه می‌شود که به آن تجزیه نامنفی ماتریس^۴ [14] گفته می‌شود. بر این اساس، روشی برای تولید پیشنهادات در [22] ارائه شده است که با ترکیب امتیازات کاربران و توضیحات آن‌ها درباره اقلام، در مدل تجزیه نامنفی ماتریس، الگوی تغییرات زمان علائق کاربران را استخراج می‌کند. بدین منظور از یک ماتریس انتقال برای نگاشت بین ویژگی‌های کاربران در دو دوره زمانی متوالی استفاده می‌کند. در این روش، ماتریس انتقال برای همه کاربران یکسان در نظر گرفته شده است؛ درحالی‌که روند تغییر علائق برای هر کاربر ممکن متفاوت باشد [23, 31]. یک روشی مبتنی بر تجزیه نامنفی ماتریس به نام DMNMF^۵ برای استخراج پویایی علائق

^۴ Non-negative Matrix Factorization

^۵ Dynamic Multi-task Non-negative Matrix Factorization

^۱ Cold-start Users

^۲ Bayesian Temporal Probabilistic Matrix Factorization

^۳ Markov Chain Monte Carlo

این روش وقتی تعداد کاربران و اقلام افزایش می‌یابند، مقیاس‌پذیر نیست.

به عنوان جمع‌بندی، در تعدادی از روش‌های پیشنهاددهنده زمانی از قبیل [3, 11, 22, 28, 32] این واقعیت که هر کاربر الگوی تغییر علائق خاص خود را دارد که در طول زمان می‌تواند متفاوت باشد [23, 31]، نادیده گرفته شده است. همچنین اغلب روش‌های موجود [11, 12, 15, 19, 28, 36, 44] فقط از امتیازات کاربران استفاده می‌کنند که در نتیجه، مسأله ذاتی خلوتی داده‌ها در آن‌ها وجود دارد. در تعدادی از روش‌ها [3, 22, 23, 28, 32] که علاوه بر امتیازات، از اطلاعات جانبی کاربران از قبیل اعتماد، توضیحات متنی درباره اقلام و خصوصیات کاربران نیز استفاده شده، مسأله خلوتی داده‌ها کاهش یافته و باعث بهبود کیفیت پیشنهادها شده است. روش‌های مبتنی بر تجزیه تنسور، رویکردی اصولی و ساخت یافته برای منظورکردن پویایی زمانی در سامانه‌های پیشنهاددهنده هستند [15]، ولی محدودیت اصلی آن‌ها، دشواری پردازش و تجزیه تنسور، به خصوص برای تنسورهای بسیار بزرگ و خلوت است، که منجر به محاسبات زمان‌بر و افزایش بسیار زیاد پیچیدگی حافظه‌ای در تجزیه تنسور می‌شود [15, 46]. از طرفی دقت پیش‌بینی و مقیاس‌پذیری خوب رویکرد تجزیه ماتریس [26] و همچنین راحت‌تر بودن ترکیب اطلاعات جانبی در مدل با استفاده از تجزیه ماتریس [35]، باعث شده است که این رویکرد به عنوان پایه اغلب مدل‌های پیشنهاددهنده زمانی از قبیل [12, 15, 44, 35, 3, 11, 22, 28, 32] قرار گیرد [39].

۳- طرح مسأله

فرض می‌شود یک سامانه پیشنهاددهنده اجتماعی شامل m کاربر و n قلم محصول باشد [3]. برای P دوره زمانی از قبل تعیین شده، ماتریس امتیازات کاربر-قلم^۲ در دوره زمانی t ($t=1, 2, \dots, P$) به صورت $R^{(t)} \in \mathbb{R}^{m \times n}$ در نظر گرفته می‌شود و $R_{ij}^{(t)}$ بیان‌گر امتیاز داده شده توسط کاربر i ($i=1, 2, \dots, m$) به قلم j ($j=1, 2, \dots, n$) در دوره زمانی t است [15]. به طور معمول امتیاز داده شده، یک عدد حقیقی بین صفر تا R_{max} است. مقدار صفر بیان‌گر این است که کاربر هیچ امتیازی به قلم محصول نداده است. امتیاز بالاتر نشان‌دهنده رضایت بیشتر کاربر از آن قلم محصول است. در اغلب سامانه‌های پیشنهاددهنده، مقدار R_{max} برابر پنج است [38, 39, 41]. هر کاربر به طور معمول

کاربران نیز در [11] ارائه شده است که با آموزش یک ماتریس انتقال حالت که بین ویژگی‌های پنهان کاربران در دو دوره زمانی متوالی نگاشت می‌کند، تغییرات علائق کاربران در طول زمان را استخراج می‌کند. اگر چه این روش محدودیت مدل‌های ارائه شده در [3, 22, 28] را ندارد و هر کاربر ماتریس انتقال علائق خود را دارد، ولی این ماتریس انتقال برای هر کاربر در همه دوره‌های زمانی، ثابت در نظر گرفته شده است، درحالی‌که الگوی تغییر علائق هر کاربر در زمان‌های مختلف می‌تواند متفاوت باشد.

برخی پژوهش‌ها برای مدل‌سازی پویایی زمانی علائق کاربران در سامانه‌های پیشنهاددهنده، از روش تجزیه تنسور^۱ [8] استفاده کرده‌اند. تجزیه تنسور، توسعه تجزیه ماتریس به یک تنسور سه‌بعدی، با در نظر گرفتن تأثیرات زمانی است. در [36] یک روش تجزیه احتمالاتی بیزین تنسور با در نظر گرفتن تغییر علائق کاربران در طول زمان ارائه شده است. در این روش، امتیازات کاربران به اقلام به صورت یک تنسور سه‌بعدی در نظر گرفته می‌شود که ابعاد تنسور متناظر با کاربران، اقلام و دوره‌های زمانی بوده و مقادیر آن، امتیازهایی هستند که یک کاربر به یک قلم محصول در یک دوره زمانی خاص می‌دهد. محدودیت این روش این است که فقط تغییرات کلی را استخراج می‌کند و تغییرات علائق برای هر کاربر خاص را مدل نمی‌کند [15]. در [19] با در نظر گرفتن یک تنسور سه‌بعدی متناظر با کاربران، فیلم‌ها و دوره‌های زمانی، با توسعه روش تجزیه احتمالاتی تنسور، ویژگی‌های پنهان کاربران، فیلم‌ها و زمان را تخمین زده و برای ارائه پیشنهادها مبتنی بر زمان به کاربران استفاده می‌کند. این مدل پیشنهادی برای حالتی مناسب است که رفتار کاربران به صورت دوره‌ای در بازه‌های زمانی، تکرار می‌شود و نمی‌تواند تغییرات پیوسته‌ی علائق کاربران در طول زمان را استخراج کند. یک مدل پیشنهاددهنده زمانی مبتنی بر تجزیه تنسور و ماتریس‌های متصل به هم در [23] ارائه شده است که از یک تنسور سه‌بعدی متناظر با تعاملات کاربران با اقلام در طول زمان و یک ماتریس حاوی خصوصیات کاربران استفاده می‌کند. در این روش، معیاری به نام نرخ پویایی علائق کاربر معرفی می‌شود که میزان نرخ تغییرات علائق هر کاربر در گذشته را استخراج و از آن برای وزن‌دهی امتیازات کاربر استفاده می‌کند. مزیت اصلی این روش اینست که برای هر کاربر الگوی تغییر علائق مخصوص او را استخراج می‌کند. با این وجود،

² User-item Matrix


¹ Tensor Factorization

تغییر می‌کنند و همچنین روابط اعتماد بر علایق کاربران تأثیر می‌گذارند، هدف پیش‌بینی مقادیر ماتریس $R^{(t)}$ با استخراج پویایی علایق کاربران و ترکیب ماتریس‌های امتیازات و اعتماد است.

