

ترکیب تجزیه نامنفی ماتریسی با روابط اعتماد برای توصیه در شبکه‌های اجتماعی

هاشم پروین^۱، دانشجوی کارشناسی ارشد، پرهام مرادی^۲، دانشیار، شاهرخ اسماعیلی^۳، استادیار

۱- گروه مهندسی کامپیوتر - دانشگاه کردستان - سنندج - ایران - hashem.parvin.ng@gmail.com

۲- گروه مهندسی کامپیوتر - دانشگاه کردستان - سنندج - ایران - p.moradi@uok.ac.ir

۳- گروه ریاضی کاربردی - دانشگاه کردستان - سنندج - ایران - sh.esmaeili@uok.ac.ir

چکیده: سیستم‌های توصیه‌گر، یکی از ابزارهای مؤثر برای کمک به کاربران است تا آیتم‌های مورد علاقه خودشان را پیدا کنند. سیستم‌های پالایش گروهی یکی از مشهورترین الگوریتم‌های توصیه به شمار می‌روند و در کارهای تجاری مختلفی استفاده شده‌اند. اما این سیستم‌ها در برخورد با کاربران و کالاهایی (آیتم‌هایی) که اطلاعات کمی از آن‌ها وجود دارد (کاربران یا کالاهای با شروع سرد) دارند، کارایی ضعیفی از خود نشان می‌دهند. برای مقابله با این چالش، در این مقاله، یک روش جدید مبتنی بر اطلاعات شبکه اجتماعی کاربران ارائه می‌شود که اطلاعات اعتماد بین کاربران را با تجزیه نامنفی ماتریس ترکیب می‌کند تا یک مدل مناسب برای توصیه به کاربر ایجاد شود. روش پیشنهادی اطلاعات مهم مانند، رتبه و اعتماد را برای کاهش پراکندگی داده و برخورد با مشکلات ناشی از شروع سرد، استفاده می‌کند. به‌علاوه، در روش پیشنهادی از راه‌کار بهینه‌سازی جهت متناوب برای افزایش همگرایی الگوریتم و کاهش پیچیدگی زمانی به‌طور مناسبی استفاده می‌شود. برای ارزیابی روش پیشنهادی چندین آزمایش روی دو مجموعه داده معتبر و مشهور انجام شده است. نتایج تجربی نشان می‌دهد که روش پیشنهادی، به‌ویژه، برای کاربران شروع سرد عملکرد بهتری نسبت به روش‌های جدید، برای توصیه در شبکه‌های اجتماعی دارد.

واژه‌های کلیدی: سیستم‌های توصیه‌گر، تجزیه نامنفی ماتریس، اطلاعات اعتماد، روش جهت متناوب، پالایش گروهی، شروع سرد.

Combining Nonnegative Matrix Factorization technique with Trust Relationships for Recommendation in Social Networks

H. Parvin¹, Msc Student; P. Moradi², Associate Professor; Sh. Esmaeili³, Assistant Professor

1- Department of Computer Engineering, University of Kurdistan, Sanandaj, Iran, Email: Hashem.parvin.ng@gmail.com

2- Department of Computer Engineering, University of Kurdistan, Sanandaj, Iran, Email: p.moradi@uok.ac.ir

3- Department of Applied Mathematics, University of Kurdistan, Sanandaj, Iran, Email: sh.esmaeili@uok.ac.ir

Abstract: Recommender systems has shown as effective tools that are proposed for helping users to select their interested items. Collaborative filtering is a well-known and frequently used recommender system applied successfully in many e-commerce websites. However, these systems have poor performance while facing cold-start users (items). To address such issues, in this paper, a social regularization method is proposed which combines the social network information of users in a nonnegative matrix factorization framework. The proposed method integrates multiple information sources such as user-item ratings and trust statements to reduce the cold-start and data sparsity issues. Moreover, the alternating direction method is used to improve the convergence speed and reduce the computational cost. We use two well-known datasets to show that the proposed method performs much better, especially for cold start users, than state-of-the-art recommendation methods for recommendation in social networks.

Keywords: Recommender systems; nonnegative matrix factorization, trust relationships, alternating direction method, collaborative filtering, cold-start.

تاریخ ارسال مقاله: ۱۳۹۷/۰۷/۰۳

تاریخ اصلاح مقاله: ۱۳۹۷/۱۲/۲۷، ۱۳۹۸/۰۱/۲۱ و ۱۳۹۸/۰۳/۰۴

تاریخ پذیرش مقاله: ۱۳۹۸/۰۴/۰۴

نام نویسنده مسئول: پرهام مرادی

نشانی نویسنده مسئول: ایران - سنندج - دانشگاه کردستان - گروه مهندسی کامپیوتر.

۱- مقدمه

سیستم‌های توصیه‌گر یکی از ابزارهای مفید برای کمک به کاربران تجارت الکترونیک است تا بتوانند، محصولات مورد علاقه خودشان را پیدا کنند. این سیستم‌ها سعی دارند، بر اساس عملکرد، سلیقه‌های شخصی، رفتارهای کاربر و بسته به زمینه‌ای که در آن مورد استفاده قرار می‌گیرند، به هر کاربر پیشنهادهایی را ارائه دهند که با تمایلات شخصی وی تطابق داشته و کاربر را در فرایند تصمیم‌گیری یاری نمایند [۱، ۲]. سیستم‌های توصیه‌گر پالایش گروهی یکی از پرکاربردترین و مؤثرترین روش‌های توصیه محسوب می‌شوند. این سیستم‌ها با بررسی انتخاب‌های کاربران در گذشته، الگوهایی را در داده‌ها پیدا می‌کنند و با توجه به آن الگوهای رفتاری، برای هر کاربر توصیه مناسب را ارائه می‌دهند. روش‌های پالایش گروهی به دو دسته کلی شامل، روش‌های مبتنی بر حافظه و روش‌های مبتنی بر مدل تقسیم‌بندی می‌شوند [۳]. در روش‌های مبتنی بر حافظه، کل داده‌های موجود در حافظه نگهداری می‌شوند و از آن‌ها برای پیش‌بینی سلیقه کاربر هدف استفاده می‌شود. بنابراین مقیاس‌پذیری کم و مصرف حافظه و زمان پردازش بالایی دارند. در مقابل، در روش‌های مبتنی بر مدل از بخشی از داده برای ساخت مدل و پیش‌بینی سلیقه کاربر استفاده می‌شود، لذا پیچیدگی حافظه و زمان اجرای کمتری برای پردازش داده‌ها نیاز دارند [۴]. تجزیه ماتریسی^۱ یکی از مؤثرترین روش‌های مبتنی بر مدل است که کارایی بالایی در حوزه‌های مختلف دارد. ایده اصلی تجزیه ماتریسی انتقال کاربران و آیتم‌ها به فضای مشخص به نام فضای نهان است. در این روش به جای محاسبه شباهت‌های آماری بین کاربرها یا آیتم‌ها، مانند ضریب همبستگی، از طریق ماتریس رتبه‌ها، فضای عامل‌های نهان (معمولاً با بعد کم) برآورد می‌شود. کاربران و آیتم‌ها در این فضا واقع می‌شوند و امتیاز کاربر به آیتم می‌تواند از طریق ضرب داخلی بردار ویژگی کاربر و آیتم (در این فضا) تا حد خوبی تخمین زده شود [۵، ۶]. روش‌های مختلفی براساس تجزیه ماتریسی برای سیستم‌های توصیه‌گر، ارائه شده‌اند. برای نمونه، روش تجزیه احتمالی [۵]، تجزیه مبتنی بر الگوریتم‌های فرا ابتکاری [۷]، تجزیه‌های نامنفی ماتریسی [۲، ۴، ۸] و سایر روش‌های دیگری که به صورت ترکیبی از تجزیه ماتریسی استفاده می‌کنند [۹، ۱۰].

یکی از کارآمدترین این روش‌ها، روش تجزیه نامنفی ماتریسی مبتنی بر راهکار جهت متناوب است. این روش برای ایجاد یک مدل مناسب از داده‌های بزرگ، ارائه شده است و به خوبی می‌تواند برای داده‌های با مقیاس بالا، مدل مناسبی را از داده‌های آموزشی ایجاد کند [۲]. اما این روش و اغلب روش‌های پالایش گروهی از دو چالش اساسی، یعنی پراکندگی داده و شروع سرد^۲ در امان نیست. زیرا کاربران به اغلب آیتم‌ها امتیاز نمی‌دهند و در نتیجه ماتریس رتبه‌بندی، بسیار تنک است و تصمیم‌گیری بر اساس رتبه‌های موجود، دقت کمی دارد [۱۱]. در واقع شروع سرد، شامل کاربرانی است که به کمتر از پنج آیتم، امتیاز داده‌اند [۱۲]. برای رویارویی با این چالش‌ها پژوهش‌های مختلفی از اطلاعات کمکی برای مقابله با این چالش‌ها استفاده کرده‌اند،

تا پراکندگی ماتریس رتبه را به وسیله این اطلاعات کاهش دهند. برای مثال در [۱۳] از اطلاعات تگ‌ها به عنوان اطلاعات کمکی برای افزایش کارایی توصیه استفاده می‌شود، اما مدل ارائه شده مقیاس‌پذیری خوبی ندارد و در مقابل شروع سرد ضعیف عمل می‌کند. همچنین در [۱۴] از اطلاعات اعتماد برای مقابله با شروع سرد و کاهش پراکندگی داده، استفاده می‌شود که هرچند دقت توصیه‌گری خوبی دارد، اما پیچیدگی‌های ناشی از مدل ایجادشده توسط این الگوریتم، باعث کاهش عملکرد آن در برخورد با داده‌های بزرگ می‌شود. در این مقاله با الهام از [۲]، یک روش مبتنی بر تجزیه ماتریسی به همراه اطلاعات اعتماد بین کاربران در شبکه‌های اجتماعی ارائه می‌شود که در برخورد با مشکلات ناشی از شروع سرد و پراکندگی داده عملکرد مناسبی دارد. در واقع، روش [۲] که یک روش کارآمد محسوب می‌شود، نسبت به مشکلات شروع سرد و پراکندگی داده بی‌توجه است و لذا نمی‌تواند در برخورد با این مشکلات عملکرد مناسبی داشته باشد. در این مقاله به منظور بهبود این روش از اطلاعات شبکه‌های اجتماعی کاربران برای کمک به تجزیه دقیق تر ماتریس رتبه‌بندی استفاده می‌شود. به صورت خلاصه می‌توان گفت که روش پیشنهادی بهبودیافته روش [۲] است که از اطلاعات اعتماد بین کاربران برای بهبود عملکرد روش [۲] در مقابل کاربران شروع سرد (کاربران و یا آیتم‌هایی (کالاها یا اقلام) که اطلاعات کمی از آن‌ها وجود دارد) استفاده می‌کند. به عبارت دیگر روش پیشنهادی از اطلاعات اعتماد بین کاربران در شبکه‌های اجتماعی برای غلبه بر مشکل شروع سرد و پراکندگی داده استفاده می‌کند تا بتواند دقت توصیه‌ها را با اطلاعات اضافی پیرامون ماتریس رتبه‌ها افزایش دهد. در روش پیشنهادی و روش ارائه شده در مرجع [۲] از بهینه‌سازی جهت متناوب برای حل تابع هدف استفاده شده است. مزیت استفاده از این روش بهینه‌سازی جهت متناوب، همگرایی سریع و پیچیدگی محاسباتی کم است که امکان استفاده از این روش‌ها را برای مسائل با مقیاس بزرگ فراهم می‌کند. نتایج ارائه شده بر روی دو مجموعه داده‌ای واقعی نشان‌دهنده این است که اضافه کردن اطلاعات اعتماد می‌تواند منجر به افزایش دقت سیستم‌های توصیه‌گر شود. همچنین این نتایج نشان‌دهنده این است که روش بهینه‌سازی جهت متناوب می‌تواند منجر به افزایش همگرایی و زمان اجرای الگوریتم‌های تجزیه ماتریسی شود. مهم‌ترین نوآوری‌های این مقاله به شرح زیر است:

