

A Temporal Recommendation System Based on Coupled Tensor Factorization

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

1- Department of Computer Engineering, Neyshabur Branch, Islamic Azad University, Neyshabur, Iran.

2*- Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran.

3- Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran.

¹htahma@gmail.com, ^{2*}jalali@mshdiau.ac.ir, and ³shakeri@mshdiau.ac.ir

Corresponding author address: Mehrdad Jalali, Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran, Post Code: 91871 – 47578.

Abstract- Recommender systems analyze the user's preference patterns and provide personalized recommendations of items that will suit a user's taste. An essential challenge in these systems is that user preferences are not static and users are likely to change their preferences over time. The adaptability of recommender systems to capture the evolving user's preferences which are constantly changing, improves the accuracy of recommender systems. In this paper, we develop a model to capture the users' preference dynamics in a personalized manner. We introduce an individual time decay factor for each user according to the rate of his preference dynamics to weight the past user preferences and decrease gradually the importance of them. We exploit the users' demographics as well as the extracted similarities between users over time, in addition to the past weighted user preferences, in a developed coupled tensor-matrix factorization technique to provide the personalized recommendations. Our evaluation results on the two real-world datasets indicate that our proposed model is better and more robust than the competitive methods in term of recommendation accuracy and is more capable to cope with cold-start problem.

Keywords- Temporal recommender systems, Coupled tensor factorization, Users' preference dynamics, Data sparsity, Cold-start.



ارائه‌ی یک سیستم پیشنهاددهنده‌ی زمانی مبتنی بر تجزیه تنسورهای اتصال

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

۱- گروه مهندسی کامپیوتر، واحد نیشابور، دانشگاه آزاد اسلامی، نیشابور، ایران

۲* - گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

۳- گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

¹htahma@gmail.com, ²jalali@mshdiau.ac.ir, and ³shakeri@mshdiau.ac.ir

* نشانی نویسنده مسئول: مهرداد جلالی، مشهد، دانشگاه آزاد اسلامی واحد مشهد، گروه مهندسی کامپیوتر، کد پستی: ۹۱۸۷۱-۴۷۵۷۸

چکیده- سیستم‌های پیشنهاددهنده با تحلیل الگوهای علایق کاربران، آیتم‌ها یا پیشنهادهایی متناسب با علایق کاربر به او ارائه می‌کنند. یک چالش اساسی در این سیستم‌ها این است که علایق کاربران ثابت نبوده و معمولاً کاربران تمایل به تغییر علایق خود در طول زمان دارند. تطبیق سیستم‌های پیشنهاددهنده برای مدل کردن تکامل علایق و نیازهای کاربران که مدام در حال تغییر می‌باشند، باعث بهبود پیشنهادهای ارائه شده به کاربر می‌گردد. در این مقاله با توسعه یک روش مدل‌سازی علایق پویای کاربر، یک سیستم پیشنهاددهنده زمانی ارائه می‌کنیم. در این روش یک تابع کاهش زمانی برای هر کاربر معرفی می‌شود که اهمیت علایق قبلی کاربران براساس نرخ تغییر علایق هر کاربر وزن‌گذاری شده و سپس این اطلاعات به‌مراه اطلاعات استخراج شده‌ی مربوط به شباهت بین کاربران در طول زمان و داده‌های دموگرافی کاربران به ترتیب در دو تنسور و یک ماتریس مدل شده و با استفاده از تکنیک تجزیه تنسور-ماتریس‌های اتصال، پویایی علایق کاربران استخراج و پیشنهادهای شخصی مناسب با هر کاربر ارائه می‌شود. ارزیابی روش پیشنهادی روی دو مجموعه داده‌ی واقعی، بهبود دقت این روش را در پیشنهاد آیتم‌ها به کاربران نسبت به سایر روش‌های مقایسه شده و توانایی بهتر آن در برخورد با مشکل شروع سرد را نشان می‌دهد.

واژه‌های کلیدی: سیستم‌های پیشنهاددهنده‌ی زمانی، تجزیه تنسور-ماتریس‌های اتصال، علایق پویای کاربر، داده‌های خلوت، شروع سرد.

۱- مقدمه

یک مسأله‌ی مهم در سیستم‌های پیشنهاددهنده‌ی واقعی اینست که علایق کاربران ثابت نبوده و معمولاً کاربران تمایل به تغییر علایق خود در طول زمان دارند، به ویژه در سیستم‌های پیشنهاددهنده‌ای که کاربران با تعداد زیادی از آیتم‌ها تعامل دارند. روش‌های متعارف فیلترینگ مشارکتی فرض می‌کنند که داده‌ها ثابت بوده و تأثیرات زمانی در ماهیت داده‌های تولید شده توسط کاربر را مورد توجه قرار نمی‌دهند. در حالی که مطالعات اخیر نشان می‌دهند که دقت نمی‌تواند بدون در نظر گرفتن پویایی زمانی در سیستم‌های پیشنهاددهنده بهبود یابد [۱] و [۲]. و مدل

سیستم‌های پیشنهاددهنده الگوهای علایق کاربران به آیتم‌ها را تحلیل کرده و پیشنهادهایی متناسب با علایق کاربر به او ارائه می‌کنند. این سیستم‌ها با فیلتر کردن اطلاعات مفید از حجم انبوه و رو به رشد اطلاعات، به غلبه بر مسأله‌ی سربار اطلاعاتی به کاربر کمک می‌کنند. موفق‌ترین و پرکاربردترین تکنیکی که در سیستم‌های پیشنهاددهنده استفاده می‌شود، فیلترینگ مشارکتی است که مبتنی بر این فرض است که کاربرانی که علایق مشابهی در گذشته داشته‌اند، در آینده نیز علایق مشابهی خواهند داشت.

ماتریس داده‌های دموگرافی کاربران با استفاده از تکنیک تجزیه تنسور-ماتریس‌های اتصالی^۱ (CTF) [۱۰]، پویایی علایق کاربران را مدل کرده و پیشنهادهای شخصی مناسب با هر کاربر ارائه می‌کنیم. هنگامی که هدف، تخمین داده‌های نامشخص در کاربردهایی از قبیل سیستم‌های پیشنهاددهنده می‌باشد، نشان داده شده است که تکنیک تجزیه تنسور-ماتریس‌های اتصالی بسیار مفید می‌باشد [۱۱]. ارزیابی مدل پیشنهادی بر روی دو مجموعه داده‌ی معروف حاوی تعاملات کاربران مربوط به گوش دادن به موسیقی و همچنین امتیازدهی فیلم‌ها، بهبود دقت این مدل را در پیشنهاد آیت‌ها به کاربران نسبت به سایر روش‌های مقایسه شده و توانایی بهتر آن در برخورد با مسأله شروع سرد را نشان می‌دهد.

در ادامه، در بخش دوم این مقاله، مطالعات مرتبط انجام شده به اختصار بیان شده است. در بخش سوم، مدل تجزیه کانونی تنسور و همچنین تکنیک تجزیه تنسور-ماتریس‌های اتصالی معرفی و روش پیشنهادی در بخش چهارم تشریح می‌شود. نتایج ارزیابی روش پیشنهادی در بخش پنجم ارائه می‌شوند. بخش ششم نیز شامل نتیجه‌گیری و پیشنهاد کارهای آتی می‌باشد.

۲- پیشینه تحقیق

تعدادی از مطالعات مربوط به سیستم‌های پیشنهاددهنده‌ی زمانی [۱۲-۱۶] از توابع کاهش پیوسته و یا پنجره‌های زمانی گسسته استفاده می‌کنند. این رویکرد بر اساس این فرض است که هر چه زمان می‌گذرد، تأثیر تغییر علایق قدیمی‌تر کاربران در پیش‌بینی امتیازدهی کاربران کمتر شده و امتیازدهی‌های اخیر کاربر، علایق فعلی او را بهتر منعکس می‌کنند [۱۷].

بسیاری از سیستم‌های پیشنهاددهنده زمانی، مبتنی بر تجزیه ماتریس هستند [۸]. اولین مدل زمانی مبتنی بر تجزیه ماتریس در [۱۸] پیشنهاد شده است که برای هر کاربر در هر زمان خاص یک بایاس برای استخراج تغییرات محلی علایق کاربران معرفی می‌کند. این مدل از روش تجزیه مقدار منفرد^۲ در تجزیه ماتریس استفاده می‌کند. یک مدل پیشنهاددهنده‌ی مبتنی بر تجزیه ماتریس در [۳] ارائه شده است که روش کاهش گرادیان نزولی را برای یادگیری بردار ویژگی پنهان هر کاربر در هر زمان توسعه می‌دهد. در [۱۹] یک روش تجزیه ماتریس احتمالی گاوسی برای استخراج رفتار تغییر علایق کاربران در طول زمان با استفاده از مدل فضای حالت پویا پیشنهاد شده است. برای آموزش پارامترهای این مدل از رفتار قبلی کاربران، از یک الگوریتم پیشینه سازی امید ریاضی^۳ (EM) و برای تخمین در EM از فیلترینگ کالمن استفاده شده