به‌عنوان یک مثال، شکل (۱) تصویری از منابع داده‌ای مهم مسأله را نشان می‌دهد. در این مثال، تعداد کاربران و اقلام به ترتیب برابر ۴ و ۵ در نظر گرفته شده است. امتیازات داده‌شده به اقلام و همچنین روابط اعتماد برقرارشده توسط کاربران بر اساس زمان آن‌ها به چند بازه زمانی تقسیم می‌شوند که شکل (۱-الف) و (۱-ب) به ترتیب ماتریس‌های امتیازات در دوره‌های زمانی t و $t-1$ را نشان می‌دهند. شکل (۱-ج) نیز گراف شبکه اعتماد متناظر آن در شکل (۱-د) مشاهده می‌شود.

	u_1	u_2	u_3	u_4
u_1	0	0	1	0
u_2	1	0	0	1
u_3	1	0	0	1
u_4	0	0	0	0

د) $T^{(t)}$: ماتریس اعتماد در t



ج) گراف شبکه اعتماد در t

	i_1	i_2	i_3	i_4	i_5
u_1	2	0	0	4	0
u_2	0	5	0	0	4
u_3	0	3	1	0	1
u_4	0	0	2	4	0

ب) $R^{(t)}$: ماتریس امتیازات در t

	i_1	i_2	i_3	i_4	i_5
u_1	0	0	3	0	1
u_2	0	1	0	0	0
u_3	2	0	0	0	0
u_4	2	0	0	0	5

الف) $R^{(t-1)}$: ماتریس امتیازات در $t-1$


(شکل-۱): مثالی برای نشان دادن منابع داده‌ای اصلی در مدل پیشنهادی
(Figure-1): An example to illustrate the main data sources in the proposed model

۴- مدل پیشنهادی

ابتدا تابع هدف مدل پیشنهادی برای استخراج علایق پویای کاربران با استفاده از روش تجزیه ماتریس به‌منظور پیش‌بینی امتیازات فرموله می‌شود؛ سپس الگوریتم بهینه‌سازی تابع هدف ارائه و در نهایت، پیش‌بینی امتیازات انجام می‌گیرد. شکل (۲) معماری مدل پیشنهادی را نشان می‌دهد.

۴-۱- تابع هدف

سامانه‌های پیشنهاددهنده متداول مبتنی بر تجزیه ماتریس‌های اتصالی (شامل داده‌هایی از قبیل امتیازات کاربران و اعتماد بین آنها)، از همه داده‌های موجود برای آموزش مدل استفاده می‌کنند [13]. از آنجایی که علایق کاربر در یک دوره زمانی درازمدت، به‌طور چشم‌گیری تغییر می‌کنند، رفتارهای قدیمی کاربر به احتمال زیاد، امتیازات قدیمی می‌توانند تأثیر منفی در تولید پیشنهادات داشته باشند [13]؛ بنابراین بر خلاف سایر روش‌های مبتنی بر تجزیه ماتریس، در مدل پیشنهادی از همه امتیازات در دوره‌های زمانی قبلی به‌عنوان داده آموزشی استفاده نمی‌شود. این چشم‌پوشی باعث می‌شود میزان



(شکل-۲): معماری مدل پیشنهادی
(Figure-2): The architecture of the proposed model

اعتماد بین صفر تا یک هستند، به منظور آموزش آسان تر پارامترها، هر مقدار $R_{ij}^{(t)}$ را با استفاده از تابع $f(x) = x/R_{max}$ به بازه $[0,1]$ تبدیل می کنیم [37, 39]. همچنین همانند [33, 37, 40, 42, 45] با استفاده از تابع لجستیک $g(x) = 1/(1 + \exp(-x))$ که در [18] پیشنهاد شده است، مقدار حاصل ضرب داخلی بردارهای ویژگی پنهان را به بازه $[0,1]$ محدود می کنیم.

با توجه به توضیحات بالا، تابع هدف تجزیه ماتریس به صورت زیر خواهد بود:

$$\min_{U^{(t)}, V^{(t)}, W^{(t)}} \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n I_{ij}^{R^{(t)}} (R_{ij}^{(t)} - g(U_i^{(t)} V_j^{(t)T}))^2 + \frac{\lambda_T}{2} \sum_{i=1}^m \sum_{k=1}^m I_{ik}^{T^{(t)}} (T_{ik}^{(t)} - g(U_i^{(t)} W_k^{(t)T}))^2 + \frac{\lambda}{2} (\|U^{(t)}\|_F^2 + \|V^{(t)}\|_F^2 + \|W^{(t)}\|_F^2) \quad (2)$$

دو عبارت نخست در رابطه (2)، بیان گر میزان خطاهای تخمین هستند. $I_{ik}^{T^{(t)}}$ و $I_{ij}^{R^{(t)}}$ توابع نشان گر^۱ هستند؛ به طوری که مقدار $I_{ij}^{R^{(t)}}$ برابر یک است، اگر کاربر i ، قلم j را در دوره زمانی t امتیازدهی کرده باشد؛ در غیر این صورت مقدار $I_{ij}^{R^{(t)}}$ برابر صفر است. به همین صورت، مقدار $I_{ik}^{T^{(t)}}$ برابر یک است، اگر کاربر i به کاربر k در دوره زمانی t اعتماد کرده باشد. در غیر این صورت مقدار $I_{ik}^{T^{(t)}}$ برابر صفر است. پارامتر λ_T میزان تأثیر اعتماد بر علایق کاربر در مقایسه با امتیازات را کنترل می کند؛ به طوری که هر چه مقدار λ_T بزرگتر باشد، میزان تأثیر اعتماد بر روی علایق کاربر بیشتر می شود. عبارت داخل پرانتز آخر در رابطه بالا، به منظور جلوگیری از بیش برآزش بوده که λ پارامتر تنظیم کننده آن است. $\| \cdot \|_F^2$ نرم فروبنیوس است، به طوری که:

$$\|R^{(t)}\|_F^2 = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |R_{ij}^{(t)}|^2}$$

علایق کاربران به صورت هموار و ملایم تغییر می کنند [13, 15, 31]؛ در نتیجه باید مطمئن شویم که ویژگی های پنهان کاربران در یک دوره زمانی کوتاه به طور قابل توجهی تغییر نمی کنند. بدین منظور فرض می کنیم که ویژگی های پنهان یک کاربر در دوره زمانی t ($t > 1$) یک وابستگی زمانی به ویژگی های پنهان او در دوره زمانی $t-1$ دارد. و برای هر کاربر i ، یک ماتریس انتقال $M_i^{(t)} \in \mathbb{R}^{d \times d}$ بین دو بردار ویژگی های او در دوره های زمانی متوالی t و $t-1$ ، یعنی $U_i^{(t)}$ و $U_i^{(t-1)}$ می سازیم. این ماتریس، نگاشت

داده در دسترس مربوط به امتیازات کاربران به اقلام به شدت کاهش یابد و مسأله خلوتی داده ها بیشتر شود. برای کاهش این مشکل از اطلاعات اعتماد بین کاربران در کنار امتیازات استفاده می کنیم.

فرض می کنیم ماتریس های $U^{(t)} \in \mathbb{R}^{m \times d}$ و $V^{(t)} \in \mathbb{R}^{n \times d}$ به ترتیب ماتریس های ویژگی های پنهان کاربران و اقلام در دوره زمانی t باشند. d ابعاد فضای ویژگی است. (مقدار d بسیار کوچک تر از هر دو مقدار m و n است) هر بردار سطری $U_i^{(t)}$ در $U^{(t)}$ و $V_j^{(t)}$ در $V^{(t)}$ به ترتیب بیان گر بردار ویژگی های کاربر i و بردار ویژگی های پنهان کاربران و اقلام در دوره زمانی t را با استفاده از ماتریس امتیازات در دوره زمانی t استخراج می کند. می توان با ضرب داخلی ویژگی های استخراج شده برای تخمین و پیش بینی مقادیر ماتریس $R^{(t)}$ استفاده کرد. به این صورت که برای پیش بینی مقدار $\hat{R}_{ij}^{(t)}$ به عنوان تخمینی از $R_{ij}^{(t)}$ خواهیم داشت:

$$\hat{R}_{ij}^{(t)} = U_i^{(t)} V_j^{(t)T} \quad (1)$$

که $V_j^{(t)T}$ ترانزاده بردار $V_j^{(t)}$ است. همچنین فرض می کنیم ماتریس های $B^{(t)} \in \mathbb{R}^{m \times d}$ و $W^{(t)} \in \mathbb{R}^{m \times d}$ به ترتیب ماتریس های ویژگی های پنهان اعتمادکنندگان و معتمدین باشند. هر بردار سطری $B_i^{(t)}$ در $B^{(t)}$ و $W_k^{(t)}$ در $W^{(t)}$ به ترتیب بیان گر بردار ویژگی های کاربر اعتمادکننده i و بردار ویژگی های کاربر معتمد k در دوره زمانی t هستند. به طور مشابه با استفاده از روش تجزیه ماتریس، بردارهای ویژگی های پنهان اعتمادکنندگان و معتمدین در دوره زمانی t استخراج، و مقدار اعتماد $T_{ik}^{(t)}$ به به صورت $B_i^{(t)} W_k^{(t)T}$ قابل پیش بینی خواهد بود که $W_k^{(t)T}$ ترانزاده $W_k^{(t)}$ است.

