

تاریخ دریافت: ۹۷/۰۲/۱۱

تاریخ پذیرش: ۹۷/۰۷/۰۶

## ارائه یک سیستم توصیه گر اثربخش با به کارگیری روابط اعتماد محلی و سراسری آگاه از زمینه

فائزه سادات گوهری

دانشجوی دکتری، دانشکده مهندسی و علوم کامپیوتر، دانشگاه شهید بهشتی، تهران، ایران  
پست الکترونیکی: f\_gohari@sbu.ac.ir

فریدون شمس علیئی\*

دانشیار، دانشکده مهندسی و علوم کامپیوتر، دانشگاه شهید بهشتی، تهران، ایران  
پست الکترونیکی: f\_shams@sbu.ac.ir

حسن حقیقی

دانشیار، دانشکده مهندسی و علوم کامپیوتر، دانشگاه شهید بهشتی، تهران، ایران  
پست الکترونیکی: h\_haghighi@sbu.ac.ir

### چکیده:

مدل سازی نمود. زمانی که ماتریس امتیازات بسیار تنک باشد، مدل محلی اثربخشی لازم را نخواهد داشت و منجر به کاهش کیفیت پیشنهادها می گردد. در چنین شرایطی، می توان با بهره گیری از یک مدل سراسری، سطح اعتماد به یک کاربر را بر اساس شهرت وی در کل جامعه تعیین نمود. در این مقاله، یک رویکرد جدید پیشنهاد می شود که از هر دو منبع اعتماد محلی و سراسری به صورت وابسته به زمینه بهره می گیرد و بر اساس سطح تنکی داده ها، آن ها را وزندهی و ترکیب می نماید. نتایج آزمایش ها بر روی مجموعه داده MovieLens 1M نشان می دهد که میانگین خطای مطلق رویکرد پیشنهادی در مقایسه با رویکردهای CATRA، HUIT و TSF، به طور متوسط به ترتیب ۲/۵٪، ۵/۶٪ و ۶/۸٪ کمتر است. همچنین در مواجهه با مشکل تنکی داده ها، خطای رویکرد پیشنهادی به طور متوسط بین ۴٪ تا ۸٪ پایین تر از رویکردهای مذکور می باشد.

با رشد سریع و مداوم اینترنت، ضرورت وجود سیستم های توصیه گر جهت پالایش اطلاعات افزایش یافته است. در طی سال های اخیر، به دلیل محبوبیت شبکه های اجتماعی، سیستم های توصیه گر مبتنی بر اعتماد توجه زیادی را به خود جلب کرده اند. یکی از ویژگی های مهم اعتماد که معمولاً در رویکردهای موجود نادیده گرفته شده است، ویژگی وابستگی به زمینه است. منظور این است که کاربرانی که در یک زمینه خاص قابل اعتماد هستند، لزوماً در زمینه های دیگر قابل اعتماد نیستند. بنابراین، سطح اعتماد میان دو کاربر را باید وابسته به زمینه هدف مورد بررسی قرار داد. برای پیش بینی ترجیحات یک کاربر در یک سیستم توصیه گر مبتنی بر اعتماد، می توان روابط اعتماد در هر زمینه را به صورت محلی یا سراسری

\* نویسنده مسئول

واژه‌های کلیدی: سیستم توصیه‌گر، سیستم توصیه‌گر مبتنی بر اعتماد، اعتماد محلی، اعتماد سراسری، سیستم توصیه‌گر آگاه از زمینه.

## ۱- مقدمه

امروزه، رشد نمایی اطلاعات موجود بر روی وب منجر به پیدایش مشکل گرانباری اطلاعات<sup>۱</sup> شده است. این بدان معناست که در میان حجم عظیمی از داده‌های برخط، یافتن اطلاعات مفید و مورد نیاز برای کاربران دشوار شده است. جویشرها مشکل یافتن محتوای وب مطلوب را به صورت جزئی کاهش می‌دهند، بخصوص زمانی که بتوان یک نیاز اطلاعاتی را با یک پرس و جو<sup>۲</sup> بیان نمود. اما در بسیاری از موارد، یک کاربر ممکن است دقیقاً نداند که چه چیزهایی می‌تواند مورد نیاز و علاقه وی باشد. در یک جویشر، کاربر می‌داند که به دنبال چه چیزی است و نیاز خود را با یک پرس و جو بیان می‌نماید و سپس جویشر باید در میان انبوهی از اطلاعات، به دنبال داده‌هایی بگردد که با پرس و جو کاربر بیشترین انطباق را دارند. به این ترتیب، نتایج جستجو، فارغ از این که پرس و جو توسط چه کسی و با چه علائق و پیش زمینه‌ای وارد شده است، معمولاً یکسان است. علاوه بر این، نتایجی که یک جویشر به کاربر تحویل می‌دهد معمولاً بسیار بیشتر از آن است که کل نتایج قابل بررسی توسط کاربر باشد. سیستم‌های توصیه‌گر با هدف رفع این مشکل، تبدیل به یکی از ابزارهای لازم و ضروری در وب امروزی شده‌اند. این سیستم‌ها با تجزیه و تحلیل رفتار کاربران، نیازها و ترجیحات آن‌ها را شناسایی نموده و بر اساس آن، محصولات و یا خدماتی را پیشنهاد می‌دهند که منطبق با نیازها و سلیقه کاربران باشند [۱-۵].

رایج‌ترین رویکرد توصیه، پالایش همکارانه می‌باشد [۶]. در این رویکرد، ابتدا گروهی از کاربران که ترجیحات مشابهی به کاربر جاری دارند، به عنوان همسایگان وی

انتخاب می‌شوند. سپس، بر مبنای عقاید این همسایگان، ترجیحات کاربر جاری پیش‌بینی می‌گردد. با وجود محبوبیت پالایش همکارانه، این رویکرد از دو مشکل ذاتی، یعنی تنگی داده‌ها و شروع سرد، رنج می‌برد [۷-۱۱]. دلیل اصلی بروز این مشکلات، فقدان اطلاعات کافی در مورد ترجیحات کاربران است. برای رفع این مشکلات، پژوهشگران رویکردهای ترکیبی را پیشنهاد داده‌اند که علاوه بر امتیازات، از اطلاعات جانبی مختلف نیز کمک می‌گیرند [۱۲]. به‌طور مثال، روابط اجتماعی موجود در شبکه اعتماد میان کاربران، یکی از منابع ارزشمند اطلاعات جانبی است که می‌تواند برای جبران کمبود امتیازات مورد استفاده قرار گیرد. در همین راستا، در طی سال‌های اخیر، سیستم‌های توصیه‌گر مبتنی بر اعتماد توسعه یافتند که بر اساس روابط اعتماد میان کاربران، توصیه‌های مناسبی را برای آن‌ها فراهم می‌کنند [۱۳-۱۷، ۱۱-۷، ۱]. این سیستم‌ها، با انتخاب اثربخش‌تر همسایگان و کاهش مشکلات مذکور، توصیه‌های باکیفیت‌تری نسبت به رویکردهای سنتی پالایش همکارانه تولید می‌کنند.

اعتماد را می‌توان به‌صورت صریح از خود کاربران جمع‌آوری کرد، یا به‌طور ضمنی از رفتار آن‌ها (مثلاً الگوی امتیازدهی) استنتاج نمود. اعتماد صریح دقیق‌تر از اعتماد ضمنی است، اما چون به تلاش بیشتری از سوی کاربر نیاز دارد، لذا همیشه در دسترس نیست. بنابراین، اعتماد ضمنی کاربرپذیری بیشتری دارد [۱۵، ۸]. به همین دلیل، در این تحقیق بر روی اعتماد ضمنی تمرکز می‌شود.