کردن دقیق علایق پویای کاربران برای راضی نگه داشتن آنها در یک سیستم پیشنهاددهنده ضروری می‌باشد [۳]. امروزه تطبیق سیستم‌های پیشنهاددهنده برای استخراج تکامل علایق و نیازهای کاربران که مدام در حال تغییر می‌باشند، یک زمینه‌ی تحقیقاتی در حال رشد در سیستم‌های پیشنهاددهنده می‌باشد [۴] و اگر چه تاکنون روش‌هایی نیز پیشنهاد شده است که تغییرات علایق کاربران در طول زمان را برای پیشنهاد آیت‌های مناسب به کاربران مدنظر قرار داده‌اند، ولی اغلب آنها با محدودیت‌های ذاتی خلوتی داده‌ها و کاربران شروع سرد مواجه هستند [۵] که باعث کاهش دقت پیشنهادها می‌شوند. مشکل خلوتی داده‌ها زمانی اتفاق می‌افتد که تعداد تعاملات کاربران-آیت‌ها کم باشد و مشکل شروع سرد هنگامی رخ می‌دهد که یک کاربر تعاملات بسیار کمی با آیت‌ها داشته باشد. برای کاهش این محدودیت‌ها، روش‌هایی نیز ارائه شده اند که علاوه بر اطلاعات مربوط به تعاملات بین کاربر و آیت‌ها، از اطلاعات جانبی درباره کاربران و آیت‌ها نیز استفاده کرده‌اند. در اغلب این روش‌ها فقط از یک نوع اطلاعات جانبی از قبیل داده‌های دموگرافی کاربران، اعتماد بین کاربران و یا ویژگی‌های آیت‌ها استفاده شده است. با استفاده از چندین منبع اطلاعاتی مختلف می‌توان شکاف میان کاربران موجود و کاربران جدید را کاهش داده و با مسأله شروع سرد مقابله کرد [۶]. مشکل خلوتی داده‌ها را کاهش داد [۷] و در نتیجه پیشنهادهای شخصی‌تر و مناسب‌تری به کاربران ارائه داد. در سال‌های اخیر استفاده از تجزیه ماتریس و سپس تجزیه تنسور در سیستم پیشنهاددهنده مورد توجه بوده و بسیاری از روش‌های فیلترینگ مشارکتی زمانی موفق از این مدل‌ها استفاده می‌کنند [۸].

در این مقاله با توسعه روش ارائه شده در [۹]، یک سیستم پیشنهاددهنده‌ی زمانی ارائه می‌کنیم که علاوه بر در نظر گرفتن تغییر علایق برای هر کاربر، و اینکه هر کاربر الگوی تغییر علایق خاص خود را دارد، فرض می‌شود که تأثیر و اهمیت علایق قبلی کاربر در پیشنهاد آیت‌های فعلی بر اساس نرخ تغییر علایق او کاهش می‌یابد و یک تابع کاهش زمانی مناسب برای هر کاربر معرفی می‌کنیم. به علاوه با توجه به اینکه علایق کاربران ممکن است از علایق دوستان آنها در طول زمان تأثیر پذیرفته و تغییر کنند [۵]، اطلاعات شباهت بین کاربران در طول زمان را نیز استخراج و به همراه داده‌های دموگرافی کاربران به منظور افزایش دانش پیشین درباره علایق پویای کاربران و کاهش مسائل شروع سرد و خلوتی داده‌ها استفاده می‌کنیم.

ما یک تنسور از روی تعاملات کاربران با آیت‌ها در طول زمان ساخته و با تنسور استخراج شده از اطلاعات شباهت بین کاربران و

یک روش مبتنی بر تجزیه ماتریس احتمالی با ترکیب تکامل علائق کاربران و روابط اجتماعی بین کاربران با استفاده از یک تابع کاهش زمانی نمایی برای پیش بینی علائق کاربران در میکرو بلاگ نویسی در [۱۶] ارائه شده است. در روش مذکور، اهمیت همه‌ی زمان‌های قبلی نسبت به زمان فعلی برای همه‌ی کاربران یکسان در نظر گرفته شده است. در حالی که در عمل، میزان اهمیت زمان‌های قبلی برای هر کاربر خاص، متفاوت است. در [۲۵] یک روش مبتنی بر تجزیه تنسور احتمالی بیزین برای مدل‌سازی تغییر علائق در طول زمان و پیشنهاد فیلم به کاربر ارائه شده است.

یک مدل پیشنهاددهنده‌ی زمانی مبتنی بر تجزیه تنسور-ماتریس‌های اتصالی در [۲۶] ارائه شده است که از یک تنسور سه بعدی خلوت حاوی تعاملات کاربران با آیتم‌ها در طول زمان و یک ماتریس شامل داده‌های دموگرافی کاربران استفاده می‌کند. این روش با معرفی معیاری بنام نرخ تغییرات علائق هر کاربر^۵ (UPD) در گوش دادن به موسیقی، علائق کاربران در گذشته را وزن‌دهی می‌کند. مدل مذکور در [۹] با معرفی مسأله‌ی بهینه‌سازی برای تجزیه تنسور-ماتریس‌های اتصالی و تخمین مقادیر نامشخص در تنسور، برای پیشنهاد موسیقی و فیلم به کاربران توسعه داده شد. در این روش، اهمیت علائق قبلی هر کاربر در همه‌ی زمان‌ها یکسان است در حالی که هر چه علائق کاربر قدیمی‌تر باشند، معمولاً تأثیر آنها بر علائق فعلی کمتر می‌باشد. روش پیشنهادی ما توسعه یافته‌ی این مدل می‌باشد.

۳- تجزیه تنسور

در تجزیه تنسور، تنسور با توجه به ابعاد آن به چند ماتریس به نام ماتریس‌های ویژگی تجزیه می‌شود. در این بخش، مدل تجزیه کانونی^۶ (CP) به عنوان یک روش متداول در تجزیه تنسور [۲۷] و روش تجزیه تنسور-ماتریس‌های اتصالی معرفی می‌گردند.

۳-۱- مدل تجزیه کانونی

مدل تجزیه کانونی، یک تنسور را به تعدادی تنسور مرتبه‌ی اول تجزیه می‌کند. تنسور N بعدی X ، مرتبه‌ی اول است، اگر بتوان آن را به صورت ضرب خارجی N بردار نوشت [۲۶]. یعنی:

$$X = \mathbf{a}^{(1)} \circ \mathbf{a}^{(2)} \circ \dots \circ \mathbf{a}^{(N)} \quad (1)$$

که $\mathbf{a}^{(i)}$ ($i=1, \dots, N$) بردار و نماد \circ بیانگر ضرب خارجی می‌باشد. تجزیه تنسور سه بعدی $X \in \mathbb{R}^{I \times J \times K}$ به ماتریس‌های ویژگی^(۱) $A^{(1)}$ ، $A^{(2)}$ و $A^{(3)}$ با استفاده از روش تجزیه کانونی به صورت زیر

است. از آنجایی که تغییر علائق برای هر کاربر متفاوت است، فرض اینکه ماتریس تغییر علائق برای همه‌ی کاربران، همگن است، محدودیت اصلی این روش در عمل می‌باشد [۳].

یک روش مبتنی بر تجزیه ماتریس احتمالی پویا در [۲۰] پیشنهاد و سپس این راهکار به مدل مبتنی بر بیزین بهبود یافته است. این روش از یک ماتریس انتقال برای هر بردار پنهان کاربر میان پنجره‌های زمانی متوالی، در تجزیه ماتریس به منظور مدل‌سازی تغییرات علائق کاربران استفاده کرده است. در [۲۱] از ترکیب تجزیه نامنفی ماتریس و سیستم دینامیک خطی^۴ (LDS)، یک سیستم پیشنهاددهنده ارائه شده است که ویژگی‌های زمانی کاربران را ادغام کرده و با استفاده از ماتریس انتقال حالت بدست آمده از LDS، تغییرات علائق کاربران در طول زمان را استخراج می‌کند.

در همه‌ی مطالعات مذکور، بجز تعاملات کاربران با آیتم‌ها، از هیچ اطلاعات جانبی دیگری استفاده نمی‌شود. و در نتیجه مسائل شروع سرد و خلوتی داده‌ها باعث محدودیت دقت این روش‌ها می‌گردد [۵]. تعدادی از روش‌های مبتنی بر تجزیه ماتریس از اطلاعات جانبی برای مقابله با مسائل شروع سرد و خلوتی داده‌ها و در نتیجه بهبود کارایی سیستم‌های پیشنهاددهنده‌ی زمانی استفاده می‌کنند. در [۲۲] روشی ارائه شده است که از بازخوردهای ناهمگن کاربران و همچنین زمان و ساختار شبکه‌های اجتماعی در مدل تجزیه ماتریس، برای پیشنهاد دقیق‌تر فیلم استفاده می‌کند. روش مشابهی در [۲۳] ارائه شده است که روابط اعتماد میان کاربران در هر بازه زمانی را به صورت یک گراف در نظر گرفته و با استفاده از لاپلاسیان گراف، روابط اعتماد را در مدل اعمال می‌کند.

روشی مبتنی بر تجزیه نامنفی ماتریس برای تولید پیشنهادها در [۵] ارائه شده است که با ترکیب امتیازات کاربران و توضیحات آن‌ها درباره‌ی آیتم‌ها، الگوی تغییرات زمانی علائق کاربران را استخراج می‌کند. بدین منظور از یک ماتریس انتقال برای نگاشت بین علائق کاربران در دو دوره‌ی زمانی متوالی استفاده می‌کند. در این روش، ماتریس انتقال برای همه‌ی کاربران یکسان در نظر گرفته شده است. در حالی که الگوی تغییر علائق برای هر کاربر متفاوت است.