- روش پیشنهادی از اطلاعات اعتماد بین کاربران استفاده می‌کند و در مقابل شروع سرد و پراکندگی داده می‌تواند خوب عمل کند. درحالی‌که روش‌های دیگر از اطلاعات اعتماد استفاده نمی‌کنند و اگر هم استفاده کنند نسبت به روش پیشنهادی کارایی کمتری دارند [۱۰، ۱۵، ۱۶].
- روش پیشنهادی به دلیل استفاده مناسب از تجزیه ماتریسی می‌تواند به خوبی رتبه‌بندی کاربران را در فضای نهان مدل کند و اطلاعات اعتماد را همراه رتبه برای ایجاد یک مدل مناسب

برچسب‌های اجتماعی تعریف می‌شود. این رویکرد از روش‌های بازیابی اطلاعات است. در [۲۵] یک رویکرد جدید پیشنهاد شده است که پالایش گروهی و توصیه‌های محتوا را باهم ترکیب می‌کند. در راستای روش‌های پالایش گروهی، ابتدا روش‌های مبتنی بر حافظه معرفی شد. در [۱۶] یک روش مبتنی بر حافظه برای افزایش کارایی سیستم‌های توصیه‌گر ارائه شد که از اطلاعات آیت‌ها برای ایجاد مدل مناسب استفاده می‌کرد. این روش مبتنی بر آیت‌ها بود و بیشتر بر اساس محتوای آیت‌هایی که مربوط به سلیقه گروهی مشخص از کاربران بود، توصیه‌هایی را به افراد مشابه آن کاربران انجام می‌داد. همچنین، در [۲۶] یک روش فرمول‌بندی مسئله پالایش گروهی مبتنی بر حافظه در یک چارچوب احتمالی ارائه شده است و دسته‌بندی‌های موردنظر کاربر را برای پیش‌بینی امتیازهای او انجام می‌دهند. به دلیل محدودیت‌های حافظه و مقیاس‌پذیری آن‌ها، روش‌های مبتنی بر مدل ارائه شدند. از کارآمدترین روش‌های مبتنی بر مدل، می‌توان به روش‌های رتبه‌بندی بر اساس تجزیه ماتریسی اشاره کرد [۲۷] که سلیقه کاربر هدف را با پیش‌بینی رتبه انجام می‌دهد. در این روش بیشتر بر اطلاعات ضمنی کاربران یا آیت‌ها تکیه می‌شود و به امتیازها کمتر توجه می‌شود. به دلیل مشکلات سایر روش‌های ارائه‌شده از جمله شروع سرد، در ادامه روش‌های مبتنی بر اطلاعات اجتماعی از جمله اعتماد بین کاربران در [۱۹] ارائه شد. در این روش علاوه بر ماتریس امتیازها از ماتریس اعتماد هم استفاده می‌شود و در آن امتیازها و اعتماد با استفاده از تجزیه ماتریس برای ایجاد یک مدل مناسب ترکیب می‌کند. برای بهبود کیفیت توصیه‌ها، روش ارائه‌شده در [۲۸] وزن یک کاربر را در محاسبه شباهت‌ها و تفاوت‌ها در نظر می‌گیرد. در این روش، یک رویکرد مبتنی بر رتبه کاربر میان محصولات مبتنی بر رتبه پیشنهاد شده است که در برخورد با داده‌های تنک کارایی خوبی دارد. در مواجهه با شروع سرد با دارا بودن مقیاس‌پذیری مناسب‌تر، در [۱۲] یک معیار شباهت جدید با استفاده از بهینه‌سازی مبتنی بر یادگیری شبکه عصبی ارائه شده است. نتایج به دست آمده از این روش از معیارهای فعلی فراتر می‌رود و دارای دقت و کیفیت بالا در هنگام اعمال شرایط شروع سرد است. همچنین نویسندگان در [۲۹] از پروفایل‌های متنی برای توصیه‌های شخصی استفاده می‌کنند. آن‌ها یک روش برای محاسبه رابطه معناشناختی بین مفاهیم در ساختارهای هسته‌شناسی غنی و پیچیده ایجاد می‌کنند و یک مطالعه کاربر محور را برای ارزیابی اثربخشی توصیه‌ها توسط روش انجام می‌دهند که از معیاری دقیق برای ارزیابی روش استفاده می‌شود. پس از آن یک روش جدید مبتنی بر خوشه‌بندی و اعتماد در [۱۷] ارائه شد. این روش از راهکار خوشه‌بندی استفاده می‌کند و با استفاده از اطلاعات رتبه و اعتماد برای هر کدام از کاربران یک خوشه مجزا می‌سازد و برای کاربر هدف با تعیین خوشه او، رتبه کاربر هدف را به خوبی پیش‌بینی می‌کند. در ادامه روش‌های تجزیه نامنفی ماتریسی ارائه شد و نویسندگان در [۲۱] یک روش تجزیه نامنفی ماتریسی برای پیش‌بینی دقیق رتبه‌ها ارائه کردند. این روش شرط نامنفی بودن

استفاده کند. در حالی که روش‌های قبلی این مدل را همراه با ضعف و پیچیدگی بالا ایجاد می‌کنند [۱۷-۱۹].

- روش‌های موجود اغلب به نامنفی بودن رتبه‌ها بی‌توجه بوده‌اند، اما در روش پیشنهادی با راه‌کاری مناسب نامنفی بودن رتبه‌ها تضمین می‌شود [۷، ۱۸، ۲۰].
 - روش پیشنهادی به دلیل استفاده از راه‌کار بهینه‌سازی جهت متناوب، سرعت همگرایی بالا، پیچیدگی زمانی کمتر و مقیاس‌پذیری بهتر نسبت به سایر روش‌ها دارد [۲، ۵، ۱۵].
 - روش پیشنهادی تأثیر اعتمادشوندگان و اعتمادکنندگان برای کمک به تجزیه‌ای بهتر را در نظر می‌گیرد. اما برخی از روش‌های قبلی تنها یکی از این دو مورد را در نظر می‌گیرند [۶، ۱۴، ۱۷]. پس روش پیشنهادی انعطاف‌پذیری بالایی برای کاربردهای مختلف توصیه‌گری دارد.
 - روش پیشنهادی دارای پیاده‌سازی آسان است و به ساختمان داده نیاز ندارد، از سرعت بالایی برخوردار است و می‌تواند روی مجموعه داده‌های بزرگ و معتبر جواب‌های بهتری نسبت به روش‌های جدید مانند [۲، ۱۲، ۱۸، ۲۱] تولید کند.
- ساختار این مقاله چنین است. در بخش ۲ مروری بر کارهای انجام‌شده در زمینه‌های مرتبط با این کار ارائه می‌شود. در بخش ۳ روش پیشنهادی همراه با جزئیات کامل مانند شبه‌کد الگوریتم ارائه می‌شود. در بخش ۴ برای ارزیابی کارایی روش پیشنهادی در مقایسه با سایر روش‌های جدید آزمایش‌های تجربی روی مجموعه‌های داده‌ای مختلف انجام شده است. در بخش ۵ نتیجه‌گیری و پیشنهاد برای انجام کارهای آتی در راستای این مقاله آمده است.

۲- مروری بر کارهای پیشین

سیستم‌های توصیه‌گر بر اساس نوع اطلاعات جمع‌آوری‌شده و روش‌های استفاده از آن‌ها، می‌توانند در سه دسته طبقه‌بندی شوند: (۱) مبتنی بر محتوی، (۲) پالایش گروهی، (۳) ترکیبی [۱۷]. برای مقابله با چالش‌های سیستم‌های توصیه‌گر الگوریتم‌های متعددی مورد استفاده قرار می‌گیرند که بیشتر آن‌ها بر پایه الگوریتم مبتنی بر پالایش گروهی است. سیستم‌های توصیه‌گر موجود در مواجهه با کاربرانی که آیت‌های کمی را رتبه‌بندی می‌کنند، دچار مشکل می‌شوند و کارایی خود را از دست می‌دهند. در ارتباط با روش‌های مبتنی بر محتوا و غلبه بر پراکندگی داده، مدل‌های احتمالی همراه با الگوریتم‌های استاندارد یادگیری استفاده شده است [۲۲]. نویسندگان [۲۳] یک روش برای ایجاد پروفایل کاربر شامل توصیف انواع آیت‌های موردعلاقه کاربر به همراه ابزار مقایسه محصولات پروفایل کاربر برای تعیین محصول مورد نیاز ارائه داده‌اند. در این روش پروفایل کاربر به‌طور خودکار از طریق بازخورد در مورد مطلوبیت محصولات ارائه‌شده به کاربر به‌روزرسانی می‌شود. در [۲۴] پروفایل کاربر و آیت‌ها بر اساس لیست‌های وزنی از

غیرممکن می‌کند. برای غلبه بر این مشکل، در مرجع [۲] از روش بهینه‌سازی جهت متناوب^۱ برای حل مسائل تابع هدف تجزیه نامنفی ماتریسی برای سیستم‌های توصیه‌گر استفاده شده است. جزئیات روش [۲] در بخش ۳-۲ ارائه شده است. برای استفاده از روش بهینه‌سازی جهت متناوب نیاز به تعریف تعدادی متغیر کمکی است. بنابراین تابع هدف روش ارائه‌شده بر مبنای استفاده از روش بهینه‌سازی جهت متناوب در معادله (۵) ارائه شده است. از مزایای این روش می‌توان به سرعت همگرایی بالا و پیچیدگی محاسباتی کم اشاره کرد.