به‌طور کلی، مدل‌های محاسبه اعتماد ضمنی بر دو نوع محلی و سراسری می‌باشد. در حالت محلی، محاسبه اعتماد میان دو کاربر بر اساس اقلامی است که مشترکاً توسط هر دو امتیاز داده شده است. در حالت سراسری، شهرت یک کاربر در کل جامعه مورد بررسی قرار می‌گیرد [۱۸]. مزیت اصلی مدل محلی نسبت به مدل سراسری، ویژگی شخصی‌سازی شده آن است و به همین دلیل بسیار متداول‌تر از مدل سراسری است. اما مدل محلی

1- Information overload  
2- Query

همیشه اثربخش نیست. در حقیقت، به دلیل وجود میلیون‌ها کاربر و قلم، قطعاً یک کاربر با تمام کاربران جامعه دارای تجربیات مشترک نیست. همچنین، در بسیاری از موارد، تعداد تعاملات مستقیم میان دو کاربر ناکافی و بسیار اندک است، که در نتیجه منجر به استنتاج غیر دقیق اعتماد محلی می‌شود [۱۹]. در چنین شرایطی می‌توان از شهرت سراسری یک کاربر بهره برد که منعکس‌کننده تجربیات کل جامعه در ارتباط با وی است. در واقع، در این حالت، کاربران می‌توانند از یک خرد جمعی بهره ببرند. بنابراین، مدل‌های محلی و سراسری می‌توانند مکمل هم باشند. زمانی که سطح تنکی داده‌ها بسیار بالا باشد و یا اطلاعات کافی درباره یک کاربر وجود نداشته باشد، مدل سراسری اثربخش‌تر از محلی است و بالعکس.

یکی از نکات مهم در حوزه سیستم‌های توصیه‌گر مبتنی بر اعتماد ضمنی، توجه به ویژگی‌های ذاتی اعتماد در زمان استنتاج روابط می‌باشد. بر اساس تئوری اعتماد، یکی از ویژگی‌های مهم اعتماد، وابستگی به زمینه است [۲۰]. بر اساس این ویژگی، کاربرانی که در یک زمینه خاص قابل اعتماد هستند، لزوماً در زمینه دیگر قابل اعتماد نیستند. فرضاً، کاربری که در زمینه پیشنهاد فیلم قابل اعتماد است، ممکن است در زمینه موسیقی قابل اعتماد نباشد. زمینه می‌تواند نوع اقلامی باشد که کاربران امتیاز داده‌اند یا شرایط دیگری که تحت آن امتیاز صادر شده است، مثلاً زمان، موقعیت و غیره. در نظر داشتن اطلاعات زمینه‌ای، نقش مهمی در استنتاج دقیق‌تر روابط اعتماد و در نتیجه انتخاب همسایگان بهتر دارد. اما با این حال، در اکثر رویکردهای موجود، این ویژگی نادیده گرفته شده است [۲۰]. برای رفع این مشکل، اخیراً در یک تحقیق جدید [۲۱]، رویکردی تحت عنوان توصیه مبتنی بر اعتماد آگاه از زمینه (CATRA)<sup>۲</sup> پیشنهاد شده است که با در نظر داشتن زمینه معنایی اقلام، روابط اعتماد میان کاربران را مورد استنتاج قرار می‌دهد.

منطق رویکرد CATRA این است که اعتماد میان دو کاربر

به محتوای معنایی اقلام وابسته است. به‌طور مثال، کاربری که می‌تواند پیشنهادها ارزشمندی برای تماشای فیلم‌هایی در ژانر کمدی بدهد، ممکن است در زمینه فیلم‌های تاریخی از اطلاعات کافی برخوردار نباشد. بنابراین، وابسته به زمینه و محتوای یک قلم، پیشنهادات یک کاربر می‌تواند قابل اعتماد یا غیر قابل اعتماد باشد. اما این رویکرد با یک مسئله مهم نیز مواجه است. از آنجایی که در رویکرد CATRA، روابط اعتماد فقط به‌صورت محلی مدل‌سازی می‌شوند، لذا در شرایطی که تنکی داده‌ها بسیار زیاد باشد، نمی‌توان روابط اعتماد را به‌صورت دقیق استنتاج نمود. در این تحقیق، با گسترش ایده توصیه‌های مبتنی بر اعتماد آگاه از زمینه، رویکرد جدیدی پیشنهاد می‌گردد که روابط اعتماد میان کاربران را هم به‌صورت محلی و هم به‌صورت سراسری در زمینه‌های مختلف مورد استنتاج قرار می‌دهد. در رویکرد پیشنهادی این مقاله، ابتدا اقلام بر اساس شباهت‌های معنایی خوشه‌بندی می‌شوند. سپس وابسته به هر خوشه معنایی، روابط اعتماد ضمنی میان کاربران به‌صورت محلی و سراسری استنتاج می‌گردد. به این ترتیب، برای پیش‌بینی نظر کاربر جاری درباره یک قلم هدف، ابتدا باید زمینه معنایی آن قلم تعیین شود و سپس همسایگان محلی و سراسری در زمینه مربوطه انتخاب شوند. بر اساس نظرات هر دو گروه از همسایگان (محلی/ سراسری)، یک پیش‌بینی جداگانه انجام می‌گیرد. نهایتاً، پیش‌بینی‌های محلی و سراسری به‌دست آمده با یکدیگر ترکیب می‌شوند تا یک پیش‌بینی واحد حاصل شود. برای این منظور، از یک معیار وزن‌دهی استفاده می‌شود که بر اساس سطح تنکی داده‌ها، میزان اهمیت مدل محلی در برابر سراسری را معین می‌کند. نتایج آزمایش‌ها بر روی مجموعه داده واقعی MovieLens، نشان‌گر کیفیت بالاتر پیش‌بینی‌های انجام گرفته توسط رویکرد پیشنهادی نسبت به هم‌تایان خود می‌باشد.

ادامه این مقاله بدین ترتیب سازماندهی شده است. در بخش بعد، مرور مختصری بر روی کارهای پیشین خواهیم

3- Context-Aware Trust-based Recommendation Approach

داشت. در بخش ۳، رویکرد پیشنهادی تشریح خواهد شد. سپس در بخش ۴، به ارزیابی عملکرد و مقایسه رویکرد پیشنهادی با دیگر کارها خواهیم پرداخت. نهایتاً در بخش ۵، نتیجه‌گیری مطرح می‌شود.

## ۲- پیش‌زمینه و کارهای مرتبط

پالایش همکارانه یکی از مهم‌ترین رویکردهای توصیه است که بیشتر از سایر روش‌ها مورد استفاده قرار گرفته است. سیستم مبتنی بر پالایش همکارانه اقلامی را پیشنهاد می‌دهد که مورد علاقه کاربران با ترجیحات مشابه بوده باشد. ایده این رویکرد این است که کاربرانی با ترجیحات مشابه، اقلام مشابهی را دوست دارند [۲۲،۲۳]. پالایش همکارانه با دو مشکل اصلی مواجه است [۷-۱۱]:

- تنگی داده‌ها: با توجه به وجود مجموعه عظیمی از کاربران و اقلام، ماتریس امتیازات معمولاً بسیار تنگ و خلوت است. در این شرایط، پیدا کردن اقلامی که مشترکاً توسط دو کاربر امتیاز داده شده باشند، دشوار است. در نتیجه، امکان محاسبه شباهت به صورت دقیق وجود نخواهد داشت.
- شروع سرد: پیش‌بینی ترجیحات کاربرانی که هنوز امتیازی ثبت نکرده‌اند یا به تعداد بسیار کمی از اقلام امتیاز داده‌اند، دشوار است و در نتیجه نمی‌توان پیشنهادهای مناسبی را برای آن‌ها تولید نمود.