در [۲۴] با مدل کردن پویایی علائق کاربران و در نظر گرفتن همبستگی بین اقلام و همچنین توضیحات متنی که کاربران درباره‌ی اقلام می‌دهند، و ترکیب همه‌ی آنها در مدل تجزیه ماتریس، امتیازات کاربران پیش‌بینی می‌شوند. این روش توانایی پیش‌بینی امتیازات کاربران جدید را ندارد.

می‌باشد:

$$\mathcal{X} \approx \llbracket A^{(1)}, A^{(2)}, A^{(3)} \rrbracket = \sum_{r=1}^R \mathbf{a}_r^{(1)} \circ \mathbf{a}_r^{(2)} \circ \mathbf{a}_r^{(3)} \quad (2)$$

که $\mathbf{a}_r^{(1)} \in \mathbb{R}^I$, $\mathbf{a}_r^{(2)} \in \mathbb{R}^J$ و $\mathbf{a}_r^{(3)} \in \mathbb{R}^K$ به ازای $r=1, \dots, R$ بردارهای ویژگی هستند. R ، رتبه‌ی تجزیه می‌باشد و بیانگر کوچک‌ترین تعداد تنسورهای مرتبه اولی می‌باشد که با ترکیب آنها تنسور \mathcal{X} تولید می‌شود [۹]. بردارهای $\mathbf{a}_r^{(1)}$ ، $\mathbf{a}_r^{(2)}$ و $\mathbf{a}_r^{(3)}$ به ترتیب ستون r ام از ماتریس‌های $A^{(1)}$ ، $A^{(2)}$ و $A^{(3)}$ را تشکیل می‌دهند.

۳-۲- روش تجزیه تنسور-ماتریس‌های اتصالی

روش تجزیه تنسور-ماتریس‌های اتصالی به طور گسترده در تجزیه داده‌های ناهمگن اتصالی استفاده شده است [۲۸]. فرض کنیم تنسور سه بعدی $\mathcal{X} \in \mathbb{R}^{I \times J \times K}$ و ماتریس $Y \in \mathbb{R}^{I \times L}$ در بعد اول خود به هم متصل باشند. مقادیر برخی از درایه‌های تنسور \mathcal{X} نامشخص می‌باشند. CTF به صورت یک مسأله‌ی بهینه‌سازی فرموله می‌شود. بدین منظور برای تجزیه تنسور \mathcal{X} و ماتریس Y ، تابع هدف زیر تعریف می‌شود [۱۰]:

$$f_W(A^{(1)}, A^{(2)}, A^{(3)}, V) = \frac{1}{2} \| \mathcal{W} * (\mathcal{X} - \llbracket A^{(1)}, A^{(2)}, A^{(3)} \rrbracket) \|^2 + \frac{1}{2} \| Y - A^{(1)} V^T \|^2 \quad (3)$$

در این رابطه، علامت * بیانگر ضرب هادامارد [۲۷]، $\|\cdot\|$ ، نرم فروبنیوس، V^T ، ترانپوز ماتریس V بوده و تنسور $\mathcal{W} \in \mathbb{R}^{I \times J \times K}$ ، \mathcal{X} مشخص باشد، درایه‌ی متناظر با آن در تنسور \mathcal{W} برابر مقدار \mathcal{X} یک و در غیر این صورت برابر صفر خواهد بود. به عبارت دیگر، هر درایه‌ی $w_{i,j,k}$ از تنسور \mathcal{W} (به ازای هر $i \in \{1, \dots, I\}$ ، $j \in \{1, \dots, J\}$ و $k \in \{1, \dots, K\}$) برابر خواهد بود با:

$$w_{i,j,k} = \begin{cases} 1 & \text{if } x_{i,j,k} \text{ is known} \\ 0 & \text{if } x_{i,j,k} \text{ is missing} \end{cases} \quad (4)$$

ماتریس‌های $A^{(1)} \in \mathbb{R}^{I \times R}$ ، $A^{(2)} \in \mathbb{R}^{J \times R}$ و $A^{(3)} \in \mathbb{R}^{K \times R}$ ماتریس‌های ویژگی‌های حاصل از تجزیه تنسور \mathcal{X} بوده که با استفاده از مدل تجزیه کانونی بدست می‌آیند. همچنین $A^{(1)}$ و $V \in \mathbb{R}^{L \times R}$ ماتریس‌های ویژگی حاصل از تجزیه ماتریس Y ، می‌باشند که از طریق روش تجزیه ماتریس بدست می‌آیند. $A^{(1)}$ ، ماتریس ویژگی مشترک متناظر با بعد مشترک بین \mathcal{X} و Y می‌باشد.

۴- روش پیشنهادی

در روش پیشنهادی، تعاملات کاربران با آیتم‌ها در دوره‌های زمانی مختلف را به صورت یک تنسور سه بعدی مدل می‌کنیم. تجزیه این تنسور منجر به کشف ویژگی‌های پنهان کاربران و آیتم‌ها می‌گردد. در حالت معمولی، با این تجزیه، می‌توان مقادیر نامشخص در تنسور را تخمین زد. ولی اگر تعداد مقادیر نامشخص زیاد باشد، استخراج ویژگی‌های پنهان و در نتیجه تخمین مقادیر نامشخص با دقت بسیار کمتری انجام می‌گیرد [۱۰]. تعداد تعاملات یک کاربر با آیتم‌ها در یک دوره زمانی خاص در سیستم‌های پیشنهاددهنده بسیار کم می‌باشد. در نتیجه تنسور حاصل، بسیار خلوت خواهد بود. بدین منظور علاوه بر اطلاعات مربوط به تعاملات پویای کاربران، از اطلاعات دموگرافی کاربر به عنوان ویژگی‌های شخصی او و همچنین شباهت ضمنی بین کاربران در دوره‌های زمانی گذشته به عنوان اطلاعات اجتماعی استفاده می‌کنیم. بکارگیری این اطلاعات اضافی می‌تواند باعث افزایش دانش پیشین درباره‌ی علائق پویای کاربران شده و ویژگی‌های پنهان کاربران و آیتم‌ها با دقت بهتری استخراج شوند. بر اساس پویایی علائق کاربران، تعاملات کاربران با آیتم‌ها را با ارائه یک تابع کاهش جدید برای دادن اهمیت بیشتر به تعاملات اخیر آنها در مقایسه با تعاملات قدیمی‌تر، وزن دهی می‌کنیم. از تکنیک CTF برای تجزیه اطلاعات اتصالی (تعاملات کاربر-آیتم، دموگرافی، شباهت بین کاربران) به منظور بهبود دقت پیشنهاد مناسب‌ترین آیتم‌ها به کاربر استفاده می‌کنیم.

مدل پیشنهادی، توسعه یافته‌ی روش ارائه شده در [۹] می‌باشد. به طوری که با ارائه‌ی یک تابع کاهش زمانی مناسب برای هر کاربر و همچنین استخراج و بهره‌گیری از اطلاعات شباهت بین کاربران سعی در بهبود پیشنهادهای ارائه شده به کاربران و مقابله با مسائل شروع سرد و خلوتی داده‌ها دارد. این مدل شامل مراحل زیر است:

۱- مدل سازی اطلاعات مربوط به تعاملات پویای کاربران با آیتم‌ها و همچنین اطلاعات دموگرافی کاربران به ترتیب در تنسور سه بعدی \mathcal{X} و ماتریس Y .

۲- بازسازی تنسور \mathcal{X} با وزن دادن به مقادیر این تنسور بر اساس تابع کاهش پیشنهادی.

۳- استخراج شباهت بین کاربران در طول زمان از روی تعاملات آنها با آیتم‌ها و ساخت تنسور سه بعدی Z از روی اطلاعات استخراج شده.

۴- اتصال تنسورهای \mathcal{X} و Z و ماتریس Y به هم و استفاده از

هر چه زمان آنها از زمان فعلی دورتر باشد، تأثیر کمتری بر علایق فعلی خواهند داشت. در این مقاله با در نظر گرفتن اینکه اهمیت علایق قبلی کاربران بر مبنای نرخ تغییر علایق آنها کاهش می‌یابد، یک فاکتور کاهش زمانی مناسب برای هر کاربر بر اساس این نرخ تغییر تعریف می‌کنیم. با توجه به مطالعه [۹]، برای هر کاربر $u \in U$ نرخ تغییر علایق کاربر، UPD_u عبارتست از:

$$UPD_u = 1 - \frac{|I_{prev}^u \cap I_{cur}^u|}{|I_{prev}^u \cup I_{cur}^u|} \quad (5)$$

که $I_{cur}^u \subset I$ مجموعه‌ی آیتم‌هایی است که کاربر u در آخرین دوره‌ی زمانی با آنها تعامل داشته است و $I_{prev}^u \subset I$ مجموعه آیتم‌هایی است که کاربر u در همه‌ی دوره‌های قبلی با آنها تعامل داشته است. مقدار بالای UPD_u به این معنی است که کاربر u تمایل زیادی به تغییر علایقش در دوره زمانی فعلی دارد. در حالی که مقدار پایین UPD_u بیانگر اینست که تغییر علایق کاربر u ناچیز است.