از آنجایی که کاربران در ماتریس امتیازات، همان اعتمادکنندگان در ماتریس اعتماد هستند، فضای ویژگی های پنهان آن ها نیز یکسان در نظر گرفته می شود [37]؛ بنابراین فرض می شود که ماتریس ویژگی های پنهان کاربر، یعنی $U^{(t)}$ ، فضای ویژگی های مشترک بین دو ماتریس امتیازات و اعتماد می باشد؛ در نتیجه هر بردار ویژگی $U_i^{(t)}$ چگونگی امتیازدهی کاربر i به اقلام و چگونگی اعتماد او به دیگران را در دوره زمانی t به صورت هم زمان مشخص می کند. در فرایند تجزیه ماتریس، می توان این دو ماتریس را از طریق فضای ویژگی های مشترک به هم متصل کرد [10, 37]. به دلیل این که مقادیر

¹ Indicator Function

$$V_j^{(t)} = V_j^{(t)} - \eta \frac{\partial \mathcal{L}}{\partial V_j^{(t)}} \quad (6)$$

$$W_k^{(t)} = W_k^{(t)} - \eta \frac{\partial \mathcal{L}}{\partial W_k^{(t)}} \quad (7)$$

$$M_i^{(t)} = M_i^{(t)} - \eta \frac{\partial \mathcal{L}}{\partial M_i^{(t)}} \quad (8)$$

که η نرخ یادگیری است. گرادیان $\mathcal{L}$ نسبت به هر یک از متغیرها عبارت است از:

$$\frac{\partial \mathcal{L}}{\partial U_i^{(t)}} = \sum_{j=1}^n I_{ij}^{R(t)} g'(U_i^{(t)} V_j^{(t)T}) (g(U_i^{(t)} V_j^{(t)T}) - R_{ij}^{(t)}) V_j^{(t)} \quad (9)$$

$$+ \lambda_T \sum_{k=1}^m I_{ik}^{T(t)} g'(U_i^{(t)} W_k^{(t)T}) (g(U_i^{(t)} W_k^{(t)T}) - T_{ik}^{(t)}) W_k^{(t)} + \lambda_1 (U_i^{(t)} - U_i^{(t-1)} M_i^{(t)}) + \lambda_2 U_i^{(t)}$$

$$\frac{\partial \mathcal{L}}{\partial V_j^{(t)}} = \sum_{i=1}^m I_{ij}^{R(t)} g'(U_i^{(t)} V_j^{(t)T}) (g(U_i^{(t)} V_j^{(t)T}) - R_{ij}^{(t)}) U_i^{(t)} + \lambda_2 V_j^{(t)} \quad (10)$$

$$\frac{\partial \mathcal{L}}{\partial W_k^{(t)}} = \lambda_T \sum_{i=1}^m I_{ik}^{T(t)} g'(U_i^{(t)} W_k^{(t)T}) (g(U_i^{(t)} W_k^{(t)T}) - T_{ik}^{(t)}) U_i^{(t)} + \lambda_2 W_k^{(t)} \quad (11)$$

$$\frac{\partial \mathcal{L}}{\partial M_i^{(t)}} = \lambda_1 U_i^{(t-1)T} (U_i^{(t-1)} M_i^{(t)} - U_i^{(t)}) + \lambda_2 M_i^{(t)} \quad (12)$$

که $g'(x) = \exp(-x)/(1 + \exp(-x))^2$ مشتق تابع لجستیک $g(x)$ می‌باشد.

۳-۴- پیش‌بینی امتیازات

با ضرب داخلی دو بردار ویژگی‌های به‌دست‌آمده $U_i^{(t)}$ و $V_j^{(t)}$ ، امتیاز کاربر i به قلم j پیش‌بینی می‌شود. از آنجایی که نتیجه حاصل ضرب، مقداری بین صفر تا یک است، مقدار امتیازات به‌صورت زیر پیش‌بینی می‌شوند.

$$\hat{R}_{ij}^{(t)} = g(U_i^{(t)} V_j^{(t)T}) \cdot R_{max} \quad (13)$$

الگوریتم (۱) روند مدل پیشنهادی در پیش‌بینی امتیازات را نشان می‌دهد. در خط ۲، تابع انتقال $M_i^{(t)}$ برای هر کاربر i با ماتریس همانی $d \times d$ عضو I مقداردهی اولیه و همچنین ماتریس‌های ویژگی پنهان $U^{(t)}$ ، $V^{(t)}$ و $W^{(t)}$ با مقادیر تصادفی مقداردهی می‌شوند. در خط ۳، ماتریس $U^{(t-1)}$ با تجزیه ماتریس $R^{(t-1)}$ به‌دست می‌آید. در پیاده‌سازی مدل پیشنهادی از روش تجزیه ماتریس در

بین دو بردار متوالی ویژگی پنهان کاربر i (بردارهای $U_i^{(t-1)}$ و $U_i^{(t)}$) را استخراج می‌کند. با در نظر گرفتن ماتریس انتقال، عبارت زیر را برای اعمال پویایی زمانی علایق کاربران در رابطه (۲) قرار می‌دهیم.

$$U_i^{(t)} \approx U_i^{(t-1)} M_i^{(t)} \quad (3)$$

در نتیجه تابع هدف رابطه (۲) به‌صورت زیر بازنویسی می‌گردد:

$$\mathcal{L} = \min_{U^{(t)}, V^{(t)}, W^{(t)}} \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n I_{ij}^{R(t)} (R_{ij}^{(t)} - g(U_i^{(t)} V_j^{(t)T}))^2 + \frac{\lambda_T}{2} \sum_{i=1}^m \sum_{k=1}^m I_{ik}^{T(t)} (T_{ik}^{(t)} - g(U_i^{(t)} W_k^{(t)T}))^2 + \frac{\lambda_1}{2} \sum_{i=1}^m \|U_i^{(t)} - U_i^{(t-1)} M_i^{(t)}\|_F^2 + \frac{\lambda_2}{2} (\|U^{(t)}\|_F^2 + \|V^{(t)}\|_F^2 + \|W^{(t)}\|_F^2) + \sum_{i=1}^m \|M_i^{(t)}\|_F^2 \quad (4)$$

در رابطه (۴)، عبارت سوم با پارامتر λ_1 عبارت تنظیم‌سازی همواری بر اساس این بینش است که علایق کاربران باید به‌صورت هموار در طول زمان تغییر کنند. این عبارت نشان‌دهنده کمینه‌سازی خطای تخمین ماتریس انتقال $M_i^{(t)}$ است. عبارت آخر به منظور جلوگیری از بیش‌برازش بوده که λ_2 پارامتر تنظیم‌کننده آن است. برای سادگی مدل، در پیاده‌سازی، λ_1 را برابر λ_2 قرار می‌دهیم.

۲-۴- الگوریتم بهینه‌سازی

تابع هدف $\mathcal{L}$ در رابطه (۴) به‌طور هم‌زمان برای همه متغیرهای $U_i^{(t)}$ ، $V_j^{(t)}$ ، $W_k^{(t)}$ و $M_i^{(t)}$ محدب نیست؛ ولی نسبت به هر یک از متغیرها به‌صورت مجزا محدب است. در نتیجه می‌توان یک بهینه محلی برای $\mathcal{L}$ با به‌کارگیری روش گرادیان نزولی تصادفی^۱ که به‌طور معمول از ویژگی همگرایی بسیار خوبی برخوردار است [13]، به‌دست آورد؛ بدین منظور، هر متغیر با ثابت نگه‌داشتن سایر متغیرها به‌صورت روابط زیر به‌روزرسانی می‌شود:

$$U_i^{(t)} = U_i^{(t)} - \eta \frac{\partial \mathcal{L}}{\partial U_i^{(t)}} \quad (5)$$

¹ Stochastic Gradient Descent

اقدام $(U^{(t)}V^{(t)T})$ انجام می‌پذیرد. در پایان (مرحله پنج) با استفاده از رابطه (۱۳)، مقادیر ماتریس امتیازات پیش‌بینی شده محاسبه می‌شود.

Algorithm 1. The process of rating prediction


Input:

matrices: $R^{(t)}, R^{(t-1)}, T^{(t)}$;
the dimension of the latent feature: d ;
parameters: $\lambda_T, \lambda_1, \lambda_2$;
learning rate: η ;
convergence parameter: ε .

Output: matrix $\hat{R}^{(t)}$.