یکی از راه‌حل‌های رفع این مشکلات، بهره‌گیری از منابع اطلاعات جانبی مثل شبکه اعتماد است [۱۷-۱۳، ۱۱-۷]. سیستم‌های توصیه‌گر مبتنی بر اعتماد، بر اساس اطلاعات موجود در شبکه میان کاربران، همسایگان قابل اعتماد کاربر جاری را شناسایی می‌کنند و با برآیند گرفتن از نظرات آن‌ها، پیشنهادهایی را تولید می‌نمایند.

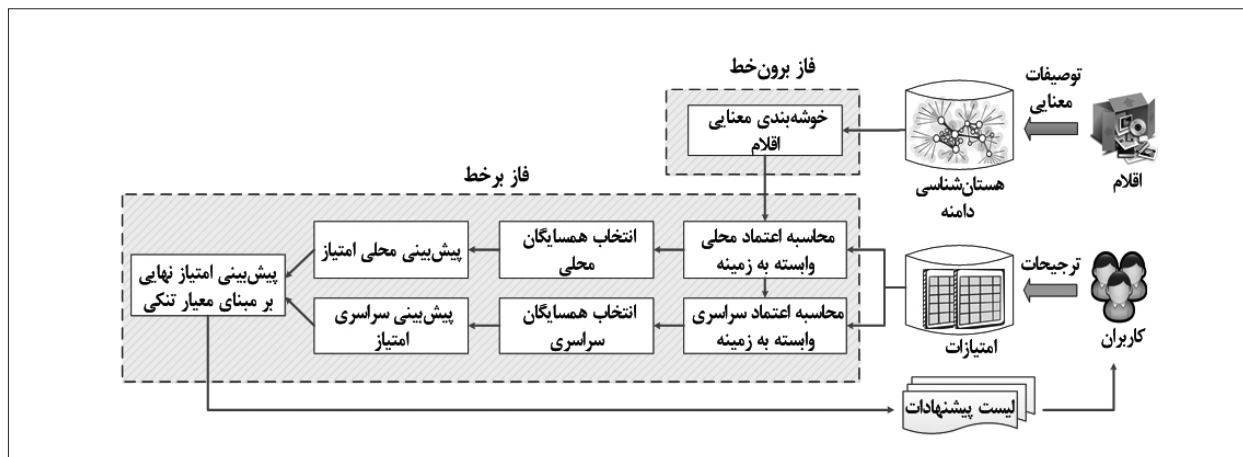
به‌طور کلی، دو نوع مدل محاسبه اعتماد وجود دارد [۱۸]: مدل محلی و مدل سراسری. مدل‌های محلی، ترجیحات شخصی کاربران را منعکس می‌کنند. اما زمانی که تعاملات کافی میان دو کاربر وجود نداشته باشد،

مدل‌های محلی اثربخش نخواهند بود. در چنین شرایطی، استفاده از روابط اعتماد سراسری برای انتخاب همسایگان ارجحیت دارد [۸،۱۱]. در طی سال‌های گذشته، رویکردهای بسیاری پیشنهاد شده‌اند که از اعتماد محلی برای بهبود پالایش همکارانه بهره می‌برند. به‌طور مثال، در [۲۴،۲۵]، از معیار همبستگی امتیازات برای محاسبه اعتماد محلی میان دو کاربر استفاده می‌شود. در برخی تحقیقات دیگر [۱۵،۱۴،۱۱،۹،۸]، برای محاسبه اعتماد محلی میان دو کاربر باید ترجیحات یکی را بر اساس نظرات دیگری پیش‌بینی نمود و سپس بر مبنای خطای پیش‌بینی، اعتماد محاسبه می‌شود. همچنین، تحقیقات متعددی بهره‌گیری از اعتماد سراسری را به‌عنوان یک منبع اطلاعاتی ارزشمند در فرآیند توصیه پیشنهاد داده‌اند. مثلاً در [۱۳]، درصد پیش‌بینی‌های درستی که یک کاربر برای کل جامعه کاربری انجام داده است، مبنای محاسبه شهرت کاربر است. در برخی از تحقیقات نیز از میانگین روابط اعتماد محلی منتسب به یک کاربر برای تعیین میزان اعتماد سراسری استفاده می‌شود [۹،۱۱،۱۴].

هدف ما در این مقاله، ارائه رویکردی است که بتواند از هر دو منبع اعتماد محلی و سراسری به‌صورت آگاهانه از زمینه بهره‌برداری و ترکیب آن‌ها، همسایگان را به‌گونه‌ای اثربخش‌تر انتخاب نماید.

## ۳- رویکرد پیشنهادی

در این بخش ساختار رویکرد پیشنهادی به‌طور مفصل تشریح می‌گردد. شکل ۱، چارچوب رویکرد پیشنهادی را نمایش می‌دهد. همان‌طور که نشان داده شده است، در مرحله برون‌خط عملیات خوشه‌بندی اقلام بر اساس توصیفات معنایی آن‌ها صورت می‌پذیرد. در مرحله برخط، ابتدا بر اساس زمینه معنایی اقلام، روابط اعتماد محلی و سراسری شکل می‌گیرد. سپس، همسایگان قابل اعتماد به‌صورت محلی و سراسری شناسایی می‌شوند. بر اساس نظرات همسایگان منتخب، پیش‌بینی‌های محلی و سراسری



شکل ۱: چارچوب رویکرد پیشنهادی

هستان شناسی، رده Movie است که تمام فیلمها نمونه‌ای از این رده هستند. برای نمونه‌دهی این هستان شناسی، با استفاده از وبگاه IMDb<sup>۶</sup> و یک خزنده وب، اطلاعات مورد نیاز در مورد هر فیلم جمع‌آوری می‌شود. شباهت معنایی میان دو قلم  $a$  و  $b$  بر مبنای توصیفات آن‌ها در هستان شناسی را می‌توان با استفاده از رابطه زیر محاسبه کرد [۲۶]:

$$SemSim(a,b) = \sum_{i=1}^{|P|} \left( \frac{common(a,b,P[i])}{\max(deg(a,P[i]),deg(b,P[i]))} \right) \times Weight(P[i]) \quad (1)$$

که در آن،  $P$  برداری حاوی مجموعه‌ای از ویژگی‌های رده Movie است (این رده، رده هدف سیستم توصیه‌گر برای ارائه پیشنهادهاست)؛  $deg(a,p)$  نشان‌دهنده تعداد نمونه‌های منتسب به  $a$  از طریق ویژگی  $p$  است؛  $common(a,b,p)$  نشان‌دهنده تعداد نمونه‌های مشترک منتسب به  $a$  و  $b$  از طریق ویژگی  $p$  است؛ و  $Weight(p)$  اهمیت ویژگی  $p$  می‌باشد. وزن هر ویژگی را می‌توان به صورت ذهنی با توجه به حوزه تعیین نمود. مثلاً در حوزه فیلم، اهمیت ژانر فیلم از محل تصویربرداری بیشتر است.

پس از محاسبه شباهت معنایی میان هر جفت قلم، خوشه‌بندی اقلام بر اساس شباهت‌های به‌دست آمده انجام می‌گیرد. برای این منظور، ما الگوریتم  $k$ -medoids

انجام می‌گیرد. در نهایت، این پیش‌بینی‌ها با استفاده از یک معیار تنگی وزن‌دهی و ترکیب می‌شوند تا پیش‌بینی نهایی به‌دست آید. بر اساس پیش‌بینی‌های نهایی، لیستی از اقلام زمینه هدف که دارای بالاترین مقدار پیش‌بینی شده هستند به کاربر جاری پیشنهاد داده می‌شوند. در ادامه به تشریح جزئیات هر یک از این مراحل خواهیم پرداخت.