تابع کاهش نمایی $dec_u(t)$ ، که وزن تعاملات در دوره‌ی زمانی t ($t = 1, \dots, |T| - 1$) را بر اساس UPD_u برای هر کاربر u کاهش می‌دهد را به صورت زیر می‌سازیم:

$$dec_u(t) = e^{-UPD_u(|T|-t)} \quad (6)$$

که $|T|-t$ تعداد دوره‌های زمانی میان دوره زمانی t ام و دوره زمانی فعلی $|T|$ می‌باشند و پارامتر UPD_u نرخ کاهش را کنترل می‌کند. با استفاده از تابع کاهش فوق، وزن هر درایه $x_{u,i,t}$ در تنسور \mathcal{X} به ازای هر کاربر $u \in U$ و $|T| > 1$ به صورت زیر کاهش می‌یابد و تنسور \mathcal{X} بازسازی می‌شود:

$$x_{u,i,t} = dec_u(t) \cdot x_{u,i,t} \quad (7)$$

به طوری که $i \in I_{prev}^u$ و $t = 1, \dots, |T| - 1$

۴-۳- استخراج شباهت بین کاربران

علایق کاربران از علایق دوستان آنها تأثیر می‌پذیرد [۵] و نشان داده شده است که شباهت بین کاربران در کنار ماتریس تعاملات آن‌ها با آیتم‌ها، تأثیر قابل توجهی در کاهش مسائل شروع سرد و خلوتی داده‌ها دارد [۲۹]. بنابراین ما از روابط شباهت بین کاربران به منظور مقابله با این مسائل و در نتیجه بهبود کارایی سیستم پیشنهاددهنده استفاده می‌کنیم. از آنجایی که روابط اجتماعی بین کاربران در طول زمان تغییر می‌کند، از شباهت بین کاربران در طول زمان در مدل پیشنهادی استفاده می‌کنیم. شباهت صریح بین کاربران در مجموعه داده‌های مورد استفاده در این مقاله، در

تکنیک CTF برای تولید تنسور $\hat{\mathcal{X}}$ به عنوان تخمینی از تنسور \mathcal{X} .
۵- تولید پیشنهادهای شخصی برای هر کاربر بر اساس تنسور $\hat{\mathcal{X}}$.

۴-۱- مدل‌سازی علایق و اطلاعات دموگرافی کاربران

فرض می‌کنیم U ، I و T به ترتیب مجموعه‌ی کاربران، آیتم‌ها و دوره‌های زمانی باشند. علایق کاربران را در تنسور سه بعدی $\mathcal{X} \in \mathbb{R}^{|U| \times |I| \times |T|}$ با ابعاد کاربران، آیتم‌ها و دوره‌های زمانی، ذخیره می‌کنیم. به طوری که درایه‌ی $x_{u,i,t}$ این تنسور متناظر با تعداد تعاملات کاربر u با آیتم i در دوره‌ی زمانی t می‌باشد. ($u \in U, i \in I$ و $t \in T$). انتخاب دوره زمانی مناسب، بستگی به کاربرد سیستم پیشنهاددهنده دارد و می‌تواند روز، ماه، سال و غیره باشد. زمانی که می‌بایست پیشنهادها برای آن زمان تولید شوند در آخرین دوره زمانی قرار دارد و در نتیجه، هدف پیش بینی مقادیر نامشخص در آخرین دوره زمانی در تنسور \mathcal{X} می‌باشد. همچنین داده‌های دموگرافی کاربران را در ماتریس $Y \in \mathbb{R}^{|U| \times |M|}$ ذخیره می‌کنیم که M ، مجموعه‌ی ویژگی‌های دموگرافی کاربران می‌باشد. ویژگی‌های عددی مانند سن را با استفاده از روش equal-width binning گسسته کرده و به جای هر مقدار عددی در ماتریس Y مقدار متناظر حاصل از گسسته‌سازی را ذخیره می‌کنیم. همچنین مقادیر ویژگی‌های دسته‌ای از قبیل کشور به باینری تبدیل می‌شوند. به طوری که برای هر مقدار مجزای یک ویژگی، یک ویژگی جدید ساخته می‌شود که هر کاربری که این مقدار را دارد، در ویژگی جدید مقدار یک و در غیر این صورت مقدار صفر برای او منظور می‌شود. با الحاق ویژگی‌های عددی گسسته شده و دسته‌ای، تعداد $|M|$ ویژگی شخصی متفاوت در ماتریس Y ایجاد می‌شود.

اگر چه داده‌های دموگرافی کاربران نیز می‌توانند پویا بوده و در طول زمان تغییر کنند، در اغلب مجموعه داده‌های موجود از قبیل مجموعه داده‌های استفاده شده در این مقاله، ویژگی‌های کاربران به صورت ثابت در دسترس می‌باشد. بنابراین همانند مطالعه‌ی [۹]، داده‌های دموگرافی کاربران در همه‌ی دوره‌های زمانی را ثابت در نظر می‌گیریم. از آنجایی که در هر دوره زمانی، تعداد کمی تعاملات کاربر-آیتم وجود دارد و همچنین معمولاً تعداد کمی از مقادیر ویژگی‌های کاربران در سیستم‌های پیشنهاددهنده، مشخص می‌باشد، تنسور \mathcal{X} و ماتریس Y خلوت می‌باشند.

۴-۲- پویایی علایق کاربران

معمولاً علایق فعلی کاربران از فعالیت‌های قبلی آنها تأثیر می‌پذیرد. این فعالیت‌ها، علایق قبلی کاربران را منعکس می‌کنند و

اگر مقدار هر درایه از تنسور \mathcal{X} (تنسور Z)، مشخص باشند، درایه‌ی متناظر با آن در تنسور \mathcal{W}_X (تنسور \mathcal{W}_Z) برابر مقدار یک و در غیر این صورت برابر صفر خواهد بود. به عبارت دیگر به ازای هر کاربر u و v و هر آیت i در زمان $t \in T$:

$$w_{X_{u,i,t}} = \begin{cases} 1 & \text{if } x_{u,i,t} \text{ is known} \\ 0 & \text{if } x_{u,i,t} \text{ is missing} \end{cases} \quad (10)$$

$$w_{Z_{u,v,t}} = \begin{cases} 1 & \text{if } z_{u,v,t} \text{ is known} \\ 0 & \text{if } z_{u,v,t} \text{ is missing} \end{cases} \quad (11)$$

با توسعه‌ی رابطه (۳)، تابع هدف CTF را به صورت زیر تعریف می‌کنیم:

$$f_{\mathcal{W}}(A^{(1)}, A^{(2)}, A^{(3)}, V, U^{(1)}, U^{(2)}) = \frac{\|\mathcal{W}_X * (\mathcal{X} - \llbracket A^{(1)}, A^{(2)}, A^{(3)} \rrbracket)\|^2}{2 \text{size}(\mathcal{X})} + \frac{\|Y - A^{(1)} V^T\|^2}{2 \text{size}(Y)} + \frac{\|\mathcal{W}_Z * (\mathcal{Z} - \llbracket A^{(1)}, U^{(1)}, U^{(2)} \rrbracket)\|^2}{2 \text{size}(Z)} \quad (12)$$

در این رابطه، $A^{(1)} \in \mathbb{R}^{|U| \times R}$ ، $A^{(2)} \in \mathbb{R}^{|I| \times R}$ و $A^{(3)} \in \mathbb{R}^{|T| \times R}$ ماتریس‌های ویژگی‌های حاصل از تجزیه تنسور \mathcal{X} ، $A^{(1)}$ و $V \in \mathbb{R}^{|M| \times R}$ ماتریس‌های ویژگی حاصل از تجزیه ماتریس Y ، و $U^{(1)} \in \mathbb{R}^{|U| \times R}$ ، $U^{(2)} \in \mathbb{R}^{|T| \times R}$ ماتریس‌های ویژگی حاصل از تجزیه تنسور Z می‌باشند که با اعمال مدل تجزیه CP با رتبه تجزیه R استخراج می‌شوند. عبارت $\llbracket A^{(1)}, A^{(2)}, A^{(3)} \rrbracket$ تنسور سه بعدی $\hat{\mathcal{X}} \in \mathbb{R}^{|U| \times |I| \times |T|}$ را به عنوان تقریبی از تنسور \mathcal{X} بر اساس مدل CP به صورت زیر تعریف می‌کند:

$$\hat{\mathcal{X}} = \llbracket A^{(1)}, A^{(2)}, A^{(3)} \rrbracket = \sum_{r=1}^R \mathbf{a}_r^{(1)} \circ \mathbf{a}_r^{(2)} \circ \mathbf{a}_r^{(3)} \quad (13)$$

که $\mathbf{a}_r^{(1)} \in \mathbb{R}^{|U|}$ ، $\mathbf{a}_r^{(2)} \in \mathbb{R}^{|I|}$ و $\mathbf{a}_r^{(3)} \in \mathbb{R}^{|T|}$ به ترتیب ستون r ام $A^{(1)}$ ، $A^{(2)}$ و $A^{(3)}$ می‌باشند. ماتریس $A^{(1)}$ ، ماتریس ویژگی متناظر با بعد مشترک بین \mathcal{X} ، Y و Z می‌باشد. $\text{size}(\mathcal{X})$ ، $\text{size}(Y)$ و $\text{size}(Z)$ به ترتیب تعداد عناصر مشخص در تنسورهای \mathcal{X} ، Y و Z می‌باشند و هدف از اعمال آنها در رابطه (۱۲)، با الهام از مطالعه‌ی [۳۱] اینست که خطای \mathcal{X} ، Y و Z بر اندازه‌ی آنها تقسیم شود تا تقریب بهینه هر سه تنسور \mathcal{X} ، Y و Z انجام شده و اختلاف اندازه‌ی تنسورها باعث قربانی شدن دقت برخی از آنها نشود. برای حل مسأله بهینه‌سازی رابطه (۱۲) با استفاده از روش بهینه‌سازی مبتنی بر گردایان، رابطه مذکور را به صورت سه مولفه f_{w_1} ، f_2 و f_{w_3} بازنویسی می‌کنیم.