- 1 Map the raw ratings in $R^{(t)}$ and $R^{(t-1)}$ into $[0,1]$.
- 2 Initialize $M_i^{(t)}$ for each user i , $U^{(t)}, V^{(t)}$ and $W^{(t)}$.
- 3 Compute $U^{(t-1)}$.
- 4 Repeat
- 5 Randomly select $R_{ij}^{(t)} \in R^{(t)}$ and $T_{ik}^{(t)} \in T^{(t)}$.
- 6 Update $U_i^{(t)}$ (equation (5)).
- 7 Update $V_j^{(t)}$ (equation (6)).
- 8 Update $W_k^{(t)}$ (equation (7)).
- 9 Update $M_i^{(t)}$ (equation (8)).
- 10 Compute $\mathcal{L}$ (equation (4)).
- 11 Until change of $\mathcal{L}$ is less than ε
- 12 For (each user i and each item j)
- 13 $\hat{R}_{ij}^{(t)} = g(U_i^{(t)}V_j^{(t)T}) \cdot R_{max}$.
- 14 End For

کتابخانه LIBMF [7]، برای محاسبه $U^{(t-1)}$ استفاده می‌کنیم. الگوریتم بهینه‌سازی تا وقتی که $\mathcal{L}$ همگرا شود، تکرار می‌شود. هم‌گرایی در خط ۱۱ بررسی می‌شود، به طوری که اگر میزان تغییر $\mathcal{L}$ بین تکرار فعلی و قبلی کمتر از مقدار آستانه ε باشد، الگوریتم بهینه‌سازی پایان می‌یابد. برای یک مثال عددی، با در نظر گرفتن ماتریس‌های امتیازات و اعتماد در شکل (۱)، فرایند پیش‌بینی امتیازات در شکل (۳) مشاهده می‌شود. در مرحله نخست، مقادیر ماتریس‌های امتیازات به بازه $[0,1]$ نرمال و در مرحله دو، ماتریس ویژگی‌های پنهان کاربران در دوره زمانی $t-1$ (ماتریس $U^{(t-1)}$) از روی ماتریس امتیازات در این دوره استخراج می‌شود. در اینجا برای سادگی نمایش همانند [3]، مقدار d برابر ۵ انتخاب شده است؛ سپس در مرحله سوم، ماتریس‌های $U^{(t-1)}$ ، $R^{(t)}$ (نرمال شده) و $T^{(t)}$ ، به‌عنوان ورودی‌های اصلی وارد فرایند آموزش و استخراج ویژگی‌های پنهان کاربران و اقدام دوره زمانی t می‌شوند. ماتریس‌های نهایی حاصل شده برای $U^{(t)}$ ، $V^{(t)}$ ، $W^{(t)}$ و $M_i^{(t)}$ ($i=1, \dots, 4$) در شکل (۳) مشاهده می‌شوند. در مرحله چهارم، ضرب دو ماتریس ویژگی‌های کاربران و



(شکل-۳): مثالی از پیش‌بینی امتیازات در مدل پیشنهادی

(Figure-3): An example of the rating predictions in the proposed model

در نتیجه مدل پیشنهادی برای سامانه‌هایی شامل میلیون‌ها کاربر و محصول مقیاس پذیر است.

۵- نتایج تجربی

۵-۱- معرفی مجموعه داده‌ها

برای ارزیابی مدل پیشنهادی از مجموعه داده Epinions [30] استفاده می‌کنیم. Epinions^۱ یک تارنمای مشهور بررسی اقلام مختلف است که کاربران می‌توانند اقلام را با مقادیر بین یک تا پنج امتیاز داده و همچنین توضیحات متنی در رابطه با اقلام درج کنند؛ علاوه بر این، هر کاربر

هزینه محاسباتی اصلی در فرایند آموزش مدل پیشنهادی، شامل ارزیابی تابع هدف $\mathcal{L}$ و گرادین آن نسبت به هر یک از متغیرها می‌باشد. پیچیدگی محاسباتی برای ارزیابی تابع هدف $\mathcal{L}$ برابر $O(dN_R + dN_T)$ می‌باشد که N_R و N_T به ترتیب تعداد عناصر غیر صفر ماتریس‌های $R^{(t)}$ و $T^{(t)}$ هستند. مقدار d ثابت و پیچیدگی‌های محاسباتی برای محاسبه گرادین‌ها در روابط (۹) تا (۱۲) به ترتیب برابر $O(dN_R)$ ، $O(dN_R + dN_T)$ و $O(1)$ است؛ بنابراین پیچیدگی محاسباتی کل در هر تکرار برابر $O(dN_R + dN_T)$ است که نسبت به تعداد داده‌های موجود در ماتریس‌های امتیازات و اعتماد، خطی است و

^۱ www.epinions.com

یک لیست اعتماد دارد که می‌تواند کاربران مورد اعتماد خود را به آن اضافه می‌کند. مجموعه داده Epinions تنها مجموعه داده بزرگ و واقعی است که شامل اطلاعات امتیازدهی و همچنین اطلاعات اعتماد بین کاربران به همراه زمان‌های امتیازدهی و برقراری اعتماد است [2]. نسخه‌ای از این مجموعه داده که استفاده می‌شود، شامل ۲۲۱۶۶ کاربر است که به حداقل یک قلم از ۲۹۶۷۷ قلم در بازه زمانی بین ۱۹۹۹/۷/۵ تا ۲۰۱۱/۵/۸ امتیاز داده‌اند. تعداد کل امتیازات و روابط اعتماد به ترتیب برابر ۹۲۲۲۶۷ و ۳۰۰۵۴۸ است. مجموعه داده‌ها به یازده دوره زمانی تقسیم می‌شوند. به دلیل آن که اطلاعات مربوط به روابط اعتماد قبل از تاریخ ۲۰۰۱/۶/۱۱ در دسترس نیست، همه داده‌های قبل از این تاریخ به عنوان نخستین دوره زمانی و داده‌های بعد از تاریخ ۲۰۱۰/۶/۱۱ به عنوان دوره زمانی یازدهم در نظر گرفته می‌شود. هر یک از سایر دوره‌های زمانی شامل داده‌های یک‌ساله هستند.

۲-۵- روش‌های مورد مقایسه

مدل پیشنهادی با روش‌های زیر مقایسه و ارزیابی می‌شود:

- ۱- روش TimeSVD++ [12]: به عنوان یک روش پایه، با در نظر گرفتن پویایی علایق کاربران در طول زمان، و تجزیه ماتریس امتیازات، اقلام مناسب را به کاربران پیشنهاد می‌کند.

- ۲- روش BTMF [44]: یک روش تجزیه ماتریس بیزین است که پویایی علایق کاربران را با آموزش یک ماتریس انتقال بردار ویژگی‌های هر کاربر بین دو دوره زمانی متوالی استخراج می‌کند.

- ۳- روش DMNMF [11]: روشی مبتنی بر تجزیه نامنفی ماتریس است که ویژگی‌های مشترک اقلام و ویژگی‌های زمانی کاربران را ادغام و با آموزش یک ماتریس انتقال حالت، تغییرات علایق کاربران در طول زمان را استخراج می‌کند.

- ۴- روش TMF^۱ [15]: یک مدل مبتنی بر تجزیه ماتریس است که با اصلاح روش کاهش گرادین برای آموزش بردار ویژگی‌های پنهان هر کاربر در هر دوره زمانی، و همچنین استفاده از رگرسیون لاسو، الگوی تغییر علایق کاربران در طول زمان را استخراج می‌کند.

- ۵- روش CMF^۲ [27]: این روش با در نظر گرفتن منابع اطلاعاتی مختلف در قالب چند ماتریس که دارای رابطه با هم هستند، پیش‌بینی امتیازات را بر

مبنای روش تجزیه ماتریس‌های اتصالی و بدون در نظر گرفتن پویایی علایق کاربران انجام می‌دهد. در اینجا دو ماتریس امتیازات و اعتماد را به عنوان ماتریس‌های اتصالی در روش CMF انتخاب می‌کنیم.

- ۶- روش TrustPMF^۳ [37]: این روش علاوه بر امتیازات، از انتشار اعتماد بین کاربران نیز در پیش‌بینی امتیازات استفاده می‌کند. TrustPMF بر مبنای این واقعیت که امتیاز کاربر به یک قلم محصول می‌تواند از کاربران معتمد او تأثیر پذیرد و همچنین نظرات این کاربر بر امتیازات کاربرانی که به او اعتماد دارند، مؤثر است، امتیازات کاربران به اقلام را با تجزیه احتمالاتی ماتریس‌های اتصالی امتیازات و اعتماد، پیش‌بینی می‌کند. این روش در مقایسه با مدل‌های معروف پیشنهاددهنده مبتنی بر اعتماد از دقت بهتری برخوردار است.

- ۷- روش TimeTrustSVD^۴ [32]: یک مدل تجزیه ماتریس بر اساس تجزیه مقدار تکین است که با در نظر گرفتن تأثیر زمان بر علایق کاربران و تغییر تمایل به اقلام، از ترکیب امتیازات، اطلاعات زمانی و روابط اعتماد بین کاربران برای پیش‌بینی امتیازات استفاده می‌کند.

جدول (۱) تفاوت روش‌های مورد مقایسه را بر مبنای منظور کردن پویایی زمانی و استفاده از اعتماد نشان می‌دهد.