### ۳-۱- خوشه‌بندی معنایی اقلام

در مرحله برون خط، اقلام بر اساس شباهت‌های معنایی خوشه‌بندی می‌شوند تا بتوان روابط اعتماد محلی و سراسری را بر مبنای این خوشه‌ها تعریف کرد. برای بهره‌گیری از اطلاعات معنایی اقلام، لازم است که مشخصه‌های اقلام به‌وسیله یک هستان شناسی دامنه نمایش داده شود. هستان شناسی مورد استفاده در این تحقیق، شامل مفاهیم و روابط حوزه فیلم است، زیرا این یک حوزه شناخته شده و رایج برای سیستم‌های توصیه‌گر است و مفاهیم و روابط متعددی در این حوزه وجود دارد (مثل فیلم، بازیگر، کارگردان، نویسنده، ژانر و...). اما به هر حال می‌توان رویکرد پیشنهادی را برای حوزه‌های دیگر با هستان شناسی‌های متفاوت نیز مورد استفاده قرار داد. در اینجا، از هستان شناسی فیلم (Movie Ontology)<sup>۴</sup> استفاده می‌شود که بر اساس استاندارد OWL<sup>۵</sup> توسط دانشگاه زوریخ توسعه یافته است. رده اصلی این

6- <http://www.imdb.com/>

4- <http://www.movieontology.org/>  
5- Web Ontology Language

[۲۷] را به دلیل سادگی و دقت بالای آن انتخاب می‌کنیم. مشابه با الگوریتم  $k$ -means [۲۸]،  $k$ -medoids نیز یک الگوریتم مبتنی بر بخش‌بندی است، با این تفاوت که به جای میانگین‌گیری، خود اشیاء را به عنوان مراکز خوشه (مدوئیدها) انتخاب می‌کند. از آنجایی که هدف  $k$ -medoids کمینه‌سازی مجموع فواصل دو بدو در داخل یک خوشه است، لذا در برابر نوفه و داده‌های خارج از محدوده، قدرت بیشتری دارد. علاوه بر این،  $k$ -medoids عموماً تحت تاثیر ترتیب اشیاء قرار نمی‌گیرد [۲۷].

برای خوشه‌بندی اقلام با استفاده از الگوریتم  $k$ -medoids، ابتدا  $k$  قلم به صورت تصادفی به عنوان مدوئیدهای اولیه انتخاب می‌شوند. سپس  $k$ -medoids دو گام را به صورت چرخشی تکرار می‌کند: در گام اول، هر قلم را به خوشه‌ای با نزدیک‌ترین مدوئید متناسب می‌نماید. برای این منظور، از شباهت معنایی به عنوان معیاری برای سنجش فاصله دو قلم استفاده می‌شود. به طور دقیق‌تر، فاصله میان دو قلم  $a$  و  $b$ ، یعنی  $dist(a, b)$ ، به صورت  $1 - SemSim(a, b)$  محاسبه می‌شود. در گام دوم، در داخل هر خوشه، به نوبت هر یک از اقلام غیر مدوئید با قلم مدوئید جابجا می‌شود. اگر با جابجایی یک غیر مدوئید با مدوئید اولیه، مجموع فواصل داخل خوشه‌ای کاهش یافت، آنگاه آن قلم غیر مدوئید به عنوان مدوئید جدید جایگزین می‌شود. این دو گام به طور مداوم تکرار می‌شوند تا جایی که مدوئیدها ثابت باقی بمانند. به این ترتیب، مجموعه‌ای از  $k$  خوشه قلم،  $C = \{c_1, c_2, \dots, c_k\}$ ، به دست خواهد آمد.

### ۳-۲ محاسبه اعتماد محلی وابسته به زمینه

با توجه به این که رویکرد پیشنهادی یک رویکرد آگاه از زمینه است، لذا روابط اعتماد میان کاربران به صورت وابسته به زمینه شکل می‌گیرند. به عبارت دقیق‌تر، در این رویکرد، روابط اعتماد با در نظر داشتن زمینه معنایی اقلام مورد استنتاج قرار می‌گیرند. به این ترتیب، سطح اعتماد میان دو کاربر بسته به زمینه‌های مختلف متغیر است. به منظور محاسبه روابط اعتماد محلی وابسته به زمینه،

ما از مدل معرفی شده در رویکرد CATRA [۲۱] استفاده خواهیم کرد.

فرض کنید که  $U$ ، مجموعه‌ای از  $n$  کاربر و  $I$ ، مجموعه‌ای از  $m$  قلم باشد. ماتریس کاربر-قلم  $R$ ، یک ماتریس  $n \times m$  بعدی است که هر درایه آن بیان‌گر امتیاز یک کاربر برای یک قلم می‌باشد. امتیاز کاربر  $u$  برای قلم  $i$  با  $r_{ui}$  نشان داده می‌شود. برای پیش‌بینی امتیاز کاربر جاری برای قلم هدف  $i$ ، ابتدا باید زمینه معنایی این قلم یا به عبارت دیگر خوشه معنایی که  $i$  بدان تعلق دارد، تعیین شود. این خوشه در واقع زمینه هدف ( $C$ ) را مشخص می‌کند. خوشه  $C$ ، خوشه‌ای است که در میان کل خوشه‌های موجود، بیشترین نزدیکی را با قلم هدف  $i$  دارد.

حال با توجه به زمینه هدف، می‌توان یک زیرماتریس از  $R$  را استخراج کرد که حاوی امتیازات مربوط به زمینه  $C$  باشد. این زیرماتریس را با  $R^C$  نشان می‌دهیم.  $R^C$  یک ماتریس  $|n \times c|$  بعدی است که در بردانده امتیازات کاربران برای اقلام خوشه معنایی  $C$  می‌باشد. به عبارت دیگر،  $R^C$  ماتریس امتیازات وابسته به زمینه  $C$  است. با داشتن این ماتریس، می‌توان اعتماد محلی میان دو کاربر را به صورت خاص برای زمینه  $C$  استنتاج کرد. بر مبنای مدل معرفی شده در [۲۱]، برای محاسبه اعتماد محلی میان دو کاربر در زمینه هدف  $C$ ، ابتدا باید اقلام متعلق به زمینه  $C$  را که مشترکاً توسط هر دو کاربر امتیازدهی شده‌اند شناسایی نمود. سپس، میانگین خطای پیش‌بینی بر روی این اقلام، به عنوان معیار سنجش اعتماد محلی مورد استفاده قرار می‌گیرد.

فرض کنید که  $I_{ii}^C$  مجموعه اقلامی از خوشه معنایی  $C$  باشد که توسط کاربر  $u$  امتیازدهی شده‌اند. اگر کاربر  $u$  و کاربر  $v$ ، حداقل دارای یک قلم مشترک در زمینه  $C$  باشند، آنگاه سطح اعتماد محلی  $u$  به  $v$  در زمینه  $C$ ، با توجه به امتیازات موجود در زیرماتریس  $R^C$ ، طبق رابطه زیر محاسبه می‌شود [۲۱]:



C دارای ارتباط اعتماد محلی مستقیم با کاربر v می‌باشند.

### ۳-۴- انتخاب همسایگان محلی

پس از محاسبه اعتماد محلی، نوبت به انتخاب همسایگان کاربر جاری می‌رسد. از آنجایی که در رویکرد پیشنهادی، روابط اعتماد به صورت وابسته به زمینه شکل می‌گیرند، بنابراین همسایگان کاربر جاری در زمینه‌های مختلف لزوماً یکسان نخواهند بود. فرض کنید  $LN_u^c$  نشان‌دهنده مجموعه همسایگان محلی کاربر جاری u در زمینه هدف C باشد. در رویکرد پیشنهادی، برای انتخاب همسایگان محلی از یک آستانه  $\alpha$  استفاده می‌شود. هرگاه میزان اعتماد محلی کاربر u به کاربر v در زمینه هدف از این آستانه بیشتر باشد ( $LT_{u,v}^c > \alpha$ )، آنگاه v به عنوان همسایه محلی u انتخاب می‌شود ( $v \in LN_u^c$ ).