دسترس نمی‌باشد، در نتیجه از یک روش اصلاح‌شده برای استخراج شباهت ضمنی بین کاربران از اطلاعات تعاملات کاربران با آیت‌ها استفاده می‌کنیم.

یکی از پرکاربردترین روش‌های محاسبه‌ی شباهت میان کاربران، معیار Cosine می‌باشد [۳۰]. این معیار، وقتی تعداد آیت‌هایی که دو کاربر با آنها تعامل داشته‌اند کم باشد، شباهت بسیار زیادی را بین آنها تخمین می‌زند. برای رفع این مشکل، اگر تعداد آیت‌هایی که دو کاربر، هر دو با آنها تعامل داشته‌اند از یک مقدار آستانه کمتر باشد، شباهت حاصل بین دو کاربر را کاهش می‌دهیم. بدین منظور پارامتر β را به صورت زیر تعریف می‌کنیم:

$$\beta = \begin{cases} \frac{n}{\omega} & n < \omega \\ 1 & \text{otherwise} \end{cases} \quad (8)$$

که n تعداد آیت‌هایی که دو کاربر، هر دو با آنها تعامل داشته‌اند و ω مقدار آستانه می‌باشد. در نتیجه با توجه به مقدار β ، شباهت بین کاربر u و v در دوره زمانی t از رابطه زیر محاسبه می‌شود:

$$\text{Sim}_{u,v,t} = \beta \frac{\sum_{i \in I_{u,t} \cap I_{v,t}} x_{u,i,t} \cdot x_{v,i,t}}{\sqrt{\sum_{i \in I_{u,t}} (x_{u,i,t})^2} \cdot \sqrt{\sum_{i \in I_{v,t}} (x_{v,i,t})^2}} \quad (9)$$

که $x_{u,i,t}$ و $x_{v,i,t}$ به ترتیب بیانگر تعداد تعاملات کاربر u و v با آیت i می‌باشد. همچنین $I_{u,t}$ و $I_{v,t}$ مجموعه آیت‌هایی هستند که به ترتیب کاربر u و v در دوره زمانی t با آنها تعامل داشته‌اند. با استفاده از رابطه (۹)، شباهت بین کاربران در دوره‌های زمانی مختلف از روی تنسور \mathcal{X} بدست آمده و در تنسور سه بعدی $Z \in \mathbb{R}^{|U| \times |U| \times |T|}$ با ابعاد کاربران، کاربران، دوره‌های زمانی ذخیره می‌شود. به طوری که مقدار درایه $z_{u,v,t}$ به ازای هر $u, v \in U$ و $t \in T$ متناظر با شباهت بین کاربر u و v در دوره زمانی t می‌باشد.

۴-۴- تجزیه تنسور - ماتریس‌های اتصالی

اخیراً استفاده از تکنیک CTF در بکارگیری اطلاعات جانبی در سیستم‌های پیشنهاددهنده مورد توجه قرار گرفته است و همچنین به طور وسیعی در مسائل تخمین داده‌های نامشخص استفاده می‌شود [۱۱]. از آنجایی که هدف ما پیش‌بینی مقادیر نامشخص در زمانی که پیشنهادها تولید می‌شوند می‌باشد که زمان مذکور در آخرین دوره زمانی در تنسور \mathcal{X} قرار دارد، تنسور \mathcal{X} را با ماتریس Y و تنسور Z در بعد مشترک کاربران، به هم متصل و با استفاده از تکنیک CTF، مقادیر نامشخص در آخرین دوره زمانی در تنسور \mathcal{X} تخمین زده می‌شوند. شکل ۱ این مدل اتصالی را نشان می‌دهد.

دو تنسور نشانگر $\mathcal{W}_X \in \mathbb{R}^{|U| \times |I| \times |T|}$ و $\mathcal{W}_Z \in \mathbb{R}^{|U| \times |U| \times |T|}$ به ترتیب متناظر با تنسورهای \mathcal{X} و Z در نظر می‌گیریم. به طوری که

با توجه به روابط (۱۵) تا (۲۵)، مشتقات جزئی f_W نسبت به $A^{(i)}$ ، V و $U^{(j)}$ به صورت زیر می‌باشند:

$$\frac{\partial f_W}{\partial A^{(i)}} = \begin{cases} \frac{\partial f_{w_1}}{\partial A^{(i)}} + \frac{\partial f_2}{\partial A^{(i)}} + \frac{\partial f_{w_3}}{\partial A^{(i)}}, & \text{for } i = 1 \\ \frac{\partial f_{w_1}}{\partial A^{(i)}} & \text{for } i \neq 1 \end{cases} \quad (26)$$


$$\frac{\partial f_W}{\partial V} = \frac{\partial f_2}{\partial V} \quad (27)$$

$$\frac{\partial f_W}{\partial U^{(j)}} = \frac{\partial f_{w_3}}{\partial U^{(j)}} \quad (28)$$

گرادیان f_W یعنی ∇f_W که یک بردار به اندازه $R(2|U| + 2|T| + |M| + |I|)$ می‌باشد، با بردارسازی مشتقات جزئی روابط (۲۶) تا (۲۸) با استفاده از عملگر بردارسازی $\text{vec}(\cdot)$ [۲۷] و الحاق آنها به صورت زیر بدست می‌آید:

$$\nabla f_W = \begin{bmatrix} \text{vec}\left(\frac{\partial f_W}{\partial A^{(1)}}\right) & \text{vec}\left(\frac{\partial f_W}{\partial A^{(2)}}\right) & \text{vec}\left(\frac{\partial f_W}{\partial A^{(3)}}\right) \\ \text{vec}\left(\frac{\partial f_W}{\partial V}\right) & \text{vec}\left(\frac{\partial f_W}{\partial U^{(1)}}\right) & \text{vec}\left(\frac{\partial f_W}{\partial U^{(2)}}\right) \end{bmatrix} \quad (29)$$

با داشتن تابع هدف و مقادیر گرادیان به ترتیب در روابط (۱۲) و (۲۹)، با استفاده از روش گرادیان مزدوج غیر خطی^۶ (NCG) پیاده سازی شده در جعبه ابزار Poblano در MATLAB، ماتریس‌های ویژگی $A^{(1)}$ ، $A^{(2)}$ و $A^{(3)}$ را محاسبه کرده و سپس تانسور \mathcal{X} را با توجه به رابطه (۱۳) به عنوان تقریبی از تانسور \mathcal{X} بدست می‌آوریم.



شکل ۱: اتصال تانسور \mathcal{X} با ماتریس Y و تانسور Z در بعد مشترک کاربران.

۴-۵- تولید پیشنهادها

به منظور تولید تعداد k آیتم پیشنهادی برای هر کاربر u در زمان فعلی، درایه‌های $\hat{x}_{u, :, |T|}$ در تانسور \mathcal{X} که متناظر با تعداد تعاملات تخمین زده شده‌ی کاربر u با هر آیتم در آخرین دوره زمانی ($|T|$) می‌باشند، به صورت یک لیست نزولی مرتب شده و آیتم‌های متناظر با k عنصر ابتدای لیست به کاربر u پیشنهاد می‌شود.

$$f_W(A^{(1)}, A^{(2)}, A^{(3)}, V, U^{(1)}, U^{(2)}) = \frac{\|W_X * (X - [A^{(1)}, A^{(2)}, A^{(3)}])\|^2}{2 \text{size}(X)} + \frac{\|Y - A^{(1)} V^T\|^2}{2 \text{size}(Y)} + \frac{f_{w_1}}{f_2} \frac{\|W_Z * (Z - [A^{(1)}, U^{(1)}, U^{(2)}])\|^2}{2 \text{size}(Z)} + \frac{f_{w_3}}{f_2} \quad (14)$$

با قرار دادن $Q = [A^{(1)}, U^{(1)}, U^{(2)}]$ و $P = [A^{(1)}, A^{(2)}, A^{(3)}]$ و با توجه به [۳۲] به ازای $i=1,2,3$ و $j=1,2$ ، مشتقات جزئی f_{w_1} نسبت به $A^{(i)}$ و V و $U^{(j)}$ عبارتند از:

$$\frac{\partial f_{w_1}}{\partial A^{(i)}} = \frac{(W_{X(i)} * P^{(i)} - W_{X(i)} * X^{(i)}) A^{(-i)}}{\text{size}(X)} \quad (15)$$

$$\frac{\partial f_{w_1}}{\partial V} = 0 \quad (16)$$

$$\frac{\partial f_{w_1}}{\partial U^{(j)}} = 0 \quad (17)$$

که $A^{(-i)}$ در رابطه (۱۵) برابر است با:

$$A^{(-i)} = \begin{cases} A^3 \odot A^2, & \text{if } i = 1 \\ A^3 \odot A^1, & \text{if } i = 2 \\ A^2 \odot A^1, & \text{if } i = 3 \end{cases} \quad (18)$$