به صورت کلی در سیستم‌های توصیه‌گر، کاربران نظر خود را در خصوص تعداد محدودی از آیتم و یا کالاها ثبت می‌کنند. بنابراین در این سیستم‌ها معمولاً ماتریس رتبه یک ماتریس بسیار تنگ است. از طرفی در این سیستم‌ها کاربران یا آیتم‌هایی وجود دارند که اطلاعات کمی از آن‌ها در ماتریس رتبه وجود دارد. به این موارد کاربران یا آیتم‌های با شروع سرد گفته می‌شود و پیش‌بینی رتبه برای آن‌ها تنها با استفاده از اطلاعات رتبه‌ها کار بسیار سختی است. برای رفع این مشکل معمولاً از اطلاعات دیگر همانند اطلاعات پرو فایل افراد در شبکه‌های اجتماعی به عنوان اطلاعات کمکی در بهبود پیش‌بینی رتبه استفاده می‌شود. در این مقاله نیز روش ارائه شده در [۲] به صورتی بهبود داده شده است که از اطلاعات اعتماد و یا اطلاعات دوستی افراد در شبکه‌های اجتماعی به عنوان اطلاعات کمکی استفاده شود. به همین منظور، معادله (۵) به نحوی بسط داده شد که این اطلاعات کمکی را در آن استفاده کرد. لذا تابع هدف نهایی روش پیشنهادی این مقاله به صورت معادله (۱۰) ارائه شد. این تابع هدف دربرگیرنده اطلاعات رتبه و اطلاعات اعتماد (یا دوستی) افراد در شبکه‌های اجتماعی است. برای حل معادله از روش بهینه‌سازی جهت متناوب استفاده شد و نتیجه آن به صورت توابع به روزرسانی افزایشی در معادلات (۱۴) تا (۱۷) ارائه شد. در ادامه جزئیات هر کدام از این موارد در بخش مربوطه توضیح داده شده است.

۳-۱- تشکیل تابع هدف اولیه

در سیستم‌های توصیه‌گر رفتار کاربران نسبت به آیتم‌ها با استفاده از یک ماتریس رتبه مدل می‌شود. این ماتریس را با R ، مجموعه کاربران را با U ، مجموعه آیتم‌ها را با I نشان می‌دهند. هر مؤلفه از ماتریس R نشان‌دهنده رتبه کاربر u به آیتم i است که با $r_{u,i}$ نشان داده می‌شود. رتبه‌های مشخص در ماتریس R را با R_K نشان می‌دهند. هدف اصلی در پالایش گروهی تخمین رتبه‌های نامشخص در ماتریس R با استفاده از رتبه‌های مشخص است. در واقع، باید این تخمین طوری باشد که ماتریس اولیه به‌ازای رتبه‌های موجود کمترین فاصله را از ماتریس تخمینی \hat{R} داشته باشد. به عبارت دیگر، ماتریس \hat{R} که توسط یک الگوریتم پالایش گروهی تخمین زده می‌شود بایستی با ماتریس R کمترین اختلاف را داشته باشد.

بردارهای نهان مربوط به آیتم‌ها و کاربران را با راه‌کارهای بهینه‌سازی کارآمد، تضمین می‌کند و در زمان مناسبی به نتایج خوبی می‌رسد. در ادامه روش‌های مبتنی بر اطلاعات شبکه اجتماعی، نویسندگان در [۱۸] یک روش مبتنی بر تجزیه ماتریسی و اطلاعات اعتماد ارائه دادند که در آن پیش‌بینی دقیق امتیازها با اضافه کردن اطلاعات شبکه اجتماعی به تابع هدف تجزیه ماتریسی انجام می‌شود. نویسندگان در [۲۱] یک روش تجزیه برخط را برای تخمین رتبه‌ها ارائه کردند که در آن ماتریس امتیازها به چند ماتریس کوچک‌تر شکسته می‌شود و بر اساس مدل ساخته‌شده برای کاربران و آیتم‌های جدید رتبه‌ها در زمان کوتاهی تخمین زده می‌شود. در ادامه نویسندگان در [۱۵] برای افزایش دقت توصیه یک روش احتمالی تجزیه ماتریس با استفاده از خوشه‌بندی ارائه دادند که از احتمال بیز^۲ برای تجزیه استفاده می‌شود تا یک مدل مناسب از داده‌های هر خوشه به دست آید. همان‌طور که بیان شد روش‌های مبتنی بر تجزیه ماتریسی در موارد مختلف توصیه‌گری عملکرد مناسب دارند. اگر از اطلاعات کمکی برای تجزیه استفاده شود چالش‌های پراکندگی داده و شروع سرد تا حد زیادی برطرف می‌شوند. بنابراین در این مقاله از راهکار تجزیه ماتریس همراه اطلاعات شبکه اجتماعی افراد برای ایجاد یک مدل مناسب و توصیه به کاربر استفاده می‌کنیم.

۳-۲ روش پیشنهادی مبتنی بر تجزیه نامنفی ماتریسی و اطلاعات اعتماد

در روش پیشنهادی برای رفع چالش‌های موجود در سیستم‌های پالایش گروهی، از راه‌کار تجزیه ماتریسی همراه اطلاعات اعتماد بین کاربران استفاده می‌شود تا دقت سیستم برای کاربران مختلف افزایش یابد. همچنین برای افزایش همگرایی و مقیاس‌پذیری از راه‌کارهای بهینه‌سازی مناسب استفاده می‌شود. روش پیشنهادی بهبودیافته روش [۲] است که چون این روش در مقابل شروع سرد و پراکندگی داده ناکارآمد است. لذا روش پیشنهادی از اطلاعات اعتماد بین کاربران در شبکه‌های اجتماعی برای غلبه بر مشکل شروع سرد و پراکندگی داده استفاده می‌کند تا دقت توصیه‌ها را با اطلاعات اضافی پیرامون ماتریس رتبه‌ها افزایش دهد. لذا، در این مقاله یک روش جدید مبتنی بر تجزیه ماتریسی و اطلاعات اعتماد کاربران در شبکه‌های اجتماعی ارائه می‌شود تا بتوان دقت و کیفیت سیستم را تا حد زیادی با استفاده از این اطلاعات افزایش داد. در ادامه ابتدا جزئیات روش تجزیه ماتریسی برای پیش‌بینی رتبه‌ها در سیستم‌های توصیه‌گر در بخش ۳-۱ ارائه شده است. رابطه (۱) تابع هدف تجزیه نامنفی ماتریسی را نشان می‌دهد. برای حل این مسئله معمولاً از روش بهینه‌سازی کاهش گرادیان استفاده می‌شود. یکی از ایرادهای استفاده از روش بهینه‌سازی کاهش گرادیان، همگرایی کند، پیچیدگی محاسباتی بالا و گیرافتادن در بهینه محلی است که استفاده از این روش را برای مسائل با مقیاس بزرگ

است. برای این منظور بر طبق قاعده بسط لاگرانژ دو ماتریس کمکی $X = (x_{u,i}) \in \mathbb{R}^{|U| \times f}$ و $Y = (y_{u,i}) \in \mathbb{R}^{|U| \times f}$ برای جداسازی محدودیت نامنفی بودن متغیرها و به روزرسانی پارامترها تعریف می‌شوند. در نتیجه تابع هدف رابطه (۲) به رابطه (۳) تبدیل خواهد شد.

$$\min \frac{1}{2} \|R - XY^T\|_F^2 = \frac{1}{2} \sum_{(u,i) \in R_k} \left(r_{u,i} - \sum_{k=1}^f x_{u,k} y_{i,k} \right)^2 \quad (3)$$

s.t. $X = P \geq 0, Y = Q \geq 0$

اکنون با اضافه کردن محدودیت‌های مسئله با یک ضریب مشخص به رابطه (۳)، تابع هدف (۴) نتیجه خواهد شد.

$$L(P, Q, X, Y, \Gamma, H) = \frac{1}{2} \|R - XY^T\|_F^2 + \sum_{(u,k)} [\Gamma \circ (X - P)]_{u,k} + \sum_{(u,k)} [H \circ (Y - Q)]_{u,k} + \frac{\rho}{2} \|X - P\|_F^2 + \frac{\tau}{2} \|Y - Q\|_F^2 \quad (4)$$

که در آن $\Gamma = (\gamma_{u,k}) \in \mathbb{R}^{|U| \times f}$ و $H = (h_{i,k}) \in \mathbb{R}^{|U| \times f}$ ضرایب لاگرانژ مربوط به محدودیت‌های $X = P$ و $Y = Q$ می‌باشند. عملگر \circ نشان‌دهنده ضرب آدامار (یا مؤلفه‌ای) بین دو ماتریس است. همچنین، ρ و τ پارامترهای جریمه و مثبت هستند که به محدودیت‌های $X - P = 0$ و $Y - Q = 0$ مربوط می‌باشند. رابطه (۴) تابع هدف روش [۲] است که می‌توان آن را به صورت تک‌عنصری وابسته به رابطه (۵) بسط داد.

$$L(P, Q, X, Y, \Gamma, H) = \frac{1}{2} \sum_{(u,i) \in \Omega} \left(r_{u,i} - \sum_{k=1}^f x_{u,k} y_{i,k} \right)^2 + \sum_{(u,k) \in \Omega} \gamma_{u,k} (x_{u,k} - p_{u,k}) + \sum_{(i,k) \in \Omega} h_{i,k} (y_{i,k} - q_{i,k}) + \sum_{(u,k) \in \Omega} \rho_u (x_{u,k} - p_{u,k})^2 + \sum_{(i,k) \in \Omega} \tau_i (y_{i,k} - q_{i,k})^2 \quad (5)$$

شایان ذکر است که در رابطه (۵) پارامترهای ρ و τ تأثیر قابل توجهی در همگرایی و دقت مدل دارند، بنابراین به صورت $\rho_u = \lambda |\Omega_u|$ و $\tau_i = \lambda |\Omega_i|$ تنظیم می‌شوند. در اینجا Ω_u و Ω_i به ترتیب تعداد رتبه‌های مشخص کاربر u و آیت i و λ یک پارامتر کنترلی است.

۳-۳- اضافه کردن اعتماد به مدل

بی‌شتر سیستم‌های توصیه‌گر با پراکندگی داده و شروع سرد مواجه هستند که برای غلبه بر این مشکلات از اطلاعات کمکی برای بهبود

براساس ایده تجزیه ماتریسی، ماتریس R به حاصل ضرب دو ماتریس کم-رتبه، با رتبه f تجزیه می‌شود. این دو ماتریس به صورت $P \in \mathbb{R}^{|U| \times f}$ و $Q \in \mathbb{R}^{|U| \times f}$ می‌باشند که $f \ll \min(|U|, |I|)$. در اینجا P ماتریس نهان کاربران و منعکس‌کننده ویژگی‌های نهان مربوط به کاربران است. همچنین، Q ماتریس نهان آیت‌ها و نشان‌دهنده ویژگی‌های نهان آیت‌ها می‌باشد. فرآیند تجزیه ماتریسی می‌تواند با کمینه‌سازی تابع هدف رابطه (۱) اجرا شود.

$$\|R - PQ^T\|_F^2 = \sum_{(u,i) \in R_k} \left(r_{u,i} - \sum_{k=1}^f p_{u,k} q_{i,k} \right)^2 \quad \text{s.t. } P, Q \geq 0 \quad (1)$$

که ماتریس R همان ماتریس داده‌های آموزشی است که باید کمترین اختلاف را با $\hat{R} = PQ^T$ داشته باشد. در الگوریتم‌های تجزیه هدف به دست آوردن ماتریس‌های نهان P و Q است، طوری که حاصل ضرب آن‌ها کمترین اختلاف را با ماتریس اولیه داشته باشد و البته عناصر این ماتریس‌ها نامنفی باشند، زیرا در سیستم‌های توصیه‌گر رتبه‌های داده شده به آیت‌ها عددی مثبت است.