### ۳-۵- انتخاب همسایگان سراسری

مشابه با فرآیند انتخاب همسایگان محلی، همسایگان سراسری نیز بر اساس میزان شهرت آن‌ها در زمینه (خوشه) هدف انتخاب می‌شوند. فرض کنید  $GN^c$  نشان‌دهنده مجموعه کاربران باشد که در زمینه هدف C از شهرت بالایی در میان کاربران برخوردارند. برای انتخاب همسایگان سراسری از یک آستانه  $\theta$  استفاده می‌کنیم. هرگاه شهرت کاربر v در زمینه هدف C از آستانه  $\theta$  بیشتر باشد ( $GT_v^c > \theta$ )، آنگاه v را می‌توان به عنوان یک همسایه سراسری برای هر یک از کاربران جامعه انتخاب نمود ( $v \in GN^c$ ).

### ۳-۶- پیش‌بینی محلی امتیاز

در این مرحله، با توجه به نظرات همسایگان محلی، امتیاز کاربر جاری u برای قلم هدف ا به صورت محلی پیش‌بینی می‌شود. برای این منظور، از میانگین وزن‌دهی شده امتیازات همسایگان محلی برای قلم ا استفاده می‌شود. بر اساس ماتریس  $R^c$ ، پیش‌بینی محلی امتیاز u برای قلم ا

$$LP_{u,i}^c = \bar{r}_u + \frac{\sum_{v \in LN_u^c} (r_{v,i} - \bar{r}_v) \times LT_{u,v}^c}{\sum_{v \in LN_u^c} LT_{u,v}^c} \quad (7)$$

$$LT_{u,v}^c = 1 - \frac{\sum_{i \in I_u^c \cap I_v^c} (p_{u,i}^v - r_{u,i})}{|I_u^c \cap I_v^c|} \quad (2)$$

که در آن،  $LT_{u,v}^c$  میزان اعتماد محلی کاربر u به v در زمینه C است؛  $I_u^c \cap I_v^c$  مجموعه اقلامی از خوشه C است که هر دو کاربر u و v امتیازدهی کرده‌اند؛  $|I_u^c \cap I_v^c|$  تعداد اقلام مشترک و  $p_{u,i}^v$  پیش‌بینی امتیاز کاربر u برای قلم ا بر مبنای نظر کاربر v است:

$$p_{u,i}^v = \bar{r}_u + (r_{v,i} - \bar{r}_v) \quad (3)$$

که در آن،  $\bar{r}_u$  و  $\bar{r}_v$  متوسط امتیازات صادر شده توسط کاربران u و v برای اقلام زمینه C می‌باشد. اگر دو کاربر فاقد قلم مشترک باشند، آنگاه میزان اعتماد محلی به صورت غیر مستقیم طبق قاعده انتشار اعتماد محاسبه می‌شود [۲۱]:

$$LT_{u,v}^c = 1 - \frac{\sum_{s \in adj(u)} LT_{u,s}^c \times (LT_{s,v}^c \times \beta)}{\sum_{s \in adj(u)} LT_{u,s}^c} \quad (4)$$

که s نشان‌دهنده کاربری است که دارای قلم مشترک با u است؛ و  $\beta$  پارامتر وزن‌دهی جهت کاهش اعتماد در طول مسیر انتشار است:

$$\beta = (MTPD - d + 1) / MTPD \quad (5)$$

در رابطه (۵)، MTPD نشان‌دهنده طول بیشینه انتشار و d فاصله میان کاربر s با کاربر v (تعداد گره‌های میانی در طی مسیر انتشار اعتماد) می‌باشد. هر قدر فاصله s از v بیشتر باشد، پارامتر  $\beta$  کمتر می‌شود و بنابراین، میزان اعتماد غیر مستقیم با افزایش طول مسیر انتشار، کاهش می‌یابد.

### ۳-۳- محاسبه اعتماد سراسری وابسته به زمینه

در رویکرد پیشنهادی، شهرت سراسری یک کاربر با میانگین گرفتن از مقادیر اعتماد محلی متناسب به وی تعیین می‌گردد [۱۴]. بر همین اساس، شهرت سراسری کاربر v در زمینه C، بدین شکل محاسبه می‌شود:

$$GT_v^c = \frac{1}{|NB_v^c|} \sum_{u \in NB_v^c} LT_{u,v}^c \quad (6)$$

که در آن  $NB_v^c$  مجموعه کاربرانی هستند که در زمینه

که در آن  $LP_{u,i}^c$  مقدار پیش‌بینی محلی امتیاز  $u$  برای قلم  $i$  است؛  $\bar{r}_u$  و  $\bar{r}_v$  متوسط امتیازات صادر شده توسط کاربران  $u$  و  $v$  برای اقلام زمینه  $c$  می‌باشد.

### ۳-۷- پیش‌بینی سراسری امتیاز

در این مرحله، امتیاز کاربر جاری  $u$  برای قلم هدف  $i$  به‌صورت سراسری و با توجه به نظرات همسایگان سراسری پیش‌بینی می‌شود. بر اساس میانگین وزنی شده امتیازات همسایگان سراسری برای قلم  $i$ ، پیش‌بینی امتیاز کاربر  $u$  برای قلم  $i$  برابر است با:

$$GP_{u,i}^c = \bar{r}_u + \frac{\sum_{v \in GN^c} (r_{v,i} - \bar{r}_v) \times GT_v^c}{\sum_{v \in GN^c} GT_v^c} \quad (8)$$

که در آن  $GP_{u,i}^c$  مقدار پیش‌بینی سراسری امتیاز کاربر  $u$  برای قلم  $i$  است.

### ۳-۸- پیش‌بینی امتیاز نهایی بر مبنای معیار تنکی

در مرحله آخر، پیش‌بینی‌های محلی و سراسری باید به نحوی وزنی و با یکدیگر ترکیب شوند تا یک مقدار پیش‌بینی واحد به‌دست آید. برای این منظور، ما از یک معیار تنکی استفاده می‌کنیم که مقدار وزن پیش‌بینی‌های محلی و سراسری را با توجه به سطح تنکی داده‌ها محاسبه می‌کند. همان‌طور که قبلاً نیز اشاره شد، زمانی که داده‌ها بسیار تنک باشند، پیش‌بینی سراسری به محلی ارجحیت دارد و بالعکس. بنابراین نیاز به معیاری داریم که با افزایش سطح تنکی داده‌ها، وزن بیشتری را به پیش‌بینی سراسری تخصیص دهد و با کاهش سطح تنکی، وزن پیش‌بینی محلی را افزایش دهد. بر اساس مطالعات انجام گرفته، ما معیار تنکی  $UIS^v$  [۲۹] را برای این منظور انتخاب کردیم. این معیار برابر است با نسبت تعداد همسایگان محلی کاربر جاری که به قلم هدف امتیاز داده‌اند در برابر تعداد کل کاربرانی که به این قلم امتیاز داده‌اند [۲۹]:

$$UIS_{u,i}^c = 1 - \frac{|LN_{u,i}^c|}{|U_i|} \quad (9)$$

که در آن  $|LN_{u,i}^c|$  تعداد همسایگان محلی کاربر  $u$  در زمینه  $c$  است که به قلم  $i$  امتیاز داده‌اند، و  $|U_i|$  تعداد کل کاربرانی است که به قلم  $i$  امتیاز داده‌اند. منطق معیار  $UIS_{u,i}^c$  این است که وقتی تعداد همسایگان محلی اندک باشد، احتمالاً بهره‌گیری از نظرات همسایگان سراسری می‌تواند به بهبود کیفیت پیش‌بینی کمک نماید. بنابراین،  $UIS_{u,i}^c$  می‌تواند معیار مناسبی برای بیان میزان اهمیت پیش‌بینی سراسری  $GP_{u,i}^c$  در برابر پیش‌بینی محلی  $LP_{u,i}^c$  باشد.