علامت \odot بیانگر ضرب Khatri-Rao [۲۷] می‌باشد. همچنین مشتقات جزئی f_2 نسبت به $A^{(i)}$ ، V و $U^{(j)}$ به صورت زیر بدست می‌آیند:

$$\frac{\partial f_2}{\partial A^{(i)}} = \begin{cases} \frac{-YV + A^{(-i)} V^T V}{\text{size}(Y)}, & \text{for } i = 1 \\ 0 & \text{for } i \neq 1 \end{cases} \quad (19)$$

$$\frac{\partial f_2}{\partial V} = \frac{-Y^T A^{(i)} + V A^{(i)T} A^{(i)}}{\text{size}(Y)} \quad (20)$$

$$\frac{\partial f_2}{\partial U^{(j)}} = 0 \quad (21)$$

و به همین ترتیب مشتقات جزئی f_{w_3} نسبت به $A^{(i)}$ ، V و $U^{(j)}$ به صورت زیر بدست می‌آیند:

$$\frac{\partial f_{w_3}}{\partial A^{(i)}} = \begin{cases} \frac{(W_{Z(i)} * Q^{(i)} - W_{Z(i)} * Z^{(i)}) (U^{(2)} \odot U^{(1)})}{\text{size}(Z)}, & \text{for } i = 1 \\ 0 & \text{for } i \neq 1 \end{cases} \quad (22)$$

$$\frac{\partial f_{w_3}}{\partial V} = 0 \quad (23)$$

$$\frac{\partial f_{w_3}}{\partial U^{(j)}} = \frac{(W_{Z(j)} * Q^{(j)} - W_{Z(j)} * Z^{(j)}) U^{(-j)}}{\text{size}(Z)} \quad (24)$$

که $U^{(-j)}$ در رابطه (۲۴) برابر است با:

$$U^{(-j)} = \begin{cases} U^{(2)} \odot A^{(1)}, & \text{if } j = 1 \\ U^{(1)} \odot A^{(1)}, & \text{if } j = 2 \end{cases} \quad (25)$$

۵- ارزیابی تجربی

۵-۱- مجموعه داده‌ها

برای ارزیابی روش پیشنهادی، آزمایش‌ها بر روی دو مجموعه داده‌ی معروف Last.fm و MovieLens انجام شده است. مجموعه داده‌ی Last.fm [۳۳] شامل ۱۹۱۵۰۸۶۸ رویداد گوش دادن ۹۹۲ کاربر به موسیقی‌های ۱۷۶۹۴۸ خواننده به همراه زمان آن در مدت ۵۴ ماه می‌باشد. همانند [۹] هر ۶ ماه را به عنوان یک بازه‌ی زمانی در نظر گرفته و مجموعه داده به ۹ دوره زمانی تقسیم می‌شود. برای ساخت تنسور اولیه \mathcal{X} ، کاربر، خواننده و دوره زمانی به عنوان ابعاد تنسور در نظر گرفته و مقادیر درایه‌های آن متناظر با تعداد دفعاتی است که یک کاربر به موسیقی یک خواننده در یک دوره‌ی زمانی گوش می‌کند. در این مجموعه داده، داده‌های دموگرافی شامل جنسیت، سن و کشور برای بعضی کاربران در دسترس می‌باشد. ویژگی جنسیت شامل دو مقدار و همچنین کشور شامل ۶۶ مقدار مختلف دسته‌ای می‌باشند. با تبدیل مقادیر این دو ویژگی به مقادیر باینری، در مجموع ۶۹ ویژگی ایجاد می‌شود که ۶۶ ویژگی مربوط به کشور، ۲ ویژگی مربوط به جنسیت و یک ویژگی مربوط به سن می‌باشد.

مجموعه داده‌ی MovieLens [۳۴] شامل تعداد ۱۰۰۰۲۰۹ امتیازدهی ۶۰۴۰ کاربر به ۳۹۵۲ فیلم مختلف می‌باشد. تعداد ۱۸ نوع^۱ فیلم وجود دارد که هر فیلم در یک یا چند نوع قرار می‌گیرد. فرض می‌شود که کاربران پس از دیدن یک فیلم به آن امتیاز می‌دهند. مقادیر امتیازدهی‌ها بین ۱ تا ۵ بوده و در مدت ۳۶ ماه انجام شده است که هر ۶ ماه را یک دوره‌ی زمانی در نظر گرفته و مجموعه داده‌ها به ۶ دوره‌ی زمانی تقسیم می‌شوند. از آنجایی که کاربران به ندرت یک فیلم را چندین مرتبه تماشا می‌کنند، در روش پیشنهادی به جای پیشنهاد فیلم، نوع فیلم به کاربر پیشنهاد می‌شود. در ساخت تنسور اولیه \mathcal{X} برای این مجموعه داده، کاربر، نوع فیلم و دوره‌ی زمانی را به عنوان ابعاد آن در نظر گرفته و مقادیر درایه‌های آن، متناظر با تعداد دفعاتی است که کاربر آن دسته فیلم را امتیازدهی کرده است. در این مجموعه داده، داده‌های دموگرافی شامل جنسیت، سن و ۲۱ نوع شغل کاربران در دسترس است. با تبدیل مقادیر ویژگی‌های دسته‌ای جنسیت و شغل به باینری، در مجموع ۲۴ ویژگی ایجاد می‌شود که ۲ ویژگی مربوط به جنسیت، ۲۱ ویژگی مربوط به شغل و یک ویژگی مربوط به سن می‌باشد.

۵-۲- روش ارزیابی

آخرین ماه در هر دوره‌ی زمانی را به عنوان مجموعه تست و ماه‌های دیگر این دوره و دوره‌های زمانی قبلی را همانند [۹] به عنوان مجموعه آموزشی در نظر می‌گیریم. در نتیجه هر یک از ماه‌های ۶، ۱۲، ۱۸، ۲۴، ۳۰، ۳۶، ۴۲، ۴۸ و ۵۴ در مجموعه داده‌ی Last.fm به عنوان مجموعه تست و همه‌ی ماه‌های قبل از هر یک از آنها به عنوان مجموعه‌ی آموزشی متناظر در نظر گرفته می‌شوند. همچنین برای مجموعه داده‌ی MovieLens، هر یک از ماه‌های ۶، ۱۲، ۱۸، ۲۴، ۳۰ و ۳۶ به عنوان مجموعه تست و همه‌ی ماه‌های قبل از هر یک از آنها به عنوان مجموعه آموزشی متناظر انتخاب می‌شوند. هدف، پیشنهاد مناسب‌ترین k خواننده به هر کاربر در مجموعه‌ی داده‌ی Last.fm و پیشنهاد مناسب‌ترین k دسته فیلم به کاربر در مجموعه داده‌ی MovieLens در یک ماه تست می‌باشد.

معیارهای Precision، Recall و F1-measure به وفور در ارزیابی سیستم‌های پیشنهاددهنده‌ی top-k آیتم استفاده می‌شوند [۳۵]. برای کاربر تست u ، Recall برابر است با نسبت تعداد آیتم‌های مورد علاقه کاربر در لیست k آیتم پیشنهاد شده به او در دوره زمانی تست t ، به کل آیتم‌های مورد علاقه او. Precision، نسبت تعداد آیتم‌های مورد علاقه‌ی کاربر در لیست k آیتم پیشنهاد شده به او در دوره زمانی تست t ، به تعداد کل آیتم‌های پیشنهادی (k) به کاربر می‌باشد. F1-measure که با ترکیب دو معیار دیگر بدست می‌آید، برای نمایش ارتباط بین Recall و Precision به کار می‌رود. این معیارها را به ترتیب به صورت $Recall_u@k$ ، $Precision_u@k$ و $F1_u@k$ نمایش می‌دهیم. در ارزیابی روش پیشنهادی، از میانگین Precision، Recall و F1-measure همه‌ی کاربران در مجموعه‌ی تست به صورت زیر استفاده می‌کنیم:

$$AR@k = \frac{1}{|U|} \sum_{u=1}^{|U|} Recall_u@k \quad (30)$$

$$AP@k = \frac{1}{|U|} \sum_{u=1}^{|U|} Precision_u@k \quad (31)$$

$$AF1@k = \frac{1}{|U|} \sum_{u=1}^{|U|} F1_u@k \quad (32)$$

ارزیابی بر روی روش‌های مبتنی بر مدل‌سازی پویایی علایق کاربران زیر انجام می‌شود:

۱- روش TimeSVD++ (Time-aware factor model based on Singular Value Decomposition) [۱۸]: به عنوان یک روش پایه، با در نظر گرفتن پویایی علایق کاربران در طول زمان، و تجزیه ماتریس تعاملات کاربران با آیتم‌ها، آیتم‌های مناسب را به کاربران پیشنهاد می‌کند. این روش از هیچ اطلاعات اضافی استفاده

نمی‌کند.

Poblano انتخاب شد.

۵-۳- نتایج آزمایش‌ها

کارایی روش‌های مقایسه شده به ازای $k=5, 10, 15, 20, 50, 100$ در مجموعه داده‌ی Last.fm و به ازای $k=1, 2, 3$ در مجموعه داده‌ی Movielens در شکل‌های ۲ و ۳ بر حسب میانگین $AR@k$ ، $F1@k$ و $AP@k$ نشان داده شده است. از آنجایی که در مجموعه داده‌ی Last.fm، هر کاربر در یک ماه تست، به موسیقی بیشتر از ۱۰۰ خواننده گوش نمی‌کند و همچنین در مجموعه داده‌ی Movielens، هر کاربر در یک ماه تست، بیش از ۳ دسته فیلم متفاوت را تماشا نمی‌کند [۹]، حداکثر مقدار k در این دو مجموعه داده، به ترتیب ۱۰۰ و ۳ انتخاب شد. همانطور که مشاهده می‌شود، کارایی دو روش پیشنهادی EUPD-CTF1 و EUPD-CTF2 به ازای همه‌ی مقادیر بررسی شده‌ی k از سایر روش‌ها برحسب هر سه معیارها بهتر می‌باشد. برتری روش پیشنهادی EUPD-CTF1 بر UPD-CTF به این معنی است که در نظر گرفتن فاکتور کاهش زمانی بر مبنای UPD برای هر کاربر، برای استخراج پویایی علایق کاربران می‌تواند به بهبود کیفیت پیشنهادها کمک کند. به‌ویژه روش EUPD-CTF1 در مجموعه داده‌ی Last.fm که میزان تغییر علایق کاربران در آن نسبت به مجموعه داده‌ی Movielens بیشتر می‌باشد [۹]، به طور متوسط بهبود بیشتری دارد.