۳-۲- ایجاد مدل فاکتور نهان مبتنی بر بسط لاگرانژ

روش ارائه شده در [۲] یکی از روش‌های کارآمد برای توصیه‌گر است که هدف آن پیش‌بینی رتبه برای سیستم‌های توصیه‌گر پالایش گروهی هنگام مواجهه با داده‌های مقیاس بالا می‌باشد. این روش می‌تواند نتایج خوبی روی مجموعه داده‌ای مشخص بگیرد و دارای دقت بالا، مقیاس‌پذیری بالا و پیچیدگی کم است. اما نقطه ضعفی که این روش و شاید اغلب روش‌های توصیه‌ای دارند، مشکل شروع سرد و پراکندگی داده می‌باشد. در واقع، این روش در برخورد با داده‌های تنک و مشکلات ناشی از شروع سرد عملکرد ضعیفی دارد. بنابراین، یکی از اهداف این مقاله بهبود این روش با استفاده از اطلاعات اعتماد بین کاربران در شبکه‌های اجتماعی است. برای ارائه روش پیشنهادی، نخست لازم است تابع هدف و نحوه عملکرد روش [۲] بیان شود. این برای بهینه‌سازی تابع هدف و اعمال محدودیت‌ها از روش بهینه‌سازی بسط ضرایب لاگرانژ^۴ استفاده می‌کند. هنگام استفاده از چارچوب مبتنی بر بسط ضرایب لاگرانژ، تجزیه یک کار اصلی یادگیری است که می‌تواند بر پایداری مدل اثر گذارد. به‌طور کلی، ترجیح داده می‌شود که یک مسئله بهینه‌سازی به زیرمسئله‌های کوچک‌تر تقسیم شود. بنابراین، رابطه (۱) را به یک صورت تک‌عنصری وابسته بسط داده می‌شود تا رابطه (۲) حاصل شود.

$$\min \frac{1}{2} \|R - PQ^T\|_F^2 = \frac{1}{2} \sum_{(u,i) \in R_k} \left(r_{u,i} - \sum_{k=1}^f p_{u,k} q_{i,k} \right)^2 \quad \text{s.t. } P, Q \geq 0 \quad (2)$$

چون P و Q بایستی نامنفی باشند، لذا با یک مسئله سخت روبه‌رو هستیم و بهینه‌سازی مستقیم رابطه (۲) پیچیده است. بدین منظور این روش با اعمال قاعده کلی روش بسط لاگرانژ سعی در بهینه‌سازی تناوبی متغیرها دارد. در واقع، هدف روش تقسیم یک مسئله بهینه‌سازی بزرگ به چندین زیرمسئله کوچک، برای افزایش همگرایی الگوریتم

در اینجا β تأثیر اعتماد روی کاربر u را مشخص می‌کند و $\mathcal{F}^+(u)$ مجموعه کاربرانی است که کاربر هدف به آن‌ها اعتماد دارد. چون بردارهای نهان ماتریس P مشخص‌کننده ویژگی‌های نهان کاربران است، بنابراین ویژگی‌های نهان کاربران مورد اعتماد کاربر هدف بایستی به ویژگی‌های نهان کاربران هدف نزدیک شود. به این ترتیب می‌توان از اطلاعات آن‌ها برای پیش‌بینی و مقابله با پراکندگی داده استفاده کرد. همان‌طور که گفته شد علاوه بر کاربران مورد اعتماد کاربران هدف، کاربرانی که به کاربر هدف اعتماد دارند نیز در فرایند تصمیم‌گیری نقش دارند. لذا، تأثیر بردارهای نهان این کاربران روی بردار نهان کاربر هدف اعمال می‌شود تا سلیقه کاربر هدف در حد امکان به کاربرانی که به او اعتماد دارند نزدیک شود. در نتیجه می‌توان رابطه (۷) را برای انجام این عمل تعریف نمود.

$$T_2(P) = \frac{\beta}{2} \sum_u \sum_{g \in \mathcal{F}^-(u)} \|P_u - P_g\|_F^2 \quad (7)$$

در اینجا $\mathcal{F}^-(u)$ مجموعه کاربرانی است که به کاربر هدف اعتماد دارند. در اینجا نیز ویژگی‌های نهان کاربران موردنظر بایستی به بردارهای نهان کاربر هدف نزدیک شود تا به این ترتیب بتوان از اطلاعات آن‌ها برای تخمین رتبه و مقابله با پراکندگی داده استفاده کرد و یک مدل مناسب از رتبه و اعتماد ساخت. با وجود این، در عمل ممکن است کاربر هدف با بعضی از کاربران (اعتمادکنندگان یا اعتمادشوندگان) شباهت کمتر و با بعضی دیگر شباهت بیشتر داشته باشد. یک کار منطقی این است که میزان نزدیکی بردارهای نهان کاربر هدف با کاربر در صد مشخص به دیگر کاربران نزدیک شود و اگر کاربر هدف با کاربر دیگر همبستگی رتبه (شباهت) بیشتر داشته باشد، بهتر است که سلیقه او بیشتر به این کاربر نزدیک شود. در مقابل، اگر همبستگی رتبه (تشابه) کمتری دارد، سلیقه کاربر هدف با آن درصد تشابه به آن کاربر نزدیک شود. در نتیجه برای اعمال این قاعده و تشکیل عبارت نهایی اعتماد رابطه (۸) تعریف می‌شود.


$$T_3(P) = \frac{\beta}{2} \sum_u \sum_{f \in \mathcal{F}^+(u)} \text{sim}(u, f) \|P_u - P_f\|_F^2 + \frac{\beta}{2} \sum_u \sum_{g \in \mathcal{F}^-(u)} \text{sim}(u, g) \|P_u - P_g\|_F^2 \quad (8)$$

در اینجا $\text{sim}(u, f)$ میزان شباهت بین دو کاربر u و f را نشان می‌دهد. این کمیت همان شباهت پیرسن^۷ است که همبستگی بین رتبه‌های دو کاربر را نشان می‌دهد و با رابطه (۹) به دست می‌آید.

$$\text{sim}(a, b) = \frac{\sum_{z \in A_{a,b}} (r_z(a) - \bar{r}(a))(r_z(b) - \bar{r}(b))}{\sqrt{\sum_{z \in A_{a,b}} (r_z(a) - \bar{r}(a))^2} \sqrt{\sum_{z \in A_{a,b}} (r_z(b) - \bar{r}(b))^2}} \quad (9)$$


که در آن $r_z(b)$ رتبه‌ای است که کاربر b به آیتم z داده است، $A_{a,b}$ مجموعه آیتم‌هایی است که کاربران a و b به آن‌ها رتبه داده‌اند، $\bar{r}(a)$

نتایج استفاده می‌کند [۱۴، ۳۰]. در این مقاله از اطلاعات اعتماد بین کاربران در شبکه‌های اجتماعی برای غلبه بر پراکندگی داده و شروع سرد استفاده می‌شود. در شبکه‌های اجتماعی، اعتماد غالباً به صورت یک طرفه است، یعنی ممکن است کاربری به کاربری دیگر، اعتماد داشته باشد، اما دیگری به او اعتماد نداشته باشد. از سوی دیگر، بر اساس تحقیقات انجام‌شده سلیقه کاربر هدف تحت تأثیر کاربرانی که به آن‌ها اعتماد دارد (اعتمادشوندگان^۵) و کاربرانی که به او اعتماد دارند (اعتمادکنندگان^۶) قرار می‌گیرد [۱۴، ۱۸]. بنابراین در این مقاله جهت بهبود عملکرد روش پایه، اطلاعات اعتمادکنندگان و اعتمادشوندگان به صورت مناسبی به تابع هدف اضافه می‌شود، تا مدل از اطلاعات رتبه و اعتماد برای پیش‌بینی دقیق‌تر استفاده کند. همان‌طور که از تجزیه ماتریس R در شکل ۱ مشخص است، ماتریس کاربران و ماتریس آیتم‌ها در یک فضای f بعدی مشخص قرار می‌گیرند و با حاصل ضرب بردارهای ویژگی کاربران و آیتم‌ها در این فضا سلیقه کاربران نسبت به آیتم‌های مختلف تخمین زده می‌شود.



شکل ۱: تجزیه ماتریس در فضای نهان f بعدی

با توجه به شکل ۲ و بر طبق این قاعده که سلیقه کاربر هدف به سلیقه دوستان او تا حد امکان نزدیک است، می‌توان گفت کاربرانی که به کاربر هدف اعتماد دارند باید سلیقه کاربر هدف به آن‌ها نزدیک باشد.



شکل ۲: قرارگیری کاربران و آیتم‌ها در فضای نهان f بعدی

در نتیجه با در نظر گرفتن تأثیر کاربرانی که کاربر هدف به آن‌ها اعتماد دارد، می‌توان رابطه (۶) را تشکیل داد، که تا حد امکان سلیقه کاربر هدف را به کاربران مورد اعتماد او نزدیک می‌کند.

$$T_1(P) = \frac{\beta}{2} \sum_u \sum_{f \in \mathcal{F}^+(u)} \|P_u - P_f\|_F^2 \quad (6)$$

با حل معادله $\frac{\partial \Phi}{\partial X} = 0$ ، مقدار بهینه پارامتر مربوطه را می توان با رابطه (۱۱) به دست آورد.

$$x_{u,k} = \frac{\sum_{i \in R_k(u)} y_{i,k} \left(r_{u,i} - \sum_{j=1, j \neq k}^f x_{u,j} y_{i,j} \right) + \rho_u p_{u,k} - \gamma_{u,k}}{\sum_{i \in R_k(u)} y_{i,k}^2 + \rho_u} \quad (11)$$

به طور مشابه با حل معادله $\frac{\partial \Phi}{\partial Y} = 0$ ، مقدار به روز شده متغیر $y_{i,k}$ بر اساس رابطه (۱۲) به دست می آید.

$$y_{i,k} = \frac{\sum_{u \in R_k(i)} x_{u,k} \left(r_{u,i} - \sum_{j=1, j \neq k}^f x_{u,j} y_{i,j} \right) + \tau_i q_{k,i} - h_{i,k}}{\sum_{u \in R_k(i)} x_{u,k}^2 + \tau_i} \quad (12)$$

همچنین با اعمال قاعده به روزرسانی تناوبی یعنی حل $\frac{\partial \Phi}{\partial P} = 0$ و $\frac{\partial \Phi}{\partial Q} = 0$ برای متغیرهای P و Q ، مقادیر به روز شده این متغیرها نیز به دست می آیند. از سوی دیگر، مقادیر به روز شده این متغیرها ممکن است مقادیری منفی نیز داشته باشد. برای جلوگیری از منفی شدن عامل های تجزیه، مقادیر آن ها در صورت منفی شدن به عددی مثبت تبدیل می شود. لذا مقادیر به روز شده P و Q به صورت رابطه های (۱۳) و (۱۴) خواهند بود.

$$p_{u,k} = \max \left(0, \frac{A}{B} \right), \quad (13)$$

$$A = \gamma_{u,k} + \rho_u x_{u,k} + \beta_1 \left(\sum_{f \in \mathcal{F}^+(u)} \text{sim}(u, f) p_{f,k} \right) + \beta_2 \left(\sum_{g \in \mathcal{F}^-(u)} \text{sim}(u, g) p_{g,k} \right),$$

$$B = \rho_u + \beta_1 \left(\sum_{f \in \mathcal{F}^+(u)} \text{sim}(u, f) \right) + \beta_2 \left(\sum_{g \in \mathcal{F}^-(u)} \text{sim}(u, g) \right)$$

$$q_{i,k} = \max \left(0, \frac{h_{i,k}}{\tau_i} + y_{i,k} \right) \quad (14)$$

همچنین برای به روزرسانی متغیرهای H و Γ ، با بهره گیری از قاعده اصلی جهت متناوب و روش گرادیان صعودی، مقادیر به روز شده این متغیرها به صورت رابطه های (۱۵) و (۱۶) به دست می آیند.

$$\gamma_{u,k} = \gamma_{u,k} + \eta \rho_u (x_{u,k} - p_{u,k}) \quad (15)$$

$$h_{i,k} = h_{i,k} + \eta \tau_i (y_{i,k} - q_{i,k}) \quad (16)$$

باید توجه داشت که مقادیر به روز شده متغیرهای P و Q وابسته به سایر متغیرهای درگیر در مسئله است و باید ترتیب به روزرسانی هر کدام از متغیرهای دیگر برای به روزرسانی متغیرهای P و Q و همچنین متغیرهای H و Γ مشخص شود. برای این کار ترتیب به روزرسانی متغیرها بر اساس قاعده اصلی جهت متناوب به صورت رابطه (۱۷) خواهد بود.