با توجه به معیار تنکی معرفی شده در رابطه (۹)، می‌توان با ترکیب خطی پیش‌بینی‌های محلی و سراسری، پیش‌بینی نهایی امتیاز کاربر  $u$  برای قلم  $i$  در زمینه  $c$ ،  $FP_{u,i}^c$ ، را بدین شکل محاسبه نمود:

$$FP_{u,i}^c = (1 - UIS_{u,i}^c) \times LP_{u,i}^c + UIS_{u,i}^c \times GP_{u,i}^c \quad (10)$$

بر اساس پیش‌بینی‌های نهایی، لیستی از اقلام زمینه هدف که دارای بالاترین مقدار پیش‌بینی شده هستند به کاربر جاری پیشنهاد داده می‌شوند.

### ۴- آزمایش‌ها

در این بخش به ارزیابی عملکرد رویکرد پیشنهادی و مقایسه آن با برخی از کارهای پایه‌ای و یا جدید در حوزه سیستم‌های توصیه‌گر مبتنی بر اعتماد می‌پردازیم. در این راستا، رویکردهای ادامه‌به‌عنوان مبنای مقایسه قرار می‌گیرند: رویکرد پالایش همکارانه مبتنی بر اعتماد (TACF) [۱۴]، رویکرد توصیه مبتنی بر اعتماد با استفاده از کلونی مورچه (TARS) [۳۰]، رویکرد ترکیب اعتماد و شباهت معنایی (TSF) [۱۵]، رویکرد تلفیقی اعتماد کاربر-قلم (HUIT) [۸]، و رویکرد توصیه مبتنی بر اعتماد آگاه از زمینه (CATRA) [۲۱]. این رویکردها در Matlab 2012 پیاده‌سازی شده و پارامترهای هر کدام به گونه‌ای تنظیم می‌شوند که بهترین نتایج به ازای هر رویکرد به‌دست آید.

### ۴-۱- طراحی آزمایش‌ها

در این مقاله، از مجموعه داده واقعی MovieLens 1M<sup>8</sup>

8- <http://grouplens.org/datasets/movielens/1m/>

7- User-Item Specific (UIS) sparsity measure



جدول ۱: تنظیم پارامترهای رویکرد پیشنهادی

پارامتر	$\theta$	$\alpha$	k	MTPD
مقدار بهینه	.۱۵۵	.۱۶	۱۸	۳

انتخاب می‌شود. این مقدار بهینه به پارامتر مربوطه متناسب می‌شود و سپس همین مراحل برای پارامتر بعدی تکرار می‌شود تا نهایتاً مقدار بهینه هر پارامتر مشخص شود. جدول ۱، تنظیم بهینه پارامترهای رویکرد پیشنهادی را نشان می‌دهد.

### ۴-۳ نتایج

دقت پیش‌بینی هر رویکرد به ازای مقادیر مختلف n در پروتکل Given-n (۵، ۱۰، ۱۵ و ۲۵) در شکل ۲ نشان داده شده است. مسلماً با افزایش n، اطلاعات موجود درباره هر کاربر آزمون افزایش می‌یابد و در نتیجه دقت رویکردهای مختلف رو به بهبود می‌رود. نتایج این آزمایش نشان‌گر برتری رویکرد پیشنهادی نسبت به دیگر رویکردها می‌باشد. در میان رویکردهای CATRA، TARS، TSF، HUIT و CATRA، دو رویکرد آخر نتایج نزدیک‌تری به رویکرد پیشنهادی دارند. رویکرد HUIT مشابه با رویکرد پیشنهادی ما مبتنی بر هر دو مدل اعتماد محلی و سراسری است. اما با این تفاوت که در HUIT، فقط زمانی از مدل سراسری استفاده می‌شود که قلم مشترکی میان دو کاربر وجود نداشته باشد. به این ترتیب، مدل محلی همواره بر مدل سراسری ارجحیت دارد، حتی اگر بر پایه اطلاعات اندکی باشد. این امر منجر به تاثیر منفی بر روی دقت نتایج می‌شود. همچنین نقطه ضعف دیگر این رویکرد نادیده گرفتن اطلاعات زمینه است.

با توجه به نتایج، رویکرد CATRA و رویکردی پیشنهادی ما دقت بالاتری نسبت به سایرین دارند. دلیل این امر، بهره‌گیری از اطلاعات زمینه است که منجر به استنتاج دقیق‌تر روابط اعتماد و در نتیجه تشکیل همسایگی‌های بهتر می‌گردد. با افزایش دقت فرآیند تشکیل همسایگی، مسلماً دقت پیش‌بینی‌های سیستم بهبود می‌یابد. در هیچ‌یک از رویکردهای TSF، TARS، TACF و HUIT، استنتاج روابط اعتماد ضمنی به صورت وابسته به زمینه نیست. بنابراین همیشه یک مجموعه همسایه ثابت برای کاربر جاری انتخاب می‌کنند، بدون توجه به این‌که قلم هدفی که باید

برای انجام آزمایش‌ها استفاده می‌شود. این مجموعه داده حاوی ۱۰۰۰۲۰۹ امتیاز از سوی ۶۰۴۰ کاربر برای ۳۹۵۲ فیلم می‌باشد. هر امتیاز یک عدد گسسته بین ۱ تا ۵ است. ما با استفاده از روش اعتبارسنجی متقابل ۵ قسمتی<sup>۱۱</sup>، کاربران را به صورت تصادفی به مجموعه‌های آموزش و آزمون تفکیک می‌کنیم. سپس، با استفاده از پروتکل آزمایش "Given-n"<sup>[۱۱]</sup>، برای هر کاربر مجموعه آزمون، تعداد n امتیاز به صورت تصادفی در مجموعه آموزش و مابقی در مجموعه آزمون قرار می‌گیرد.

ارزیابی عملکرد هر رویکرد، بر اساس دقت پیش‌بینی‌های حاصله انجام می‌گیرد. برای این منظور، ما از معیار رایج میانگین خطای مطلق (MAE)<sup>۱۱</sup> استفاده می‌کنیم که تفاوت میان پیش‌بینی‌ها با مقادیر واقعی امتیازات را محاسبه می‌کند:

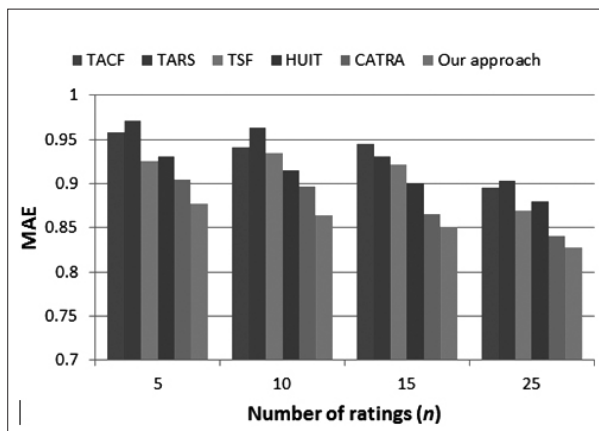
$$MAE = \frac{1}{\#TS} \sum_{(u,i) \in TS} |r_{u,i} - p_{u,i}| \quad (11)$$

که TS نشان‌دهنده مجموعه آزمون و #TS اندازه این مجموعه است.