روش EUPD-CTF2 که در مقایسه با EUPD-CTF1 از شباهت بین کاربران نیز استفاده می‌کند، بیشترین دقت را در ارائه‌ی پیشنهادها به کاربران دارد. این نتیجه بیانگر آن است که مشارکت شباهت میان کاربران در طول زمان در روش پیشنهادی، منجر به بهبود دقت پیشنهادها می‌گردد. این بهبود در مجموعه داده‌ی Movielens نسبت به Last.fm بیشتر می‌باشد. یعنی شباهت بین کاربران، تأثیر بیشتری در انتخاب دسته فیلم توسط آنها نسبت به انتخاب موسیقی یک خواننده داشته است. همچنین مشاهده می‌شود، روش‌های TimeSVD++ [۱۸] و TF [۱۵] که فقط از تعاملات کاربران با آیتم‌ها در طول زمان استفاده می‌کنند و علایق قبلی کاربران را وزن‌گذاری نمی‌کنند، دقت‌های کمتری در مقایسه با سه روش دیگر دارند.

نتایج ارزیابی روش‌های مورد مقایسه در ماه‌های مختلف تست به ازای $k=100$ در مجموعه داده‌ی Last.fm و $k=3$ در مجموعه داده‌ی Movielens (همانند [۹])، به ترتیب در شکل‌های ۴ و ۵ نشان داده شده است. همانطور که مشاهده می‌شود، دقت روش پیشنهادی EUPD-CTF1 نسبت به روش UPD-CTF [۹] از ماه

۲-روش TF (Tensor Factorization) [۱۵]: این روش تنسور تعاملات کاربران با آیتم‌ها در طول زمان را برای مدل‌سازی علایق کاربران و ارائه‌ی پیشنهادها مناسب به آنها تجزیه می‌کند و از هیچ اطلاعات اضافی استفاده نمی‌کند.

۳-روش UPD-CTF (User Preference Dynamics-Coupled Tensor Factorization) [۹]: این روش پیشنهادها را بر اساس UPD و اطلاعات دموگرافی کاربران مدل می‌کند.

۴-روش EUPD-CTF1 (Enhanced UPD-CTF1): روش پیشنهادی ما با استفاده از اطلاعات تعاملات کاربران با آیتم‌ها در طول زمان و داده‌های دموگرافی کاربران می‌باشد. این روش، در مقایسه با روش UPD-CTF از یک تابع کاهش زمانی برای هر کاربر استفاده می‌کند. به طوری که تأثیر علایق قبلی کاربر در تولید پیشنهادها فعلی به او بر اساس نرخ تغییر علایقش کاهش می‌یابد.

۵-روش EUPD-CTF2 (Enhanced UPD-CTF2): روش پیشنهادی ما با استفاده از اطلاعات تعاملات کاربران با آیتم‌ها در طول زمان، داده‌های دموگرافی کاربران، و همچنین شباهت بین کاربران در طول زمان می‌باشد. این روش همانند EUPD-CTF1 در مقایسه با روش UPD-CTF، از یک تابع کاهش زمانی برای هر کاربر استفاده می‌کند. علاوه بر این، اطلاعات شباهت بین کاربران را نیز استخراج کرده و از آنها در تولید پیشنهادها مناسب‌تر به کاربر استفاده می‌کند.


مقادیر پارامترهای روش UPD-CTF، همان مقادیر استفاده شده توسط ارائه دهندگان روش مذکور در [۹] می‌باشد. با آزمایش مقادیر مختلف ۵، ۱۰، ۱۵، ۲۰ و ۲۵، برای R در مدل تجزیه CP، بهترین کارایی به ازای $R=20$ روی هر دو مجموعه داده حاصل شد. مقدار w برای مجموعه داده‌های Last.fm و Movielens به ترتیب ۵۰ و ۳، با توجه به نتایج بهتر آنها در مقایسه با سایر مقادیر، انتخاب شد. حداکثر تعداد تکرار^۱ و ارزیابی‌های تابع^۱ در الگوریتم بهینه‌سازی گرادین مزدوج غیر خطی به ترتیب برابر 10^4 و 10^5 انتخاب شد. پارامتر حداکثر تعداد تکرار، میزان همگرایی الگوریتم بهینه‌سازی را کنترل می‌کند. همچنین پارامتر حداکثر تعداد ارزیابی‌های تابع، حداکثر تعداد دفعاتی که تابع الگوریتم بهینه‌سازی اجرا می‌شود را تعیین می‌کند. سایر پارامترهای کنترل‌کننده‌ی خاتمه الگوریتم، مقادیر پیش فرض در جعبه ابزار

دو مجموعه داده، در برخی ماه‌های تست، دقت کمی بیشتر و در برخی ماه‌ها، دقت تقریباً کمتری نسبت به UPD-CTF دارد. با این وجود، بررسی نتایج در شکل‌های ۶ و ۷ نشان می‌دهند که به‌طور میانگین، روش پیشنهادی EUPD-CTF1 عملکرد بهتری در مواجهه با مسأله‌ی شروع سرد نسبت به روش UPD-CTF دارد. نتایج در شکل‌های ۶ تا ۹ حاکی از آن است که روش پیشنهادی EUPD-CTF2 که از اطلاعات شباهت بین کاربران در دوره‌های زمانی گذشته استفاده می‌کند، در مواجهه با مسأله‌ی شروع سرد، تأثیر قابل توجهی در بهبود دقت پیشنهادها داشته و بهترین عملکرد را دارد. در شکل‌های ۶ تا ۹ می‌توان دید که روش‌های TimeSVD++ و TF در برخورد با کاربران شروع سرد نسبت به سایر روش‌ها عملکرد خوبی ندارند.

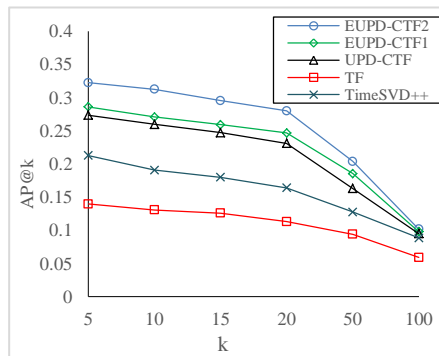
به طور کلی نتایج آزمایش‌ها نشان می‌دهند که روش پیشنهادی EUPD-CTF2 نسبت به روش‌های مقایسه شده در مدل کردن علائق پویای کاربر به منظور پیشنهاد top-k آیت‌م، بهتر عمل کرده و به‌کارگیری اطلاعات جانبی از قبیل داده‌های دموگرافی و شباهت بین کاربران در دوره‌های زمانی مختلف در مدل ارائه شده، می‌تواند باعث کاهش مسائل خلوتی داده‌ها و شروع سرد گردند.

۲۴ به بعد در مجموعه داده‌ی Last.fm و از ماه ۱۲ به بعد در مجموعه داده‌ی Movielens. در همه‌ی معیارها بهتر بوده است. اگر چه دقت روش EUPD-CTF1 بسیار نزدیک به دقت UPD-CTF می‌باشد و بهبود آن نسبتاً کم است، ولی حتی بهبود کم هم منجر به افزایش قابل توجه کیفیت پیشنهادها در عمل خواهد شد [۳۶].

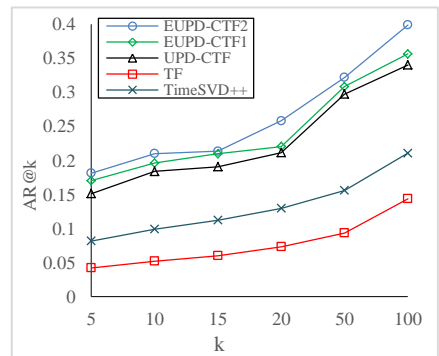
شکل‌های ۶ و ۷ به‌ترتیب کارایی روش‌های مقایسه شده را در برخورد با کاربران شروع سرد بر حسب میانگین $AR@k$ ، $AP@k$ و $F1@k$ به ازای مقادیر مختلف k در مجموعه داده‌های Last.fm و Movielens نشان می‌دهند. در این حالت، فقط کاربرانی که حداکثر ۵ تعامل با آیت‌م‌ها داشته‌اند، در مجموعه داده‌ی تست قرار گرفته‌اند. همان‌طور که در این دو شکل مشاهده می‌شود روش EUPD-CTF2 در مقایسه با سایر روش‌ها در هر دو مجموعه داده دقت بهتری دارد. شکل‌های ۸ و ۹ به ترتیب نتایج ارزیابی روش‌های مورد مقایسه در ماه‌های مختلف تست، با در نظر گرفتن فقط کاربرانی که حداکثر ۵ تعامل با آیت‌م‌ها داشته‌اند، را به ازای $k=100$ در مجموعه داده‌ی Last.fm و $k=3$ در مجموعه داده‌ی Movielens نشان می‌دهند. مشاهده می‌شود که روش پیشنهادی EUPD-CTF1 که از شباهت بین کاربران استفاده نمی‌کند، در هر