میانگین رتبه های کاربر a و $\bar{r}(b)$ هم میانگین رتبه های کاربر b است. لذا با استفاده از اطلاعات اعتماد بین کاربران می توان سلیقه کاربر هدف را به سایر دوستان او نزدیک کرد. با این روش بردارهای ویژگی کاربران و آیت م ها با دقت بیشتری مقداردهی خواهند شد و باعث افزایش دقت سیستم می شود.

۳-۴- تشکیل تابع هدف نهایی

تابع هدف نهایی روش ارائه شده با در نظر گرفتن تأثیر اعتماد به صورت رابطه (۱۰) خواهد بود.

$$L(P, Q, X, Y, \Gamma, H) = \frac{1}{2} \|R - XY^T\|_F^2 + \sum_{(u,k)} [\Gamma \circ (X - P)]_{u,k} + \sum_{(u,k)} [H \circ (Y - Q)]_{u,k} + \frac{\rho}{2} \|X - P\|_F^2 + \frac{\tau}{2} \|Y - Q\|_F^2 + \frac{\beta_1}{2} \sum_u \sum_{f \in \mathcal{F}^+(u)} \text{sim}(u, f) \|P_u - P_f\|_F^2 + \frac{\beta_2}{2} \sum_u \sum_{g \in \mathcal{F}^-(u)} \text{sim}(u, g) \|P_u - P_g\|_F^2 \quad (10)$$

که β_1 تأثیر اعتمادکنندگان و β_2 تأثیر اعتماد شونده گان نسبت به کاربر هدف را مشخص می کند که با تغییر این پارامترها می توان تأثیر کاربران اعتمادکنندگان و اعتماد شونده گان نسبت به کاربر هدف را ارزیابی کرد. همان طور که در تابع هدف (۱۰) دیده می شود، برای به دست آوردن مجهول های اصلی یعنی P و Q باید سایر پارامترهای وابسته یعنی (X, Y, Γ, H) را به دست آورد. روش های مختلفی برای بهینه سازی تابع هدف رابطه (۱۰) وجود دارد که در ادامه با روش بهینه سازی جهت متناوب^۸ مسئله مربوطه حل می شود. این روش سرعت همگرایی را افزایش می دهد و باعث افزایش دقت الگوریتم نیز می شود [۲].

۳-۵- بهینه سازی بر اساس روش جهت متناوب

برای حل مسئله ای با تابع هدف (۱۰) با روش بهینه سازی جهت متناوب^۸ باید متغیرها به صورت تناوبی به روزرسانی شوند، یعنی فرایند بهینه سازی روی یک متغیر با ثابت گرفتن سایر متغیرها انجام شود. برای این کار، نخست با ثابت گرفتن دیگر متغیرها نتیجه می شود:

$$\frac{\partial \Phi}{\partial X} = -RY + XY^T Y + \Gamma + \rho(X - P) = - \sum_{i \in R_k(u)} y_{i,k} \left(r_{u,i} - \sum_{j=1, j \neq k}^f x_{u,j} y_{i,j} \right) - \rho_u p_{u,k} + \gamma_{u,k} + x_{u,k} \left(\sum_{i \in R_k(u)} y_{i,k}^2 + \rho_u \right) = 0$$

بهینه این پارامترها برای روش پیشنهادی تنظیم خواهد شد. نتایج عملی روش پیشنهادی در مقایسه با سایر روش‌های توصیه‌گر مورد مقایسه و بررسی قرار می‌گیرد. برای ارزیابی دقیق و مقایسه روش پیشنهادی با سایر روش‌ها از کتابخانه قدرتمند لیبرک^۱ استفاده شده است، زیرا اغلب روش‌های مقایسه‌شده در این کتابخانه به صورت دقیق پیاده‌سازی شده‌اند. همچنین این کتابخانه معیارهای ارزیابی مختلف را در اختیار ما قرار می‌دهد تا روش‌های مختلف براساس آن معیارها ارزیابی شوند. کلیه روش‌های پیشنهادی با زبان جاوا پیاده‌سازی شده‌اند. برای انجام آزمایش‌ها از سیستمی با پردازنده از نوع Core i5 و حافظه شش گیگابایتی استفاده شده است.

جدول ۱: شبه کد روش پیشنهادی

Algorithm 1. Pseudo code of proposed method	
Inputs: R, U, I, f, T	
Outputs: nonnegative features P, Q build on R	
Begin	
1:	Initialize X, Y, P, Q, Γ, K
2:	Initialize p, τ
3:	Initialize η, λ, β
4:	Initialize $t = 0, n = \max_iteration_round$
5:	While $t \leq n$ do
6:	For each user u in U
7:	For $k = 1$ to f
8:	Compute ρ_u According to $\rho_u = \lambda \Omega_u $
9:	Compute $x_{u,k}$ According to (12)
10:	Compute $\gamma_{u,k}$ According to (16)
11:	Compute $p_{u,k}$ According to (14)
12:	End for
13:	End for
14:	For each item i in I
15:	For $k=1$ to f
16:	Compute $y_{i,k}$ According to (13)
17:	Compute $q_{i,k}$ According to (15)
18:	Compute τ_i According to $\tau_i = \lambda \Omega_i $
19:	Compute $h_{i,k}$ According to (17)
20:	End for
21:	End for
22:	$t = t + 1$;
23:	End while
End	

۴-۱- مجموعه‌های داده‌ای

در این مقاله آزمایش‌های تجربی روی سه مجموعه داده‌ای مشهور و معتبر انجام شده است. این مجموعه‌های داده‌ای به دلیل ویژگی‌های مناسبی که دارند در اغلب کارهای تحقیقاتی استفاده می‌شوند و جزء داده‌های دنیای واقعی هستند و ارزیابی الگوریتم روی آن‌ها عملکرد روش را در کاربردهای دنیای واقعی بهتر نشان می‌دهد. همچنین این مجموعه‌های داده‌ای حاوی اطلاعات اعتماد و رتبه هستند و لذا برای ارزیابی روش پیشنهادی مناسب هستند. مشخصات آماری این مجموعه‌های داده‌ای در جدول ۲ قرار دارد. در این جدول تعداد رتبه‌ها، اطلاعات اعتماد و سایر موارد مهم در مورد این داده‌ها آمده است. مجموعه‌های داده استفاده شده همراه مشخصات آماری مربوط به آن‌ها در <https://www.librec.net/datasets.html> موجود است.

$$\begin{aligned} P^{t+1} &= \operatorname{argmin}_P \Phi(P, Q^t, X^{t+1}, Y^{t+1}, \Gamma^t, H^t) \\ Q^{t+1} &= \operatorname{argmin}_Q \Phi(P^t, Q, X^{t+1}, Y^{t+1}, \Gamma^t, H^t) \\ \Gamma^{t+1} &= \Gamma^t + \eta \nabla_{\Gamma} \Phi(P^{t+1}, Q^{t+1}, X^{t+1}, Y^{t+1}, \Gamma, H^t) \\ H^{t+1} &= H^t + \eta \nabla_H \Phi(P^{t+1}, Q^{t+1}, X^{t+1}, Y^{t+1}, \Gamma^t, H), \end{aligned} \quad (17)$$

که منظور از t مقدار قدیم متغیر مربوطه در زمان t و $t+1$ مقدار جدید متغیر مربوطه در زمان $t+1$ می‌باشد.

۳-۶- طراحی الگوریتم

همان‌طور که گفته شد برای به‌دست آوردن مقادیر پارامترهای اصلی یعنی P و Q باید مقادیر به‌روزرشده سایر پارامترها نیز معلوم باشد. همچنین ترتیب به‌روزرسانی متغیرها باید بر اساس رابطه (۱۷) در نظر گرفته شود. جدول ۱ شبه‌کد روش پیشنهادی را نشان می‌دهد. ورودی‌های الگوریتم شامل ماتریس رتبه R ، ماتریس اعتماد T ، مجموعه کاربران U ، مجموعه آیتم‌ها I ، پارامترهای الگوریتم η, λ و β ، پارامتر تعداد زمان اجرا یعنی t و تعداد فاکتورهای نهان یعنی f است. در خطوط ۱-۴ مقادیر اولیه تصادفی به ماتریس‌ها و متغیرهای مربوطه داده می‌شود. بهتر است مقادیر اولیه در بازه $[0, 1]$ باشد تا الگوریتم سریع‌تر به جواب برسد. پس از آن در خطوط ۵-۲۱ فرایند آموزش مدل بر اساس الگوریتم پیشنهادی انجام می‌شود و متغیرهای مربوطه با مقادیر جدید در هر تکرار به‌روز می‌شوند. سرانجام این مراحل ادامه می‌یابد تا تعداد تکرارها تمام شود یا اینکه خطای مطلق از یک مقدار آستانه کمتر شود. در این الگوریتم، متغیرهای مربوط به کاربران در داخل حلقه مربوطه محاسبه می‌شوند (خطوط ۹-۱۱) و متغیرهای مربوط به آیتم‌ها داخل حلقه مربوطه به‌روزرسانی می‌شوند (خطوط ۱۶-۱۹). لذا در هر تکرار، ماتریس‌های نهان اصلی یعنی P و Q ، با مقادیر وابسته به سایر متغیرها، به‌روزرسانی می‌شوند. پس از پایان الگوریتم، این دو ماتریس به‌عنوان خروجی برگشت داده می‌شوند که می‌توان از حاصل ضرب آن‌ها، ماتریس رتبه تخمینی را به‌دست آورد.