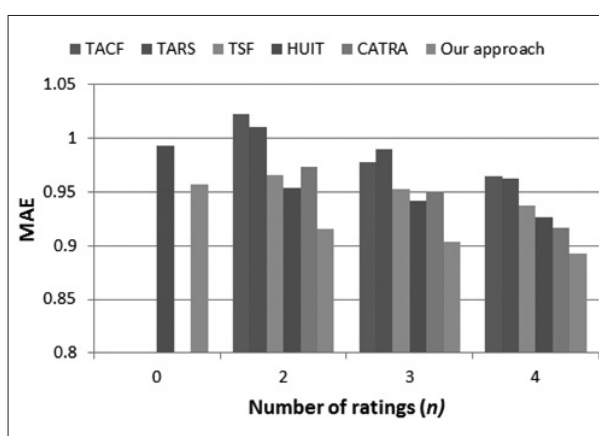
### ۴-۲- تنظیم پارامترها

حصول بهترین عملکرد برای رویکرد پیشنهادی، وابسته به تنظیم مناسب پارامترهای ورودی آن است. این پارامترها شامل تعداد خوشه‌ها (k)، آستانه انتخاب همسایگان محلی ( $\alpha$ )، آستانه انتخاب همسایگان سراسری ( $\theta$ )، و بیشینه طول انتشار اعتماد (MTPD) می‌باشد. تعیین مقادیر بهینه این پارامترها با آزمایش تحلیل حساسیت انجام می‌گیرد. برای این منظور، پارامترها به صورت یک به یک مورد آزمایش قرار می‌گیرند. برای هر پارامتر تحت آزمایش، مقادیر مختلف امتحان می‌شود، درحالی‌که دو پارامتر دیگر مقدار ثابتی دارند. مقداری که منجر به کمترین MAE می‌شود، به عنوان مقدار بهینه پارامتر تحت آزمایش

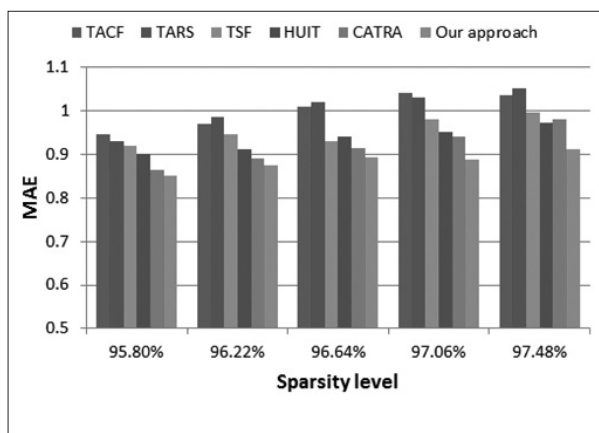
9- 5-fold-cross-validation  
10- Mean Absolute Error



شکل ۲: MAE رویکردهای مختلف به ازای تعداد امتیازات



شکل ۳: MAE رویکردهای مختلف در برابر مشکل شروع سرد



شکل ۴: MAE رویکردهای مختلف در برابر سطوح مختلف تنگی

سطح تنگی، برتری رویکرد پیشنهادی نسبت به بقیه بارزتر می‌گردد. دلیل آن این است که در این رویکرد، مدل‌های اعتماد محلی و سراسری بر اساس سطح تنگی داده‌ها وزن‌دهی و ترکیب می‌شوند تا بدین ترتیب بتوان پیش‌بینی‌های دقیقی را بر اساس حجم داده‌های موجود انجام داد.

مورد پیش‌بینی قرار گیرد، چه ویژگی‌هایی خاصی دارد و چه افرادی قابلیت ارائه پیشنهادها مناسب با توجه به این ویژگی‌های خاص را دارند. نادیده گرفتن این امر منجر به تاثیر منفی بر روی عملکرد سیستم توصیه‌گر و کاهش دقت آن می‌گردد. نتایج این آزمایش، اثربخشی اطلاعات زمینه معنایی برای بهبود دقت سیستم‌های توصیه‌گر مبتنی بر اعتماد را ثابت می‌کند.

در آزمایش دوم، عملکرد رویکردهای مختلف در برابر مشکل شروع سرد مورد ارزیابی قرار می‌گیرد. برای این منظور، کاربرانی با تعداد امتیازات کمتر از ۵ را به‌عنوان کاربران جدید در نظر می‌گیریم. شکل ۳ نتایج به‌دست آمده را به ازای مقادیر مختلف  $n$  (۰، ۲، ۳ و ۴) نشان می‌دهد. در شرایطی که  $n$  برابر با ۰ باشد، تنها رویکردهایی که از مدل سراسری بهره می‌گیرند (یعنی رویکرد پیشنهادی و HUIT)، قادر به تولید پیش‌بینی هستند. بنابراین، سایر رویکردها نمی‌توانند برای کاربرانی که سابقه تعامل با سیستم ندارند، هیچ‌گونه پیشنهادی تولید کنند. همان‌طور که نتایج نشان می‌دهد، رویکرد پیشنهادی به‌واسطه بهره‌گیری از روابط اعتماد سراسری و محلی آگاه از زمینه، عملکرد بهتری در مواجهه با کاربران سردآغاز دارد.

در آزمایش سوم، عملکرد رویکردهای مختلف در برابر سطوح مختلف تنگی داده‌ها مورد آزمون قرار می‌گیرد. سطح تنگی داده‌ها در مجموعه داده MovieLens برابر با ۹۵/۸٪ می‌باشد:

$$= \text{سطح تنگی} = 100 \times ((\text{تعداد اقلام} \times \text{تعداد کاربران}) / \text{تعداد امتیازات} - 1)$$

به‌منظور افزایش سطح تنگی، در طی ۴ مرحله و در هر مرحله ۱۰۰۰۰۰ امتیاز را به‌طور تصادفی انتخاب و از مجموعه آموزش حذف می‌کنیم. به این ترتیب، سطح تنگی داده‌ها از ۹۵/۸٪ به ۹۷/۴٪ افزایش خواهد یافت. در این آزمایش از پروتکل Given-15 استفاده می‌کنیم. شکل ۴ نتایج به‌دست آمده را به ازای سطوح مختلف تنگی نشان می‌دهد. با توجه به نتایج، رویکرد پیشنهادی دقت بالاتری دارد. با افزایش

- [1] M.M. Azadjalal, P. Moradi, A. Abdollahpouri, M. Jalili, "A trust-aware recommendation method based on Pareto dominance and confidence concepts", *Knowledge-Based Systems*, Vol. 116, pp. 130–143, 2017.
- [2] F.S. Gohari, M.J. Tarokh, "New Recommender Framework: Combining Semantic Similarity Fusion and Bicluster Collaborative Filtering", *Computational Intelligence*, Vol. 32, pp. 561–586, 2016.
- [3] J. Wei, J. He, K. Chen, Y. Zhou, Z. Tang, "Collaborative filtering and deep learning based recommendation system for cold start items", *Expert Systems with Applications*, Vol. 69, pp. 29–39, 2017.
- [4] ملک زاده همدانی، ا.، کاندی، م.، «تنوع‌بخشی شخصی‌سازی شده در سیستم توصیه‌گر با استفاده از الگوریتم شبیه‌سازی تبرید دوهدفه»، *علوم رایانشی*، شماره ۳، ۱۳۹۵، <http://csj.isi.org.ir/abstract.aspx.1-17>.
- [5] F.S. Gohari, M.J. Tarokh, "A New Hybrid Collaborative Recommender Using Semantic Web Technology and Demographic data", *International Journal of Information & Communication Technology Research*, Vol. 8, pp. 51–61, 2016.
- [6] G. Adomavicius, A. Tuzhilin, "Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions", *IEEE Transactions on Knowledge and Data Engineering*, Vol. 17, pp. 734–749, 2005.
- [7] G. Guo, J. Zhang, D. Thalmann, "Merging trust in collaborative filtering to alleviate data sparsity and cold start", *Knowledge-Based Systems*, Vol. 57, pp. 57–68, 2014.
- [8] Q. Shambour, J. Lu, "An effective recommender system by unifying user and item trust information for B2B applications", *Journal of Computer and System Sciences*, Vol. 81, pp. 1110–1126, 2015.
- [9] F.S. Gohari, H. Haghighi, F.S. Aliee, "A semantic-enhanced trust based recommender system using ant colony optimization", *Applied Intelligence*, Vol. 46, pp. 328–364, 2017.
- [10] Z. Zhang, Y. Liu, Z. Jin, R. Zhang, "A dynamic trust based two-layer neighbor selection scheme towards online recommender systems", *Neurocomputing*, Vol. 285, pp. 94–103, 2018.
- [11] F.S. Gohari, F.S. Aliee, H. Haghighi, "A New Confidence-Based Recommendation Approach: Combining Trust and Certainty", *Information Sciences*, Vol. 422, pp. 21–50, 2018.
- [12] F.S. Gohari, M.J. Tarokh, "Classification and Comparison of the Hybrid Collaborative Filtering Systems", *International Journal of Research in Industrial Engineering*, Vol. 4, pp. 129–148, 2017.
- [13] J. O'Donovan, B. Smyth, "Trust in recommender systems", in: *Proceedings of the 10th International Conference on Intelligent User Interfaces*, ACM, pp. 167–174, 2005.
- [14] C.-S. Hwang, Y.-P. Chen, "Using trust in collaborative filtering recommendation", in: *New Trends in Applied Artificial Intelligence*, Springer, pp. 1052–1060, 2007.
- [15] Q. Shambour, J. Lu, "A trust-semantic fusion-based recommendation approach for e-business applications", *Decision Support Systems*, Vol. 54, pp. 768–780, 2012.
- [16] C.-H. Lai, D.-R. Liu, C.-S. Lin, "Novel personal and