جدول (۱): تفاوت روش‌های مورد مقایسه
(Table-1): Differences between comparison methods

روش	پویایی زمانی	اعتماد
TimeSVD++	بله	خیر
BTMF	بله	خیر
DMNMF	بله	خیر
TMF	بله	خیر
CMF	خیر	بله
TrustPMF	خیر	بله
TimeTrustSVD	بله	بله
روش پیشنهادی ما	بله	بله

در ارزیابی‌ها، مقادیر بهینه برای پارامترها در هر روش، توسط ارائه‌دهندگان آن روش تعیین و یا با آزمایش مقادیر مختلف توسط ما به دست می‌آیند. بر این اساس در روش‌های TimeSVD++، CMF و مدل پیشنهادی ما، مقدار پارامتر نرخ یادگیری برابر 0.003، در روش TMF

³ Probabilistic Matrix Factorization with Trust relations

⁴ Singular Value Decomposition with Time and Trust

¹ Temporal Matrix Factorization

² Collective Matrix Factorization

اصلی انجام شدند. برای ارزیابی، داده‌های امتیازات و اعتماد در هر دوره زمانی (به‌جز نخستین دوره زمانی) به‌عنوان مجموعه آزمایش و همه دوره‌های زمانی قبل از آن به‌عنوان مجموعه آموزشی در نظر گرفته می‌شود. در نتیجه، ۱۰ حالت ارزیابی مختلف (Case-1 تا Case-10) به‌وجود می‌آید. برای مثال، وقتی چهارمین دوره زمانی به‌عنوان مجموعه آزمایش انتخاب می‌شود، همه سه دوره زمانی قبل از آن به‌عنوان مجموعه آموزشی در نظر گرفته می‌شود.

برابر 0.02 و در روش TimeTrustSVD برابر 0.001 منظور شد. همچنین در مدل پیشنهادی، $\lambda_T = 5$ و $\varepsilon = 10^{-6}$ انتخاب شدند. به‌منظور مقایسه عادلانه، همانند مطالعات [21, 37, 40] در همه روش‌های مورد مقایسه، اندازه بُعد بردارهای ویژگی‌های پنهان برابر ۱۰ و مقدار پارامترهای تنظیم‌سازی عدد 0.001 انتخاب شد.

مدل پیشنهادی با استفاده از نرم‌افزار متلب نسخه 2016a پیاده‌سازی و آزمایش‌های تحت ویندوز ۱۰ روی رایانه‌ای با پردازنده اینتل Corei5 با ۸ گیگابایت حافظه

(جدول ۲): نتایج کارایی روش‌های مقایسه شده

(Table-2) The performance results of comparative methods

Method	Metrics	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8	Case-9	Case-10	Average±Std
TimeSVD++	MAE	1.2819	1.2114	1.2184	1.1758	1.1814	1.1898	1.1423	1.1141	1.129	1.1046	1.1749±0.0545
	RMSE	1.4185	1.4111	1.4192	1.3624	1.3344	1.3367	1.2998	1.2645	1.2708	1.2591	1.3377±0.0638
BTMF	MAE	1.0153	0.998	0.9949	0.9415*	0.941*	0.9378*	0.9589	0.9654	0.9862	1.0141	0.9753±0.0302
	RMSE	1.28	1.2703	1.2814	1.2145	1.2141*	1.1734	1.1203*	1.1269*	1.1413	1.1291*	1.1951±0.0658
DMNMF	MAE	1.2639	1.2401	1.2134	1.2095	1.1954	1.1154	1.1192	1.0814	1.0214	1.033	1.1493±0.0868
	RMSE	1.3871	1.3943	1.3814	1.3819	1.3312	1.2767	1.2815	1.2293	1.2108	1.2215	1.3096±0.0744
TMF	MAE	1.2723	1.2471	1.246	1.2191	1.1648	1.1621	1.1576	1.1053	1.1104	1.1027	1.1036±0.0635
	RMSE	1.3904	1.3812	1.3802	1.3296	1.3195	1.3013	1.2843	1.2428	1.2456	1.2437	1.3119±0.0584
CMF	MAE	1.1859	1.1151	1.0904	1.0497	0.9701	0.9665	0.9998	0.9649	0.9971	1.004	1.0344±0.0745
	RMSE	1.3512	1.3476	1.3272	1.29	1.2652	1.1376*	1.1385	1.1286	1.1257*	1.1354	1.2247±0.0997
TrustPMF	MAE	1.1438	1.108	1.0636	1.0319	0.9742	0.9691	0.9696	0.9704	0.9805	0.9911	1.0202±0.0643
	RMSE	1.3314	1.3256	1.3207	1.3151	1.2614	1.2322	1.1291	1.1278	1.1259	1.1311	1.23±0.0926
TimeTrustSVD	MAE	0.9971*	0.9766*	0.9763*	0.9775	0.9833	0.9711	0.9584*	0.9612*	0.9711*	0.9732*	0.9745±0.0109
	RMSE	1.1913*	1.2009*	1.2119*	1.2022*	1.2265	1.204	1.197	1.1683	1.1696	1.1729	1.1945±0.0192
Our model	MAE	0.8674	0.8713	0.8791	0.8722	0.9054	0.9121	0.9047	0.9521	0.9683	0.9697	0.9102±0.0401
	RMSE	1.1212	1.1261	1.1463	1.1406	1.1532	1.119	1.0985	1.1128	1.1206	1.1213	1.126±0.0164
Improve	MAE	13.01%	10.78%	9.96%	7.36%	3.78%	2.74%	5.6%	0.95%	0.29%	0.36%	6.6%
	RMSE	5.88%	6.23%	5.41%	5.12%	5.02%	1.64%	1.95%	1.25%	0.45%	0.69%	5.73%

۴-۵- نتایج

نتایج کارایی روش‌های مقایسه‌شده در جدول (۲) مشاهده می‌شود. اعداد پررنگ بیان‌گر بهترین نتیجه هستند. نماد ستاره (*) در جدول بیان‌گر بهترین نتیجه در بین روش‌های مقایسه‌شده، به‌جز مدل پیشنهادی ما است. سطر آخر جدول، (سطر 'improve') درصد بهبودی را که مدل پیشنهادی نسبت به نتایج ستاره‌دار به‌دست می‌آورد؛ نشان می‌دهد. نتایج نشان می‌دهند که مدل پیشنهادی بهترین کارایی را بر حسب هر دوی MAE و RMSE در همه حالت‌های ارزیابی دارد.

برتری مدل پیشنهادی نسبت به روش‌های TimeSVD++, BTMF, DMNMF و TMF که فقط پویایی زمانی علایق را در پیش‌بینی امتیازات در نظر می‌گیرند و از اعتماد استفاده نمی‌کنند، بیان‌گر این نتیجه است که رویکرد پیشنهادی ما در استخراج علایق پویای کاربران بهتر عمل کرده و از آنجایی که امتیازات داده‌شده بر اساس زمان به چند دوره زمانی تقسیم می‌شوند که در

۳-۵- معیارهای ارزیابی

معیارهای ارزیابی مورد استفاده، خطای میانگین قدر مطلق^۱ (MAE) و خطای جذر میانگین مربعات^۲ (RMSE) هستند که معروف‌ترین معیارها در ارزیابی امتیازات پیش‌بینی شده، هستند [38]. این معیارها به‌صورت زیر تعریف می‌شوند:

$$MAE = \frac{\sum_{(i,j) \in R_{test}^{(t)}} |\hat{R}_{ij}^{(t)} - R_{ij}^{(t)}|}{|R_{test}^{(t)}|} \quad (14)$$

$$RMSE = \sqrt{\frac{\sum_{(i,j) \in R_{test}^{(t)}} |\hat{R}_{ij}^{(t)} - R_{ij}^{(t)}|^2}{|R_{test}^{(t)}|}} \quad (15)$$

در روابط بالا، $R_{test}^{(t)}$ مجموعه امتیازات در مجموعه آزمایش است. مقادیر کوچک‌تر MAE یا RMSE بیان‌گر پیش‌بینی دقیق‌تر هستند.

¹ Mean Absolute Error

² Root Mean Square Error

نتیجه تعداد امتیازات در هر دوره زمانی بسیار کم می‌باشد، استفاده از اعتماد در مدل ما باعث کاهش این مشکل خلوتی داده‌ها شده و به افزایش دقت پیش‌بینی‌ها کمک می‌کند. از طرفی، برتری مدل پیشنهادی بر روش‌های مبتنی بر اعتماد CMF و TrustPMF که پویایی زمانی علائق کاربران را در نظر نمی‌گیرند، نشان می‌دهد که منظور کردن پویایی زمانی در کنار اعتماد در مدل ما منجر به افزایش دقت پیشنهادها می‌شود. به‌عنوان یک نتیجه، برتری مدل پیشنهادی بر شش روش مقایسه‌شده یاشده، بیان‌گر این است که پویایی زمانی و اعتماد مکمل هم بوده و رویکرد پیشنهادی در تجزیه ماتریس‌های اتصال امتیازات و اعتماد بین کاربران بر اساس پویایی زمانی علائق آن‌ها بهتر می‌تواند امتیازات را پیش‌بینی کند.