بخش اول الگوریتم که شامل مقاردهای اولیه می‌باشد می‌تواند به‌صورت جداگانه و یا در طول الگوریتم انجام گیرد. از سوی دیگر، $\max(|U|, |I|) \gg |R_K|$. بنابراین کل پیچیدگی زمانی روش پیشنهادی $O(t \times f \times |R_K|)$ خواهد بود. پیچیدگی زمانی نسبت به تعداد کاربران به‌صورت خطی می‌باشد و قادر است برای داده‌های با مقیاس بالا در زمان مناسبی نتایج مطلوب را تولید کند.

۴- آزمایش‌های تجربی

در این بخش بر اساس معیارهای ارزیابی مختلف عملکرد روش پیشنهادی با سایر روش‌های جدید در این حوزه مقایسه می‌شود. نخست مجموعه‌های داده‌ای و مشخصات آماری آن‌ها معرفی می‌شود، سپس معیارهای ارزیابی پرکاربرد در پیش‌بینی رتبه کاربر هدف ارائه می‌شود. تنظیم پارامترهای روش پیشنهادی انجام می‌شود و مقادیر

روش های TrustSVD و SocialMF به دلیل مدل خوبی که از داده ها همراه اطلاعات شبکه اجتماعی می سازند عملکرد بهتری نسبت به سایر روش ها دارند. با وجود این، روش پیشنهادی عملکرد بهتری نسبت به این دو روش دارد و نتایج بهتری را تولید کند.

۴-۴- نتایج روی کاربران شروع سرد

در این بخش عملکرد روش های مختلف روی دو مجموعه داده در مواجهه با کاربرانی که شروع سرد دارند در جدول ۴ آمده است. هرچند روش های اعتماد محور در مقابله با شروع سرد مقاوم هستند، اما روش پیشنهادی در اغلب موارد خطای پیش بینی کمتری نسبت به سایر روش ها دارد. در واقع، روش پیشنهادی تأثیر اعتماد کنندگان و اعتماد شونده گان را در پیش بینی رتبه در نظر می گیرد، در حالی که در روش های دیگر به این امر کمتر توجه می شود. روش TrustSVD به دلیل برخورداری از این ویژگی نسبت به روش های دیگر عملکرد بهتری دارد، هرچند عملکرد آن در اغلب موارد از روش پیشنهادی ضعیف تر است. همچنین، روش های مبتنی بر رتبه از جمله ANLF از اطلاعات کناری استفاده نمی کنند، لذا عملکرد نامنا سبی در برخورد با شروع سرد دارند.

جدول ۴: نتایج عملی روی کاربران شروع سرد

روش ها	معیار	FilmTrust	Epinions
TrustSVD[32]	MAE	۰/۶۵	۰/۸۷
	RMSE	۰/۸۴	۱/۱۲
TrustMF[3]	MAE	۰/۶۱	۰/۹۳
	RMSE	۰/۸۸	۱/۲۷
SocREC[31]	MAE	۰/۷۵	۰/۹۱
	RMSE	۰/۹۳	۱/۳۱
RSTE[6]	MAE	۰/۶۱	۰/۹۳
	RMSE	۰/۷۷	۱/۲۶
SocialMF[19]	MAE	۰/۵۸	۰/۹۱
	RMSE	۰/۸۱	۱/۳۱
ANLF[2]	MAE	۰/۷۸	۰/۹۵
	RMSE	۰/۹۸	۱/۱۷
Proposed Method	MAE	۰/۶۰	۰/۸۴
	RMSE	۰/۷۸	۱/۰۹

۴-۵- حساسیت پارامترها

روش پیشنهادی دارای سه پارامتر اصلی λ ، β و η است که عملکرد آن برای تولید نتیجه مطلوب وابسته به تعیین مقادیر مناسب برای این پارامترها است. پارامتر λ یک پارامتر تقویتی برای تعیین تأثیر رتبه های هر کاربر است، پارامتر β درجه اعتماد در مدل را مشخص می کند و پارامتر η نرخ یادگیری یا طول گام های مدل برای بهینه سازی تابع خطا است. نتایج حاصل از تغییر این پارامترها روی دو مجموعه داده در شکل های ۳ تا ۶ نشان داده شده است. استراتژی تعیین پارامترها به این صورت است که ابتدا مقادیر یکی از پارامترها را تغییر داده و مقادیر

جدول ۲: مشخصات مجموعه های داده های استفاده شده

Datasets	user	items	ratings	trusters	trustees
Epinions	۴۰۱۶۳	۱۳۹۷۳۸	۶۶۴۸۲۴	۳۳۹۶۰	۴۹۲۸۸
FilmTrust	۱۵۰۸	۲۰۷۱	۳۵۴۹۷	۶۰۹	۷۳۲

۴-۲- معیارهای ارزیابی

دقت پیش بینی، اصلی ترین کانون تمرکز در متون علمی مرتبط با سیستم های توصیه گر است [۵، ۱۸، ۱۹، ۳۱]. لذا دو معیار شناخته شده برای ارزیابی دقت پیش بینی استفاده می شود که عبارتند از میانگین خطای مطلق MAE و مجذور مربع خطا $RMSE$:

$$RMSE = \sqrt{\frac{1}{Z} \sum_{(u,j)} (\hat{r}_{u,j} - r_{u,j})^2} \quad (18)$$

$$MAE = \frac{1}{Z} \sum_{(u,j)} |\hat{r}_{u,j} - r_{u,j}| \quad (19)$$


که در آن $r_{u,j}$ رتبه پیش بینی شده، $r_{u,j}$ هم رتبه واقعی و Z تعداد رتبه هایی است که کاربر u به آیتم j داده است. مقادیر کمتر این معیارها به معنای عملکرد بهتر روش متناظر است.

۴-۳- نتایج عملی روی همه کاربران


در این بخش روش پیشنهادی بر اساس معیارهای ارزیابی خطای روی دو مجموعه داده ای پر کاربرد مورد ارزیابی و مقایسه قرار می گیرد. نتایج حاصل در جدول ۳ نمایش داده شده است. نتایج هر کدام از روش ها بر اساس تعداد فاکتورهای نهان با مقدار ۱۰ است. از نتایج این جدول مشخص است که روش پیشنهادی در اغلب موارد عملکرد بهتری نسبت به سایر روش ها دارد. روش ANLF فقط از اطلاعات رتبه برای پیش بینی سلیقه کاربر هدف استفاده می کند و چون از اطلاعات کمکی برای افزایش دقت الگوریتم استفاده نمی کند، دقت آن نسبت به سایر روش ها پایین است.

جدول ۳: نتایج عملی روی همه کاربران

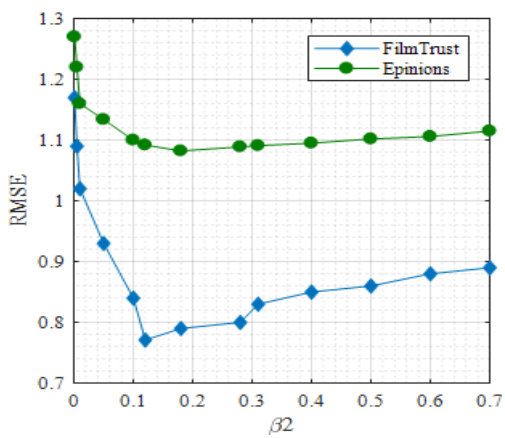
روش ها	معیار	FilmTrust	Epinions
TrustSVD[32]	MAE	۰/۶۰	۰/۸۱
	RMSE	۰/۷۸	۱/۰۹
TrustMF[3]	MAE	۰/۷۲	۰/۸۷
	RMSE	۰/۹۱	۱/۱۸
SocREC[31]	MAE	۰/۷۱	۰/۸۶
	RMSE	۰/۹۱	۱/۱۰
RSTE[6]	MAE	۰/۶۸	۰/۸۸
	RMSE	۰/۸۵	۱/۱۱
SocialMF[19]	MAE	۰/۶۹	۰/۸۷
	RMSE	۰/۸۵	۱/۰۹
ANLF[2]	MAE	۰/۷۱	۰/۹۱
	RMSE	۰/۹۰	۱/۲۵
Proposed Method	MAE	۰/۵۸	۰/۷۸
	RMSE	۰/۷۷	۱/۰۸



شکل ۴: تأثیر پارامتر η



شکل ۵: تأثیر پارامتر β_1




شکل ۶: تأثیر پارامتر β_2

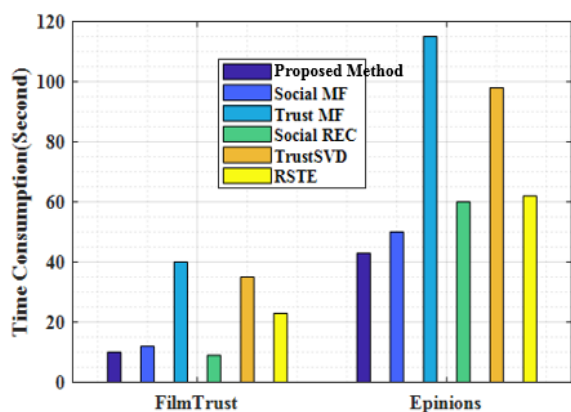
۴-۶- تحلیل همگرایی

در این بخش همگرایی روش پیشنهادی در مقابل سایر روش‌ها بررسی می‌شود. نتایج حاصل در شکل ۷ نشان داده شده است. در روش پیشنهادی به دلیل استفاده از راه‌کار جهت متناوب برای بهینه‌سازی تابع هدف، همگرایی سریع خواهد بود. لذا همان‌طور که در شکل ۷ مشخص است، روش پیشنهادی در حدود ۳۵ تکرار به جواب مطلوب همگرا می‌شود، در حالی که روش‌های دیگر در بیشتر از ۱۰۰ تکرار به جواب مطلوب خودشان می‌رسند. چون سایر روش‌ها در مورد همگرایی مدل، هیچ‌گونه استراتژی خاصی را مدنظر قرار نداده‌اند و به این موضوع بی‌توجه بوده‌اند، لذا همگرایی آن‌ها در زمان بیشتری رخ می‌دهد. برای