در این مقاله، رویکرد جدیدی پیشنهاد داده شد که با در نظر داشتن زمینه معنایی اقلام، روابط اعتماد میان کاربران را به صورت محلی و سراسری استنتاج می‌نماید. این رویکرد در دو مرحله برون‌خط و برخط کار می‌کند. در مرحله برون‌خط، خوشه‌بندی معنایی اقلام صورت می‌گیرد، و در مرحله برخط، پیشنهادها مناسب برای کاربران تولید می‌شود. برای این منظور، ابتدا روابط اعتماد محلی و سراسری وابسته به زمینه ساخته می‌شود. سپس، همسایگان محلی و سراسری در زمینه هدف شناسایی شده و بر مبنای نظرات آن‌ها پیش‌بینی‌های محلی و سراسری تولید می‌شود. در نهایت این پیش‌بینی‌ها با استفاده از یک معیار تنکی وزندهی شده و با ترکیب خطی آن‌ها، پیش‌بینی نهایی ترجیحات کاربر جاری انجام می‌گیرد. نتایج آزمایش‌ها بر روی مجموعه داده Mov-ielens 1M نشان داد که رویکرد پیشنهادی نسبت به رویکردهای کنونی، دقت بالاتری دارد و در مبارزه با مشکلات تنکی و شروع سرد اثربخش‌تر از سایرین است. با توجه به نتایج، میانگین خطای مطلق رویکرد پیشنهادی در مقایسه با رویکردهای CATRA، HUIT و TSF، به طور متوسط به ترتیب ۲/۵٪، ۵/۶٪ و ۶/۸٪ کمتر است. برای کاربران سردآغازی که فاقد هیچ‌گونه امتیازی هستند، تنها رویکردهایی که از مدل اعتماد سراسری بهره می‌برند (یعنی رویکرد پیشنهادی و HUIT)، قادر به تولید پیشنهادها هستند. نتایج به دست آمده برای این کاربران نشان داد که خطای رویکرد پیشنهادی حدوداً ۳/۷٪ کمتر از HUIT است. برای کاربرانی سردآغازی که حداقل یک امتیاز دارند، میانگین خطای مطلق رویکرد پیشنهادی در مقایسه با CATRA، HUIT و TSF، به طور متوسط به ترتیب ۵/۳٪، ۴/۱٪ و ۴/۷٪ کمتر است. همچنین در مواجهه با مشکل تنکی داده‌ها، رویکرد پیشنهادی به طور متوسط بین ۴٪ تا ۸٪ بهتر از رویکردهای مذکور عمل می‌کند.

netnews", in: Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work, ACM, pp. 175–186, 1994.

[24] M. Papagelis, D. Plexousakis, T. Kutsuras, "Alleviating the sparsity problem of collaborative filtering using trust inferences", in: Trust Management, Springer, pp. 224–239, 2005.

[25] W. Yuan, D. Guan, Y.-K. Lee, S. Lee, S.J. Hur, "Improved trust-aware recommender system using small-worldness of trust networks", Knowledge-Based Systems, Vol. 23, pp. 232–238, 2010.

[26] W. Carrer-Neto, M.L. Hernández-Alcaraz, R. Valencia-García, F. García-Sánchez, "Social knowledge-based recommender system. Application to the movies domain", Expert Systems with Applications, Vol. 39, pp. 10990–11000, 2012.

[27] L. Kaufman, P.J. Rousseeuw, Finding groups in data: an introduction to cluster analysis, John Wiley & Sons, 2009.

[28] J. MacQueen, others, "Some methods for classification and analysis of multivariate observations", in: Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Oakland, CA, USA, pp. 281–297, 1967.

[29] D. Anand, K.K. Bharadwaj, "Utilizing various sparsity measures for enhancing accuracy of collaborative recommender systems based on local and global similarities", Expert Systems with Applications, Vol. 38, pp. 5101–5109, 2011.

[30] P. Bedi, R. Sharma, "Trust based recommender system using ant colony for trust computation", Expert Systems with Applications, Vol. 39, pp. 1183–1190, 2012.

group-based trust models in collaborative filtering for document recommendation", Information Sciences, Vol. 239, pp. 31–49, 2013.

[17] F.S. Gohari, F.S. Alike, H. Haghighi, "A trust-aware group recommender system using particle swarm optimization", in: 2017 International Symposium on Computer Science and Software Engineering Conference (CSSE), pp. 80–85, 2017.

[18] P. Massa, P. Avesani, "Trust-aware collaborative filtering for recommender systems", in: On the Move to Meaningful Internet Systems, Springer, pp. 492–508, 2004.

[19] D. Rosaci, "Trust measures for competitive agents", Knowledge-Based Systems, Vol. 28, pp. 38–46, 2012.

[20] G. Guo, J. Zhang, D. Thalmann, A. Basu, N. Yorke-Smith, "From ratings to trust: an empirical study of implicit trust in recommender systems", in: Proceedings of the 29th Annual ACM Symposium on Applied Computing, ACM, pp. 248–253, 2014.

[۲۱] گوهری، ف. س.، شمس‌علی‌ئی، ف.، حقیقی، ح.، "بهبود سیستم‌های توصیه‌گر با بهره‌گیری از روابط اعتماد وابسته به زمینه"، در مجموعه مقالات بیست و سومین کنفرانس ملی سالانه انجمن کامپیوتر ایران، تهران، ۱۳۹۶، <http://csi.org.ir/fa/paper/view/id.۲۴۵۸>.

[22] B. Sarwar, G. Karypis, J. Konstan, J. Riedl, "Item-based collaborative filtering recommendation algorithms", in: Proceedings of the 10th International Conference on World Wide Web, ACM, pp. 285–295, 2001.

[23] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom, J. Riedl, "GroupLens: an open architecture for collaborative filtering of

## جدیدترین کتاب از انتشارات انجمن انفورماتیک ایران منتشر شد!

# کار عمیق

برای تهیه کتاب با دفتر انجمن انفورماتیک ایران

تماس بگیرید ۶۶۴۱۲۸۶۱

## چاپ چهارم