همان‌طور که در جدول (۲) مشاهده می‌شود، روش مبتنی بر اعتماد TimeTrustSVD که پویایی زمانی علائق را در پیش‌بینی امتیازات در نظر می‌گیرد، دومین بهترین کارایی را در بیشتر حالت‌ها و روش BTMF دومین بهترین کارایی را در تعدادی از حالت‌ها دارد. به‌طور میانگین روش TimeTrustSVD بعد از مدل پیشنهادی ما، بهترین کارایی را دارد. این مشاهدات بار دیگر بیان‌کننده این است که پویایی زمانی و روابط اعتماد، مکمل هم هستند و در کنار یکدیگر می‌توانند باعث افزایش دقت در پیش‌بینی امتیازات شوند. دقت بهتر مدل پیشنهادی نسبت به روش TimeTrustSVD بیان‌گر این است که ماتریس انتقال ارائه‌شده در مدل ما بر مبنای این که علائق کاربر به‌صورت هموار تغییر می‌کند و یادگیری ویژگی‌های پنهان در دوره زمانی فعلی با استفاده از داده‌های دوره زمانی قبل مفید است. همچنین مدل‌سازی علائق پویای کاربران با در نظر گرفتن منحصربه‌فرد بودن الگوی تغییر علائق هر کاربر، منجر به بهبود دقت پیشنهادهای ارائه‌شده می‌شود.

روش پیشنهاددهنده زمانی BTMF که از اعتماد استفاده نمی‌کند، به‌طور میانگین عملکرد بهتری نسبت به روش‌های TimeSVD++, TMF, DMNMF, CMF و TrustPMF دارد. این روش، به‌طور میانگین، دقتی نزدیک به روش TimeTrustSVD نیز دارد. این نتایج می‌تواند به این دلیل باشد که BTMF همانند مدل پیشنهادی از این واقعیت که علائق کاربران به‌صورت هموار تغییر می‌کنند [13, 15, 31] و همچنین هر کاربر الگوی تغییر علائق مخصوص به خود را دارد [23, 31]، استفاده می‌کند و

برای هر کاربر یک ماتریس انتقال علائق آموزش داده می‌شود. دقت بیشتر مدل پیشنهادی ما نسبت به BTMF به‌دلیل ترکیب امتیازات و اعتماد در مدل پیشنهادی و همچنین تفاوت در نحوه آموزش ماتریس‌های انتقال است. برخلاف روش‌های مورد مقایسه، در مدل پیشنهادی فقط از داده‌های مربوط به دوره زمانی قبلی برای آموزش مدل استفاده می‌شود. از نتایج جدول (۲) و برتری مدل پیشنهادی می‌توان نتیجه گرفت که انتخاب این داده‌ها به‌عنوان مجموعه آموزشی، می‌تواند دقت پیش‌بینی امتیازات در دوره فعلی را بهبود بخشد. این نتیجه به این معنی است که علائق و رفتارهای بسیار قدیمی کاربران، واقعاً نمی‌توانند منعکس‌کننده علائق فعلی آن‌ها باشند [43].

به‌منظور بررسی معنادار بودن میزان بهبود دقت در مدل پیشنهادی نسبت به سایر روش‌های مقایسه‌شده از نظر آماری، از آزمون آماری t زوجی^۱ با سطح معنی‌داری ۰/۰۵ ($\alpha = 0.05$) استفاده می‌کنیم. این آزمون بین مقادیر MAE و RMSE مدل پیشنهادی و هر یک از روش‌های دیگر به‌صورت جداگانه انجام که مقادیر p-value به‌دست‌آمده در جدول (۳) مشاهده می‌شود. با توجه به این که این مقادیر کمتر از ۰/۰۵ هستند، می‌توان نتیجه گرفت که میزان بهبود مدل پیشنهادی در مقایسه با سایر روش‌های مقایسه شده از نظر آماری معنادار است.

(جدول-۳): مقادیر p-value آزمون t-test بین

نتایج مدل پیشنهادی و روش‌های مورد مقایسه
(Table-3) The p-values of the t-test between the results of the proposed model and the other methods



	MAE	RMSE
TimeSVD++	0	0
BTMF	0.0021	0.0042
DMNMF	0.0002	0
TMF	0	0
CMF	0.0049	0.0075
TrustPMF	0.0058	0.0033
TimeTrustSVD	0.0018	0

به‌اختصار، نتایج آزمایش‌ها بیان‌گر این است که مدل پیشنهادی در استخراج و مدل‌سازی علائق پویای کاربران در طول زمان نسبت به روش‌های مقایسه‌شده، برتری داشته و باعث بهبود دقت پیشنهادها به کاربران و در نتیجه افزایش رضایت آن‌ها در سامانه پیشنهاددهنده می‌شود. اگر چه بهبود در مدل پیشنهادی کم است (به‌طور میانگین حدود ۶/۶ درصد در MAE و ۵/۷۳ درصد در RMSE)، ولی حتی بهبود کم در دقت، نیز می‌تواند تأثیر قابل توجهی در کیفیت پیشنهادها در عمل داشته باشد [10, 12, 31].

¹ Paired t-test

۵-۵- تأثیر پارامتر λ_T

پارامتر λ_T میزان تأثیر اعتماد بر علایق کاربران را در مدل پیشنهادی کنترل می‌کند. برای بررسی تأثیر مقادیر مختلف این پارامتر بر دقت پیشنهادها، مدل پیشنهادی به‌ازای مقادیر ۰/۱، ۰/۵، ۱، ۲، ۵، ۱۰ و ۲۰ برای این پارامتر مورد ارزیابی قرار گرفت که نتایج در شکل (۴) مشاهده می‌شوند. این نتایج نشان می‌دهند که پارامتر λ_T تأثیر قابل توجهی بر دقت پیشنهادها دارد و ترکیب ماتریس امتیازات و اعتماد می‌تواند به بهبود دقت پیشنهادها کمک کند. با افزایش λ_T میانگین MAE و RMSE در ابتدا کاهش می‌یابد ولی هنگامی که λ_T از یک مقدار آستانه (مقدار پنج) بیشتر می‌شود میانگین MAE و RMSE شروع به افزایش می‌کند. نتایج بیان‌گر این است که فقط استفاده از ماتریس امتیازات و یا فقط استفاده از ماتریس اعتماد نمی‌تواند نتایج بهتری از ترکیب این دو ماتریس با هم تولید کند. مدل پیشنهادی به‌ازای مقدار ۵ برای λ_T بیشترین دقت را دارد.





(شکل ۴): تأثیر مقادیر مختلف λ_T (الف) MAE (ب) RMSE
(Figure-4): Impact of different values of λ_T (a) MAE and (b) RMSE

۵-۶- تأثیر اندازه دوره زمانی

یک مسئله بحرانی در سامانه‌های پیشنهاددهنده زمانی، انتخاب اندازه مناسب برای دوره‌های زمانی است [13]. انتخاب مقدار مناسب برای اندازه دوره زمانی (به‌عنوان مثال هفته، سال) در مجموعه داده‌های مختلف، متفاوت است و به‌طور معمول به کاربرد سامانه پیشنهاددهنده

بستگی دارد [23]. برای بررسی تأثیر مقادیر مختلف آن بر روی کارایی سامانه، با توجه به اینکه اطلاعات مربوط به زمان در داده‌های مربوط به اعتماد در مجموعه داده‌های Epinions مورد استفاده به‌صورت سال، در دسترس است، به‌ازای اندازه‌های دوره‌های زمانی یک، دو و سه سال، روش‌های مورد مقایسه‌ای که پویایی زمانی را در نظر می‌گیرند، ارزیابی شدند. شکل (۵) کارایی روش‌های مورد مقایسه برحسب MAE و RMSE را به‌ازای مقادیر مختلف اندازه دوره زمانی نشان می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، به‌ازای اندازه دوره زمانی برابر یک‌سال، همه روش‌ها بهترین کارایی خود را داشته‌اند و وقتی اندازه دوره زمانی به دو و یا سه سال افزایش می‌یابد، کارایی همه روش‌ها کاهش می‌یابد. این نتایج به این معنی است که در مجموعه داده یادشده، انتخاب اندازه طولانی‌تر بازه زمانی باعث ازدست‌دادن تغییرات رفتار کاربران در درون آن بازه زمانی و در نتیجه نبود منظورشدن آن‌ها در مدل‌سازی می‌شود.