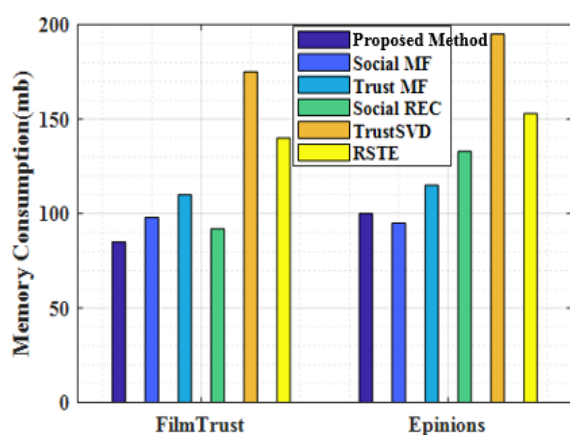
سایر پارامترها ثابت در نظر گرفته می‌شود. روش پیشنهادی نیز شامل سه پارامتر است که در هر مرحله با ثابت گرفتن مقادیر دو پارامتر، مقادیر پارامتر سوم به صورت متغیر در بازه‌ای مشخص برای ۱۰۰۰ تکرار چنان تغییر داده می‌شود که برای مقدار مربوطه کمترین خطا به دست آید. همان‌طور که از شکل ۳ مشخص است پارامتر λ از مقدار ۰/۰۱ تا ۲/۵ تغییر می‌کند و با افزایش این پارامتر روی هر دو مجموعه داده، خطا کاهش پیدا می‌کند. اما پس از مدتی با افزایش بیش از حد این پارامتر خطای مدل صعودی می‌شود. لذا اگر مقدار λ برابر ۱/۵۶ باشد، در هر دو مجموعه داده تقریباً نتیجه مطلوب را تولید می‌کند. شکل ۴ تأثیر پارامتر η را نشان می‌دهد و با افزایش این پارامتر در بازه مربوطه خطای مدل تا یک نقطه مشخص روی هر دو داده کم می‌شود. بنابراین اگر مقدار پارامتر η را در محدوده ۱/۹۵ تا ۲/۰۱ قرار دهیم تقریباً نتیجه مطلوب به دست خواهد آمد. در روش پیشنهادی تأثیر اعتماد بر اساس پارامتر β مشخص می‌شود. اگر بخواهیم تأثیر اعتماد به تفکیک تأثیر هر کدام از کاربران (اعتماد‌کنندگان و اعتماد شونده‌گان) روی عملکرد روش پیشنهادی مشخص شود، باید در رابطه (۱۰) که تابع هدف روش پیشنهادی را نشان می‌دهد پارامترهای β_1 و β_2 برای دو جمله آخر طوری تعریف شوند که β_1 تأثیر اعتماد‌کنندگان و β_2 تأثیر اعتماد شونده‌گان را مشخص کند. لذا با تغییر این پارامترها می‌توان تأثیر کاربران اعتماد کننده و اعتماد شونده نسبت به کاربر هدف را ارزیابی کرد. برای پارامتر β_1 ، همان‌طور که از شکل ۵ مشخص است، افزایش این پارامتر هم باعث کاهش خطا می‌شود، اما چون افزایش بیشتر این پارامتر به معنی کاهش تأثیر اطلاعات رتبه و افزایش تأثیر اطلاعات اعتماد است، لذا از یک نقطه مشخص به بعد، خطا افزایش می‌یابد. لذا، مقادیر ۰/۲۸ و ۰/۳۱ از پارامتر β_1 به ترتیب برای داده‌های FilmTrust و Epinions مقادیر مطلوبی هستند. همچنین برای پارامتر β_2 در شکل ۶، افزایش این پارامتر هم تا محدوده مشخصی باعث کاهش خطا می‌شود و در کل مقادیر ۰/۱۲ و ۰/۱۸ از پارامتر β_2 به ترتیب برای داده‌های FilmTrust و Epinions مقادیر مطلوبی هستند. همان‌طور که مشاهده می‌شود مقدار β_1 در هر دو مجموعه داده همیشه بیشتر از β_2 است و این نشان می‌دهد که نرخ اعتماد کاربر هدف به کاربران دیگر اهمیت بیشتری در تعیین سلیقه کاربر هدف دارد.



شکل ۳: تأثیر پارامتر λ

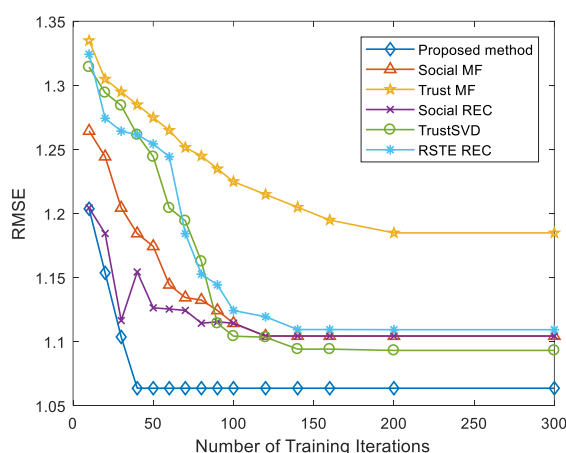


شکل ۸: زمان اجرای روش‌های مقایسه شده



شکل ۹: حافظه اشغال شده توسط روش‌های مختلف

مثال TrustMF در حدود ۳۰۰ تکرار لازم دارد تا به خطا کمینه برسد. در واقع، همگرایی الگوریتم تأثیر زیادی در مقیاس‌پذیری روش پیشنهادی دارد و اگر روی داده‌های بزرگ همگرایی سریع‌تر صورت گیرد، مدل مقیاس‌پذیری خوبی را خواهد داشت. همان‌طور که در مقاله مربوط به روش بهینه‌سازی جهت متناوب بحث شده است [۳۳]، یکی از مزایای اصلی این روش افزایش سرعت همگرایی است، چون به صورت تناوبی متغیرها را به‌روزرسانی می‌کند و با توجه به این‌که ماتریس‌های کمکی را با ضرایب مشخص به تابع هدف اضافه می‌کند، لذا در هر تکرار با دانش بیشتری در جهت کاهش خطا حرکت می‌کند، لذا سرعت و دقت این روش بهینه‌سازی بالا است و دلیل همگرایی سریع روش پیشنهادی ناشی از بهینه‌سازی تابع هدف آن با روش جهت متناوب است.



شکل ۷: همگرایی روش‌های مختلف

۴-۸- مقیاس‌پذیری

یکی از بارزترین ویژگی مهم که یک الگوریتم توصیه باید داشته باشد، کارایی آن در مقابله با رشد داده است. در واقع باید روش بتواند با افزایش کاربران و آیتم‌ها در سیستم در زمان مناسبی عملیات پیش‌بینی را انجام دهد و بتواند مقیاس‌پذیری مناسبی را داشته باشد. همان‌طور که در شکل ۱۰ نشان داده شده است، روش پیشنهادی با درصد‌های مختلفی در بازه ۰/۱ تا ۱ با طول گام ۰/۱ آموزش داده شده است و زمان اجرای روش پیشنهادی برای هر حالت مشخص شده است. نتایج نشان می‌دهد که روش پیشنهادی در هر سه مجموعه داده با افزایش اندازه داده زمان اجرای آن به صورت خطی رشد می‌کند و روش پیشنهادی دارای مقیاس‌پذیری مطلوب است. این مقیاس‌پذیری ناشی از روش بهینه‌سازی جهت متناوب است که به صورت تناوبی متغیرها را به‌روز می‌کند، لذا سرعت همگرایی الگوریتم را افزایش می‌دهد. همچنین، اطلاعات اعتماد در شبکه‌های اجتماعی به‌صورتی به تابع هدف اضافه شده است که کمترین پیچیدگی را برای الگوریتم ایجاد می‌کند. لذا روش پیشنهادی به دلیل مقیاس‌پذیری می‌تواند برای کاربردهای دنیای واقعی روی داده‌های بزرگ استفاده شود.

۴-۷- حافظه و زمان اجرا


روش‌های مختلف بر اساس حافظه و زمان اجرا در ۱۰۰ تکرار متوالی، مورد مقایسه قرار گرفته‌اند و نتایج حاصل در شکل‌های ۸ و ۹ نشان داده شده است. همان‌طور که از شکل ۸ مشخص است، روش پیشنهادی روی دو مجموعه داده در اغلب موارد زمان کمتری را برای رسیدن به نتیجه واقعی خود نیاز دارد. روش TrustMF روی مجموعه داده Epinions که یک مجموعه داده بزرگ است، از همه روش‌ها زمان اجرای بیشتری دارد، پس از آن، TrustSVD زمان اجرای بیشتری را در هر دو داده نیاز دارد. پیچیدگی زمانی کم در روش پیشنهادی به دلیل استفاده از راه‌کار جهت متناوب و ایجاد یک الگوریتم بهینه است. این الگوریتم به ساختمان داده خاصی نیاز ندارد و به صورت ساده و سریع اجرا می‌شود. در شکل ۹، روش‌های مختلف بر اساس حافظه اشغال شده در ۱۰۰ تکرار ارزیابی شده‌اند. نتایج نشان می‌دهد که در اغلب موارد روش پیشنهادی حافظه کمتری را نسبت به سایر روش‌ها لازم دارد. در واقع، روش پیشنهادی در طول فرایند آموزش مدل به دلیل اینکه از هیچ ساختمان داده یا آرایه کمکی استفاده نمی‌کند، حافظه کمتری را اشغال می‌کند.

۵- نتیجه گیری

در این مقاله، یک روش تجزیه نامنفی ماتریسی برای افزایش کارایی سیستم‌های توصیه‌گر پالایش گروهی ارائه شد. در این روش از اطلاعات شبکه‌های اجتماعی افراد برای مقابله با مشکل پراکندگی داده و شروع سرد استفاده می‌شود. در واقع، چون تجزیه ماتریس رتبه‌ها بر اساس اطلاعات رتبه نمی‌توانست مدل مناسبی را ایجاد کند از اطلاعات اعتماد بین کاربران در شبکه‌های اجتماعی برای کمک به تجزیه درست و دقیق‌تر ماتریس رتبه استفاده می‌شود. همچنین، برای افزایش کارایی الگوریتم از راه‌کار بهینه‌سازی جهت متناوب استفاده شد تا مدل پیشنهادی بتواند در مقابل داده‌های بزرگ به خوبی عمل کند. در واقع، استفاده از راه‌کار بهینه‌سازی جهت متناوب روش پیشنهادی را قادر می‌سازد که در زمان کمتری به نتیجه مطلوب همگرا شود. همچنین، روش پیشنهادی به دلیل استفاده از اطلاعات اعتماد بین کاربران به عنوان اطلاعات کناری در مقابل شروع سرد و پراکندگی داده مقاوم بوده و خطای پیش‌بینی کمتری را نسبت به سایر روش‌ها دارد. به علاوه، چون روش پیشنهادی به هیچ‌گونه ساختمان داده و با آرایه‌های کمکی نیاز ندارد، لذا پیاده‌سازی آن آسان و زمان اجرا و حافظه کمتری را دارد. نتایج آزمایش‌های تجربی روی دو مجموعه داده بزرگ نشان می‌دهد که روش پیشنهادی در اغلب مواقع عملکرد بهتری را نسبت به سایر روش‌ها دارد. با وجود مزیت‌های روش پیشنهادی، برای کاربر تازه‌ایی که وارد سیستم می‌شود مدل بایستی از اول به‌روز شود و این چالش مشترک در اغلب تحقیقات در این زمینه است. بنابراین برای کاهش بار محاسباتی در مواجهه با داده‌های جدید بهتر است از الگوریتم‌های پردازش موازی استفاده کرد تا بتوان مدل افزایشی مناسبی برای داده‌های جریان‌دار ارائه داد. تحقیقات آتی ما در راستای برطرف‌نمودن این چالش خواهد بود.