(ج)




(ب)




(الف)


شکل ۲: کارایی روش‌های مقایسه شده در مجموعه داده Last.fm به ازای مقادیر مختلف k بر حسب میانگین (الف) $AR@k$ ، (ب) $AP@k$ و (ج) $AF1@k$




شکل ۳: کارایی روش‌های مقایسه شده در مجموعه داده MovieLens به ازای مقادیر مختلف k برحسب میانگین الف (AR@k، ب) AP@k و ج) AFI@k




شکل ۴: کارایی روش‌های مقایسه شده در مجموعه داده Last.fm به ازای k=100 برحسب الف (AR@100، ب) AP@100 و ج) AFI@100



شکل ۵: کارایی روش‌های مقایسه شده در مجموعه داده MovieLens به ازای k=3 برحسب الف (AR@3، ب) AP@3 و ج) AFI@3




شکل ۶: کارایی روش‌های مقایسه شده با در نظر گرفتن فقط کاربران با حداکثر ۵ تعامل در ماه‌های تست، در مجموعه داده Last.fm به ازای مقادیر مختلف k برحسب میانگین الف (AR@k، ب) AP@k و ج) AFI@k




شکل ۷: کارایی روش‌های مقایسه شده با در نظر گرفتن فقط کاربران با حداکثر ۵ تعامل در ماه‌های تست، در مجموعه داده MovieLens به ازای مقادیر

مختلف k برحسب میانگین الف (AR@k، ب (AP@k و ج) AFI@k



شکل ۸: کارایی روش‌های مقایسه شده با در نظر گرفتن فقط کاربران با حداکثر ۵ تعامل در ماه‌های تست در مجموعه داده Last.fm به ازای k=100

برحسب الف (AR@100، ب (AP@100 و ج) AFI@100



شکل ۹: کارایی روش‌های مقایسه شده با در نظر گرفتن فقط کاربران با حداکثر ۵ تعامل در ماه‌های تست در مجموعه داده MovieLens به ازای k=3

برحسب الف (AR@3، ب (AP@3 و ج) AFI@3

قبلی کاربران بر اساس یک فاکتور کاهش زمانی خاص مبتنی بر نرخ پویایی علایق هر کاربر، و استخراج شباهت بین کاربران در دوره‌های زمانی مختلف، و همچنین در نظر گرفتن داده‌های دموگرافی کاربران، با استفاده از تکنیک تجزیه‌ی تنسور-ماتریس‌های اتصالی، top-k آیتم به کاربر پیشنهاد می‌کند. مقایسه‌ی روش پیشنهادی با سایر روش‌ها، برتری روش پیشنهادی و توانایی برخورد آن با مسائل خلوتی داده‌ها و شروع سرد را نشان می‌دهد.

۶- نتیجه‌گیری

یکی از مسائل اساسی در سیستم‌های پیشنهاددهنده، تغییر علایق کاربران در طول زمان می‌باشد. مدل‌سازی پویایی زمانی علایق کاربران باعث بهبود قابل توجهی در دقت پیشنهادها و در نتیجه رضایت کاربران می‌گردد. در این مقاله روشی برای استخراج علایق پویای کاربران توسعه داده شده است که با وزندهی علایق پویای

- [16] 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.
- [17] C. Zhang, "Improving recommender systems with rich side information," Ph.D. dissertation, Simon Fraser University, Canada, 2015.
- [18] Y. Koren, "Collaborative filtering with temporal dynamics," *Communications of the ACM*, vol. 53, no. 4, pp. 89–97, 2010.
- [19] 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.
- [20] 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.
- [21] 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.
- [22] N. N. Liu, L. He, and M. Zhao, "Social temporal collaborative ranking for context aware movie recommendation," *ACM Transactions on Intelligent Systems and Technology*, vol. 4, no. 1, pp. 15:1–15:26, 2013.
- [23] A. Y. Aravkin, K. R. Varshney, and L. Yang, "Dynamic matrix factorization with social influence," in *Proceedings of the 2016 IEEE International Workshop on Machine Learning for Signal Processing*, 2016, pp. 1–6.
- [24] 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.
- [25] L. Xiong, X. Chen, T.-K. Huang, J. Schneider, and J. G. Carbonell, "Temporal collaborative filtering with bayesian probabilistic tensor factorization," in *Proceedings of the 2010 SIAM International Conference on Data Mining*, 2010, pp. 211–222.
- [26] D. Rafailidis and A. Nanopoulos, "Modeling the dynamics of user preferences in coupled tensor factorization," in *Proceedings of the 8th ACM Conference on Recommender systems*, 2014, pp. 321–324.
- [27] T. G. Kolda and B. W. Bader, "Tensor Decompositions and Applications," *SIAM Review*, vol. 51, no. 3, pp. 455–500, 2008.
- [28] E. Acar, M. A. Rasmussen, F. Savorani, T. Næs, and R. Bro, "Understanding data fusion within the framework of coupled matrix and tensor factorizations," *Chemometrics and Intelligent Laboratory Systems*, vol. 129, pp. 53–63, 2013.
- [29] 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.
- [30] M. Wang and J. Ma, "A novel recommendation approach based on users' weighted trust relations and the rating similarities," *Soft Computing*, vol. 20, no. 10, pp. 3981–3990, 2016.
- [31] Q. Do and W. Liu, "ASTEN: An accurate and scalable approach to coupled tensor factorization," in *Proceedings of the International Joint Conference on Neural Networks*, 2016, pp. 99–106.
- [32] E. Acar, D. M. Dunlavy, T. G. Kolda, and M. Morup, "Scalable tensor factorizations for incomplete data," *Chemometrics and Intelligent Laboratory Systems*, vol. 106, no. 1, pp. 41–56, 2011.
- [33] "The Lastfm-1K Dataset." [Online]. Available: <http://www.dtic.upf.edu/~ocelma/MusicRecommendationDataset/lastfm-1K.html>. [Accessed: 01-Jan-2017].
- [34] "The Movielens-1M Dataset." [Online]. Available: <https://grouplens.org/datasets/movielens/>. [Accessed: 01-Jan-2017].
- برای کارهای آینده، مقایسه‌ی روش پیشنهادی با سایر روش‌های پیشنهاددهنده‌ی زمانی و همچنین در نظر گرفتن تغییرات اعتماد بین کاربران در طول زمان در بهبود پیشنهادها، مورد توجه می‌باشد. همچنین پیاده‌سازی به‌صورت موازی مدل پیشنهادی به منظور مقیاس پذیری آن در مجموعه داده‌های بزرگ مفید خواهد بود.

مراجع

- [1] C. Rana and S. K. Jain, "A study of the dynamic features of recommender systems," *Artificial Intelligence Review*, vol. 43, no. 1, pp. 141–153, 2012.
- [2] 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.
- [3] 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.
- [4] C. Rana and S. K. Jain, "An evolutionary clustering algorithm based on temporal features for dynamic recommender systems," *Swarm and Evolutionary Computation*, vol. 14, pp. 21–30, 2014.
- [5] 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.
- [6] I. Barjasteh, "Matrix completion with side Information for effective recommendation," Ph.D. dissertation, Michigan State University, USA, 2016.
- [7] W. Pan, "A survey of transfer learning for collaborative recommendation with auxiliary data," *Neurocomputing*, vol. 177, pp. 447–453, 2016.
- [8] 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.
- [9] 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.
- [10] E. Acar, T. G. Kolda, and D. M. Dunlavy, "All-at-once Optimization for Coupled Matrix and Tensor Factorizations," *arXiv preprint arXiv:1105.3422*, no. 1, 2011.
- [11] E. Acar, R. Bro, and A. K. Smilde, "Data Fusion in Metabolomics Using Coupled Matrix and Tensor Factorizations," *Proceedings of the IEEE*, vol. 103, no. 9, pp. 1602–1620, 2015.
- [12] H. Su, X. Lin, B. Yan, and H. Zheng, "The collaborative filtering algorithm with time weight based on mapreduce," in *International Conference on Big Data Computing and Communications*, 2015, pp. 386–395.
- [13] N. N. Liu, M. Zhao, E. Xiang, and Q. Yang, "Online evolutionary collaborative filtering," in *Proceedings of the fourth ACM conference on Recommender systems*, 2010, pp. 95–102.
- [14] S. Spiegel, J. Clausen, S. Albayrak, and J. Kunegis, "Link prediction on evolving data using tensor factorization," in *New frontiers in applied data mining*, Springer, Berlin, Heidelberg, 2011, pp. 100–110.
- [15] D. M. Dunlavy, T. G. Kolda, and E. Acar, "Temporal link prediction using matrix and tensor factorizations," *ACM Transactions on Knowledge Discovery from Data*, vol. 5, no. 2, pp. 1–27, 2011.

- [35] X. Su and Taghi M.Khoshgoftaar, "A survey of collaborative filtering techniques," *Advances in Artificial Intelligence*, vol. 2009, pp. 1–19, 2009.
- [36] 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.

زیرنویس‌ها:

- ¹ Coupled Tensor Factorization
- ² Singular Value Decomposition
- ³ Expectation Maximization Algorithm
- ⁴ Linear Dynamic System
- ⁵ User's Preference Dynamics
- ⁶ CANDECOMP/PARAFAC
- ⁷ Nonlinear Conjugate Gradient
- ⁸ Genre
- ⁹ Maximum Number of Iterations
- ¹⁰ Maximum Number of Function Evaluations