نکته قابل توجهی دیگری که می‌توان مشاهده کرد، اینست که مدل پیشنهادی به‌ازای همه اندازه‌های دوره زمانی متفاوت آزمایش شده، کارایی بهتری نسبت به سایر روش‌ها دارد.



(شکل ۵): تأثیر اندازه دوره زمانی (الف) MAE (ب) RMSE
(Figure-5): Impact of different length of the time period (a) MAE and (b) RMSE

علائق کاربران در سامانه‌های پیشنهاددهنده در اثر عوامل مختلفی با گذشت زمان تغییر می‌کنند. در نظر گرفتن تغییرات زمانی و مدل‌سازی دقیق پویایی علایق کاربران به منظور ارائه پیشنهادهای مناسب‌تر و جلب رضایت کاربران ضروری بوده و یک چالش مهم به‌شمار می‌رود. در این مقاله با در نظر گرفتن پویایی علایق کاربران در طول زمان، و این واقعیت که روابط اجتماعی می‌توانند بر علایق کاربران در یک سامانه پیشنهاددهنده، تأثیرگذار باشند، یک مدل پیشنهاددهنده اجتماعی ارائه شد. مدل پیشنهادی با توسعه روش تجزیه ماتریس و ترکیب امتیازات و اطلاعات اعتماد بین کاربران، امتیازات کاربران به اقلام را پیش‌بینی می‌کند. نتایج ارزیابی نشان می‌دهد که پویایی زمانی و روابط اعتماد در جهت افزایش دقت سامانه‌های پیشنهاددهنده مکمل هم هستند و مدل پیشنهادی نسبت به روش‌های مقایسه‌شده، از عملکرد بهتری برخوردار است. این مدل، این واقعیت را که استخراج پویایی علایق کاربران بر اساس منحصربه‌فرد بودن الگوی تغییر علایق هر کاربر، منجر به بهبود دقت پیشنهادهای ارائه‌شده به کاربران و در نتیجه افزایش رضایت آن‌ها از سامانه می‌شود، را تقویت می‌کند. همچنین تحلیل پیچیدگی زمانی مدل پیشنهادی بیان‌گر مقیاس‌پذیری آن است.

برای پژوهش‌های آینده، استفاده از هر دوی اطلاعات اعتماد و عدم اعتماد کاربران و همچنین اعمال درجه تأثیرپذیری هر کاربر از افراد مورد اعتماد، در مدل پیشنهادی مورد توجه است. توسعه مدل برای مقابله با مسأله شروع کاربران سرد در حالتی که کاربر در دوره زمانی قبلی، هیچ داده امتیازدهی و همچنین اطلاعات اعتماد ندارد، نیز مدنظر خواهد بود. یک راه‌کار ممکن، استفاده از اطلاعات اضافی دیگر نظیر ویژگی‌های دموگرافی کاربران، علاوه بر ماتریس‌های امتیازات و اعتماد است. مقادیر بهینه برای پارامترهای مدل همانند اغلب روش‌های دیگر از طریق جستجوی تصادفی تعیین می‌شوند. در آینده، ارائه یک روش کارا که بتواند این پارامترها را به‌طور خودکار تنظیم کند، به‌خصوص وقتی اندازه‌ی مجموعه داده‌ها بزرگ می‌باشد، مدنظر است.

۷- مراجع

[۱] حسینی منیره، نصرالهی مقصود، بقائی علی، "یک سامانه توصیه‌گر ترکیبی با استفاده از اعتماد و خوشه‌بندی دوجته به‌منظور افزایش کارایی پالایش‌گروهی"، پردازش علائم و داده‌ها، ۱۵ (۲):

- [1] M. Hosseini, M. Nasrollahi, and A. Baghaei. "A hybrid recommender system using trust and bi-clustering in order to increase the efficiency of collaborative filtering". *JSDP*, vol 15, no. 2, pp.119-132, 2018.
- [2] A. Y. Aravkin, K. R. Varshney, and L. Yang, "Dynamic matrix factorization with social influence," in *2016 IEEE International Workshop on Machine Learning for Signal Processing*, 2016, pp. 1–6.
- [3] H. Bao, Q. Li, S. S. Liao, S. Song, and H. Gao, "A new temporal and social PMF-based method to predict users' interests in micro-blogging," *Decision Support Systems*, vol. 55, no. 3, pp. 698–709, 2013.
- [4] I. Barjasteh, R. Forsati, D. Ross, A. H. Esfahanian, and H. Radha, "Cold-start recommendation with provable Guarantees: A decoupled approach," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 6, pp. 1462–1474, 2016.
- [5] J. Cheng, Y. Liu, H. Zhang, X. Wu, and F. Chen, "A new recommendation algorithm based on user's dynamic information in complex social network," *Mathematical Problems in Engineering*, vol. 2015, pp. 1-6, 2015.
- [6] W. Cheng, G. Yin, Y. Dong, H. Dong, and W. Zhang, "Collaborative filtering recommendation on users' interest sequences," *Plos One*, vol. 11, no. 5, p. e0155739, 2016.
- [7] W.-S. Chin, B.-W. Yuan, M.-Y. Yang, Y. Zhuang, Y.-C. Juan, and C.-J. Lin, "LIBMF: a library for parallel matrix factorization in shared-memory systems," *The Journal of Machine Learning Research*, vol. 17, no. 1, pp. 2971–2975, 2016.
- [8] E. Frolov and I. Oseledets, "Tensor methods and recommender systems," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 7, no. 3, pp. 1–41, 2017.
- [9] J. Gaillard, "Recommender systems : Dynamic adaptation and argumentation.", Ph.D. dissertation, Dept. Computer Science, Avignon Univ., Avignon, France, 2014.
- [10] G. Guo, J. Zhang, and N. Yorke-Smith, "A novel recommendation model regularized with user trust and item ratings," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 7, pp. 1607–1620, 2016.
- [11] B. Ju, Y. Qian, M. Ye, R. Ni, and C. Zhu, "Using dynamic multi-task non-negative matrix factorization to detect the evolution of user preferences in collaborative filtering," *PLoS ONE*, vol. 10, no. 8, pp. 1–20, 2015.
- [12] Y. Koren, "Collaborative filtering with temporal dynamics," *Communications of the ACM*, vol. 53, no. 4, pp. 89–97, 2010.