مراجع

- [1] T. D. T. Do and L. Cao, "Coupled Poisson factorization integrated with user/item metadata for modeling popular and sparse ratings in scalable recommendation," *Thirty-Second AAAI Conference on Artificial Intelligence (AAAI-18)*, pp. 1-7, 2018.
- [2] X. Luo, M. Zhou, S. Li, Z. You, Y. Xia and Q. Zhu, "A nonnegative latent factor model for large-scale sparse matrices in recommender systems via alternating direction method," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 27, pp. 579-592, 2016.
- [3] B. Yang, Y. Lei, J. Liu and W. Li, "Social collaborative filtering by trust," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, pp. 1633-1647, 2017.
- [4] X. Luo, M. Zhou, Y. Xia and Q. Zhu, "An efficient non-negative matrix-factorization-based approach to collaborative filtering for recommender systems," *IEEE Transactions on Industrial Informatics*, vol. 10, pp. 1273-1284, 2014.
- [5] A. Hernando, J. Bobadilla and F. Ortega, "A non negative matrix factorization for collaborative filtering recommender systems based on a Bayesian probabilistic



شکل ۱۰: مقیاس‌پذیری روش پیشنهادی روی مجموعه‌های داده‌ای

۹-۴- آزمون آماری

برای ارزیابی دقیق‌تر دقت روش پیشنهادی نسبت به سایر روش‌ها از آزمون آماری تی‌تست^{۱۲} بر اساس معیار MAE استفاده شده است تا مشخص شود که آیا از لحاظ آماری دقت روش پیشنهادی نسبت به سایر روش‌ها در سطح معنی‌داری ۰/۰۵ تفاوت معنی‌داری دارد یا خیر؟ نتایج حاصل از آزمون آماری در جدول ۵ نشان داده شده است. نتایج نشان می‌دهد در اکثر موارد مقدار p روش‌های دیگر در مقایسه با روش پیشنهادی کمتر از سطح معنی‌داری می‌باشد و این نشان‌دهنده این است که فرض صفر رد می‌شود و فرض یک قابل‌قبول است. بنابراین، خطای روش پیشنهادی نسبت به سایر روش‌ها به صورت معناداری کمتر است. همچنین، روش پیشنهادی در اکثر موارد میانگین واریانس کمتری نسبت به بقیه روش‌ها دارد و ثبات نتایج آن برای هر سه مجموعه داده بیشتر است.

جدول ۵: آزمون آماری روی مجموعه‌های داده‌ای

Methods	-	FilmTrust	Epinions
Proposed method	Mean	۰/۵۹۱۲	۰/۷۸۴۴۴۴۴۴
	Variance	۰/۰۰۰۲۸۵۵۱۱	۰/۰۰۰۱۲۱۰۲۸
	p-value	-	-
SoRec	Mean	۰/۷۲۱۹۴۶۶۶	۰/۸۱۹۶۶۶۶۶
	Variance	۰/۰۰۰۳۰۷۴۳۳	۰/۰۰۰۱۹
	p-value	۵/۴۴E-۱۰	۲/۰۵E-۰۷
RSTE	Mean	۰/۶۹۴۶۲۱	۰/۸۸۸۷۷۷۷۷
	Variance	۰/۰۰۰۷۲۱۲۱	۰/۰۰۰۱۶۴۱۹۴
	p-value	۲/۰۵۶E-۰۶	۱/۵۸E-۰۹
SocialMF	Mean	۰/۷۰۳۳۱۳۳۱	۰/۸۷۵۶۶۶۶۶
	Variance	۰/۰۰۰۲۹۱۷۸۸۸	۰/۰۰۰۱۶۹۷۵
	p-value	۴/۰۰۱E-۰۸	۹/۲۳E-۰۸
TrustMF	Mean	۰/۷۲۴۲۴۸۷۹	۰/۷۸۱۳۳۳۳۳
	Variance	۰/۰۰۰۱۷۹۵۱۱	۰/۰۰۰۲۸۳۷۵
	p-value	۱/۲۰E-۰۸	۵/۳۰E-۰۶
TrustSVD	Mean	۰/۶۱۱۴۶۵۴۶	۰/۸۱۰۶۶۶۶۶
	Variance	۰/۰۰۰۳۷۸۰	۰/۰۰۰۳۶
	p-value	۰/۰۲۳۰۰۸۲۸	۰/۰۰۷۱۱۹۲۷۷
ANLF	Mean	۰/۷۲۰۲۶۵۴۶	۰/۹۰۸۸۸۸۸۹
	Variance	۰/۰۰۰۳۶۵۰۶۶	۰/۰۰۰۳۶۱۱۱
	p-value	۳/۳۸E-۰۸	۹/۲۹E-۰۸

- networks,” *Proceedings of the Fourth ACM Conference on Recommender Systems*, Barcelona, Spain, 2010.
- [۲۰] اکرم ناظمی سجزی و مرجان کائدی، «اصلاح نویز طبیعی در سیستم‌های توصیه‌گر مشارکتی با در نظر گرفتن تغییر ترجیحات کاربر»، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۸، صفحه ۳۴۵-۳۵۶، ۱۳۹۷.
- [21] X. Luo, M. Zhou, H. Leung, Y. Xia, Q. Zhu, Z. You, et al., “An incremental-and-static-combined scheme for matrix-factorization-based collaborative filtering,” *IEEE Transactions on Automation Science and Engineering*, vol. 13, pp. 333-343, 2016.
- [22] A. Popescul, D. M. Pennock and S. Lawrence, “Probabilistic models for unified collaborative and content-based recommendation in sparse-data environments,” in *Proceedings of the Seventeenth Conference on Uncertainty in Artificial Intelligence*, pp. 437-444, 2001.
- [23] M. J. Pazzani and D. Billsus, “Content-based recommendation systems,” in *The Adaptive Web: Methods and Strategies of Web Personalization*, P. Brusilovsky, A. Kobsa, and W. Nejdl, Eds., ed Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 325-341, 2007.
- [24] I. Cantador, A. Bellogín and D. Vallet, “Content-based recommendation in social tagging systems,” in *Proceedings of the fourth ACM Conference on Recommender Systems*, pp. 237-240, 2010.
- [25] L. Yao, Q. Z. Sheng, A. H. H. Ngu, J. Yu and A. Segev, “Unified collaborative and content-based web service recommendation,” *IEEE Transactions on Services Computing*, vol. 8, pp. 453-466, 2015.
- [26] J. Wang, A. P. De Vries and M. J. Reinders, “Unifying user-based and item-based collaborative filtering approaches by similarity fusion,” in *Proceedings of the 29th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 501-508, 2006.
- [27] Y. Shi, M. Larson and A. Hanjalic, “List-wise learning to rank with matrix factorization for collaborative filtering,” *Proceedings of the Fourth ACM Conference on Recommender Systems*, Barcelona, Spain, 2010.
- [28] M. Gao, Z. Wu and F. Jiang, “Userank for item-based collaborative filtering recommendation,” *Information Processing Letters*, vol. 111, pp. 440-446, 2011.
- [29] A. Hawalah and M. Fasli, “Utilizing contextual ontological user profiles for personalized recommendations,” *Expert Systems with Applications*, vol. 41, pp. 4777-4797, 2014.
- [30] H. Parvin, P. Moradi, S. Esmaili and M. Jalili, “An efficient recommender system by integrating non-negative matrix factorization with trust and distrust relationships,” in *2018 IEEE Data Science Workshop (DSW)*, pp. 135-139, 2018.
- [31] H. Ma, H. Yang, M. R. Lyu and I. King, “Sorec: social recommendation using probabilistic matrix factorization,” in *Proceedings of the 17th ACM Conference on Information and Knowledge Management*, pp. 931-940, 2008.
- [32] 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, pp. 1607-1620, 2016.
- [33] S. Boyd, “Alternating direction method of multipliers,” in *Talk at NIPS Workshop on Optimization and Machine Learning*, 2011.
- model,” *Knowledge-Based Systems*, vol. 97, pp. 188-202, 2016.
- [6] H. Ma, I. King and M. R. Lyu, “Learning to recommend with social trust ensemble,” in *Proceedings of the 32nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 203-210, 2009.
- [7] D. Z. Navgaran, P. Moradi and F. Akhlaghian, “Evolutionary based matrix factorization method for collaborative filtering systems,” in *Electrical Engineering (ICEE), 2013 21st Iranian Conference on*, pp. 1-5, 2013.
- [8] H. Parvin, P. Moradi and S. Esmaili, “Nonnegative matrix factorization regularized with trust relationships for solving cold-start problem in recommender Systems,” in *Electrical Engineering (ICEE), Iranian Conference on*, pp. 1571-1576, 2018.
- [9] M. Ranjbar, P. Moradi, M. Azami and M. Jalili, “An imputation-based matrix factorization method for improving accuracy of collaborative filtering systems,” *Engineering Applications of Artificial Intelligence*, vol. 46, pp. 58-66, 2015.
- [10] P. Pirasteh, D. Hwang and J. J. Jung, “Exploiting matrix factorization to asymmetric user similarities in recommendation systems,” *Knowledge-Based Systems*, vol. 83, pp. 51-57, 2015.
- [۱۱] فریاد طهماسبی، مجید مقدادی و سجاد احمدیان، «ارائه یک روش ترکیبی جدید بر اساس تکنیک گسترش پروفایل برای حل مسئله شروع سرد در سیستم‌های توصیه‌گر»، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۸، صفحه ۱۵۱-۱۵۹، ۱۳۹۷.
- [12] J. Bobadilla, F. Ortega, A. Hernando and J. Bernal, “A collaborative filtering approach to mitigate the new user cold start problem,” *Knowledge-Based Systems*, vol. 26, pp. 225-238, 2012.
- [13] K. H. Tso-Sutter, L. B. Marinho and L. Schmidt-Thieme, “Tag-aware recommender systems by fusion of collaborative filtering algorithms,” in *Proceedings of the 2008 ACM Symposium on Applied Computing*, pp. 1995-1999, 2008.
- [14] H. Parvin, P. Moradi and S. Esmaili, “A collaborative filtering method based on genetic algorithm and trust statements,” in *Fuzzy and Intelligent Systems (CFIS), 2018 6th Iranian Joint Congress on*, pp. 13-16, 2018.
- [15] J. Bobadilla, R. Bojorque, A. H. Esteban and R. Hurtado, “Recommender Systems Clustering Using Bayesian Non Negative Matrix Factorization,” *IEEE Access*, vol. 6, pp. 3549-3564, 2018.
- [16] B. Sarwar, G. Karypis, J. Konstan and J. Riedl, “Item-based collaborative filtering recommendation algorithms,” in *Proceedings of the 10th International Conference on World Wide Web*, pp. 285-295, 2001.
- [17] G. Guo, J. Zhang and N. Yorke-Smith, “Leveraging multiviews of trust and similarity to enhance clustering-based recommender systems,” *Knowledge-Based Systems*, vol. 74, pp. 14-27, 2015.
- [18] G. Guo, J. Zhang and N. Yorke-Smith, “TrustSVD: Collaborative filtering with both the explicit and implicit influence of user trust and of item ratings,” in *Twenty-Ninth AAAI Conference on Artificial Intelligence (AAAI-15)*, pp. 123-125, 2015.
- [19] M. Jamali and M. Ester, “A matrix factorization technique with trust propagation for recommendation in social

زیر نویس ها

⁷ Pearson

⁸ Alternating Direction method

⁹ Librec

¹⁰ MAE

¹¹ RMSE

¹² T-test

¹ Matrix Factorization

² Cold-Start

³ Bayes

⁴ Lagranj

⁵ Trustees

⁶ Trusters