- 14, pp. 21–30, 2014.
- [25] N. Sahoo, D. A. Tepper, and T. Mukhopadhyay, “A hidden markov model for collaborative filtering,” *MIS Quarterly*, vol. 36, no. 4, pp. 1329–1356, 2012.
- [26] Y. Shi, M. Larson, and A. Hanjalic, “Collaborative filtering beyond the user-item matrix: A survey of the state of the art and future challenges,” *ACM Computing Surveys (CSUR)*, vol. 47, no. 1, p. 3, 2014.
- [27] A. P. Singh and G. J. Gordon, “Relational learning via collective matrix factorization,” *Proceeding of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining - KDD 08*, 2008, pp. 650–658.
- [28] J. Z. Sun, D. Parthasarathy, and K. R. Varshney, “Collaborative kalman filtering for dynamic matrix factorization,” *IEEE Transactions on Signal Processing*, vol. 62, no. 14, pp. 3499–3509, 2014.
- [29] H. Tahmasbi, M. Jalali, and H. Shakeri, “Modeling Temporal Dynamics of User Preferences in Movie Recommendation,” in *2018 8th International Conference on Computer and Knowledge Engineering (ICCCKE)*, 2018, pp. 194–199.
- [30] J. Tang, “Epinions Dataset.” [Online]. Available: <http://www.cse.msu.edu/~tang-jili/trust.html>. [Accessed: 05-Jan-2018].
- [31] J. Tang, H. Gao, A. Das Sarma, Y. Bi, and H. Liu, “Trust evolution: Modeling and its applications,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 27, no. 6, pp. 1724–1738, 2015.
- [32] C. Tong, J. Qi, Y. Lian, J. Niu, and J. J. P. C. Rodrigues, “TimeTrustSVD: A collaborative filtering model integrating time, trust and rating information,” *Future Generation Computer Systems*, vol. 93, pp. 933–941, 2019.
- [33] J. Wang, S. Zhang, X. Liu, Y. Jiang, and M. Zhang, “A novel collective matrix factorization model for recommendation with fine-grained social trust prediction,” *Concurrency Computation*, vol. 29, no. 19, pp. 1–14, 2017.
- [34] H. Wu, K. Yue, Y. Pei, B. Li, Y. Zhao, and F. Dong, “Collaborative topic regression with social trust ensemble for recommendation in social media systems,” *Knowledge-Based Systems*, vol. 97, pp. 111–122, 2016.
- [35] T. Wu, Y. Feng, J. Sang, B. Qiang, and Y. Wang, “A novel recommendation algorithm incorporating temporal dynamics, reviews and item correlation,” *IEICE TRANSACTIONS on Information and Systems*, vol. 101, no. 8, pp. 2027–2034, 2018.
- [36] L. Xiong, X. Chen, T.-K. Huang, J. Schneider, and J. G. Carbonell, “Temporal collaborative filtering with bayesian probabilistic tensor
- [13] S. Li and Y. Fu, “Robust representations for response prediction,” in *Robust Representation for Data Analytics*, Springer, pp. 147–174, 2017.
- [14] D. R. Liu, K. Y. Chen, Y. C. Chou, and J. H. Lee, “Online recommendations based on dynamic adjustment of recommendation lists,” *Knowledge-Based Systems*, vol. 161, pp. 375–389, 2018.
- [15] Y. Y. Lo, W. Liao, C. S. Chang, and Y. C. Lee, “Temporal matrix factorization for tracking concept drift in individual user preferences,” *IEEE Transactions on Computational Social Systems*, vol. 5, no. 1, pp. 156–168, 2018.
- [16] W. Lu, S. Ioannidis, S. Bhagat, and L. V. S. Lakshmanan, “Optimal recommendations under attraction, aversion, and social influence,” *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining - KDD '14*, 2014, pp. 811–820.
- [17] C. Luo, X. Cai, and N. Chowdhury, “Self-training temporal dynamic collaborative filtering,” in *Proceedings of the 18th Pacific-Asia Conference on Knowledge Discovery and Data Mining*, Springer, 2014, pp. 461–472.
- [18] A. Mnih and R. Salakhutdinov, “Probabilistic matrix factorization,” in *Advances in Neural Information Processing Systems*. Cambridge, MA, USA: MIT Press, 2008, pp. 1257–1264.
- [19] J. Pan, Z. Ma, Y. Pang, and Y. Yuan, “Robust probabilistic tensor analysis for time-variant collaborative filtering,” *Neurocomputing*, vol. 119, pp. 139–143, 2013.
- [20] F. S. F. Pereira, J. Gama, S. de Amo, and G. M. B. Oliveira, “On analyzing user preference dynamics with temporal social networks,” *Machine Learning*, vol. 107, no. 11, pp. 1745–1773, 2018.
- [21] D. Rafailidis, “Modeling trust and distrust information in recommender systems via joint matrix factorization with signed graphs,” in *Proceedings of the 31st Annual ACM Symposium on Applied Computing*, 2016, pp. 1060–1065.
- [22] D. Rafailidis, P. Kefalas, and Y. Manolopoulos, “Preference dynamics with multimodal user-item interactions in social media recommendation,” *Expert Systems with Applications*, vol. 74, pp. 11–18, 2017.
- [23] D. Rafailidis and A. Nanopoulos, “Modeling users preference dynamics and side information in recommender systems,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 46, no. 6, pp. 782–792, 2016.
- [24] C. Rana and S. K. Jain, “An evolutionary clustering algorithm based on temporal features for dynamic recommender systems,” *Swarm and Evolutionary Computation*, vol.



دانشگاه آزاد اسلامی واحد کاشمر فعالیت دارد. زمینه‌های پژوهشی مورد علاقه ایشان داده‌کاوی و تحلیل شبکه‌های اجتماعی است.

نشانی رایانامه ایشان عبارت است از:

htahma@gmail.com



مهرداد جلالی در سال ۱۳۷۷

کارشناسی خود را در رشته مهندسی رایانه گرایش نرم‌افزار در دانشگاه آزاد اسلامی واحد مشهد اخذ کرده و کارشناسی ارشد را در رشته هوش مصنوعی و رباتیک در سال ۱۳۸۰ در دانشگاه علوم و تحقیقات تهران به پایان رساند. از آن تاریخ عضو هیأت علمی دانشگاه آزاد اسلامی واحد مشهد است. ایشان دکترای خود را در سال ۱۳۸۸ در دانشگاه یوی‌ام مالزی به اتمام رساند. همچنین به مدت یک سال به‌عنوان پژوهش‌گر ارشد در شرکت میموس مالزی در حوزه وب‌معنایی مشغول به کار بوده است. وی در حال حاضر دانشیار گروه رایانه دانشگاه آزاد اسلامی واحد مشهد و همچنین پژوهش‌گر انستیتو فناوری کارلسروهه آلمان است. حاصل تلاش ایشان در طی این سال‌ها چاپ مقاله در بیش از ۱۵۰ کنفرانس و ژورنال در زمینه‌های داده‌کاوی، یادگیری ماشین، وب معنایی، و تحلیل شبکه‌های اجتماعی است.

نشانی رایانامه ایشان عبارت است از:

Mehrdad.jalali@kit.edu



حسن شاکری مدرک کارشناسی خود

را در سال ۱۳۷۴ و کارشناسی ارشد خود را در سال ۱۳۷۶ در رشته مهندسی رایانه به‌ترتیب از دانشگاه‌های فردوسی مشهد و صنعتی شریف اخذ کرد و دکترای خود را در رشته مهندسی رایانه از دانشگاه فردوسی مشهد در سال ۱۳۹۳ به پایان رساند. هم‌اکنون استادیار گروه مهندسی رایانه و مدیر کل فناوری اطلاعات دانشگاه آزاد اسلامی واحد مشهد است و تاکنون بیش از ۱۰۰ مقاله در ژورنال‌ها و کنفرانس‌های ملی و بین‌المللی از ایشان به چاپ رسیده است. زمینه پژوهشی مورد علاقه ایشان مدیریت اعتماد، امنیت سامانه‌های رایانه‌ای، تحلیل شبکه‌های اجتماعی و پردازش متن است. نشانی رایانامه ایشان عبارت است از:

shakeri@mshdiau.ac.ir

factorization,” in *Proceedings of the 2010 SIAM International Conference on Data Mining*, 2010, pp. 211–222.

- [37] B. Yang, Y. Lei, J. Liu, and W. Li, “Social collaborative filtering by trust,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 8, pp. 1633–1647, Aug. 2017.
- [38] X. Yang, Y. Guo, Y. Liu, and H. Steck, “A survey of collaborative filtering based social recommender systems,” *Computer Communications*, vol. 41, pp. 1–10, 2014.
- [39] H. Yin, B. Cui, L. Chen, Z. Hu, and Z. Huang, “A temporal context-aware model for user behavior modeling in social media systems,” in *Proceedings of the 2014 ACM SIGMOD international conference on Management of data*, 2014, no. 1, pp. 1543–1554.
- [40] Y. Yu, Y. Gao, H. Wang, and R. Wang, “Joint user knowledge and matrix factorization for recommender systems,” *World Wide Web*, vol. 21, no. 4, pp. 1141–1163, 2018.
- [41] F. Yu, A. Zeng, S. Gillard, and M. Medo, “Network-based recommendation algorithms: A review,” *Physica A: Statistical Mechanics and its Applications*, vol. 452, pp. 192–208, 2016.
- [42] Z. Zhang and H. Liu, “Social recommendation model combining trust propagation and sequential behaviors,” *Applied Intelligence*, vol. 43, no. 3, pp. 695–706, 2015.
- [43] F. Zhang, Q. Liu, and A. Zeng, “Timeliness in recommender systems,” *Expert Systems with Applications*, vol. 85, pp. 270–278, 2017.
- [44] C. Zhang, K. Wang, H. Yu, J. Sun, and E.-P. Lim, “Latent factor transition for dynamic collaborative filtering,” in *Proceedings of the 2014 SIAM International Conference on Data Mining*, 2014, pp. 452–460.
- [45] W. Zhang, Y. Du, T. Yoshida, and Y. Yang, “DeepRec: A Deep Neural Network Approach to Recommendation with Item Embedding and Weighted Loss Function,” *Information Sciences*, vol. 470, pp. 121–140, 2019.
- [46] B. Zou, C. Li, L. Tan, and H. Chen, “GPU-TENSOR: efficient tensor factorization for context-aware recommendations,” *Information Sciences*, vol. 299, pp. 159–177, 2015.



حمیدرضا طهماسبی مدرک

کارشناسی و کارشناسی ارشد خود را در رشته مهندسی رایانه گرایش نرم‌افزار از دانشگاه آزاد اسلامی واحد مشهد اخذ و دانش‌آموخته مقطع دکترا در رشته مهندسی رایانه گرایش سامانه‌های نرم‌افزاری است. هم‌اکنون به‌عنوان عضو هیأت علمی گروه مهندسی رایانه در