

تنوع بخشی شخصی سازی شده در سیستم توصیه گر با استفاده از الگوریتم شبیه سازی تبرید دوهدفه

الهه ملک زاده همدانی

گروه مهندسی فناوری اطلاعات - دانشکده مهندسی کامپیوتر - دانشگاه اصفهان - اصفهان - ایران

دانشجوی کارشناسی ارشد تجارت الکترونیکی

پست الکترونیکی: e.malekzadeh@eng.ui.ac.ir

مرجان کاندی*

استادیار گروه مهندسی فناوری اطلاعات - دانشکده مهندسی کامپیوتر - دانشگاه اصفهان - اصفهان - ایران

پست الکترونیکی: kaedi@eng.ui.ac.ir

چکیده

افزایش حجم اطلاعات روی وب، موجب تولید ابزارهایی شد که پیدا کردن اطلاعات مرتبط به کاربران را برای آنها آسان تر کنند. یکی از این ابزارها که امروزه جزء مهمی از سیستم های تجارت الکترونیکی است، سیستم توصیه گر است. طراحی الگوریتم های توصیه معمولاً با هدف بهبود دقت انجام می شود اما ثابت شده که تمرکز روی این معیار به تنهایی برای ساخت یک توصیه گر خوب کافی نیست و توجه به ابعاد دیگر این سیستم ها نیز ضروری است. یکی از معیارهای مهم که در سال های اخیر مورد توجه قرار گرفته، تنوع اقلام لیست توصیه است. افزایش تنوع در توصیه ها منجر به کاهش دقت می شود. مسئله مطرح در این رابطه، میزان مناسب تنوع بخشی به توصیه ها است. از آنجا که نیاز هر کاربر به تنوع با کاربران دیگر متفاوت است، می توان تنوع بخشی را متناسب با نیاز هر کاربر انجام داد. در این پژوهش روشی مبتنی بر شبیه سازی تبرید دوهدفه ارائه می شود که با استفاده از آن می توان برای هر کاربر یک لیست توصیه بهینه بر مبنای دو معیار دقت و تنوع شخصی سازی شده ایجاد کرد. نتایج اجرای روش پیشنهادی روی داده های Movielens و Netflix نشان می دهد که با این روش تنوع بخشی شخصی سازی شده، در ازای حداکثر ۵/۳۵ درصد کاهش دقت نسبت به روش استاندارد، پالایش مشارکتی انجام می شود.

واژه های کلیدی: سیستم توصیه گر، تنوع بخشی، شخصی سازی، شبیه سازی تبرید.

۱. مقدمه

هر روز مقدار زیادی اطلاعات جدید در فضای وب قرار می گیرد و حجم این اطلاعات، پیوسته در حال افزایش است. این حجم انبوه اطلاعات موجب بروز مسئله سربار اطلاعاتی شده است و یافتن محتوای مرتبط با نیاز اطلاعاتی کاربر را دشوار کرده است [۱، ۲]. با وجود این مقدار بسیار زیاد اطلاعات، پیدا کردن اطلاعات درست در زمان کم حتی با استفاده از ابزارهای متداول مانند موتورهای جستجو و روش های پالایش اطلاعات، بسیار مشکل است و ابزارهای هوشمندانه تر و شخصی سازی شده تری برای هدایت کاربران به سمت اطلاعات مرتبط با نیازهای آنها لازم است [۳]. در زمینه تجارت الکترونیکی، سیستم های توصیه گر محبوب ترین ابزار برای حل این مسئله هستند. این سیستم ها در حوزه های مختلفی مانند مدیریت دانش، گردشگری، فروشگاه های برخط، شبکه های اجتماعی، سیستم های سلامت الکترونیکی، دولت الکترونیکی و آموزش الکترونیکی به کار گرفته می شوند [۴، ۵]. سیستم های توصیه گر با تحلیل داده هایی که از گذشته یک کاربر در دسترس است، ترجیحات او را استخراج می کنند و اطلاعاتی را به کاربر توصیه می کنند که بیشترین تطبیق را با ترجیحات او دارد [۶-۸]. به عبارت دیگر سیستم توصیه گر به وسیله پیشنهادهای خود

به کاربر کمک می‌کند تا اقلام جدیدی را که قبلاً مشاهده نکرده است، اما مورد علاقه او هست پیدا کند [۹-۱۱]. در یک سیستم توصیه‌گر سه مؤلفه اصلی وجود دارد: (۱) کاربران، (۲) اقلام و (۳) امتیازدهی‌های کاربران به اقلام.

بیشتر پژوهش‌هایی که در حوزه توصیه‌گرها انجام شده متمرکز بر توسعه الگوریتم‌های تخمین امتیازها و بهبود معیارهای اندازه‌گیری دقت^۱ هستند [۱، ۱۰، ۱۲، ۱۳]. در حال حاضر این موضوع به طور گسترده‌ای پذیرفته شده است که پیش‌بینی دقیق اگرچه مهم و ضروری است اما برای ساخت یک توصیه‌گر خوب کافی نیست [۱، ۳، ۱۱، ۱۴-۱۹]. توصیه‌گرهایی را که تنها بر معیار دقت تمرکز دارند، اصطلاحاً «دقت-محور»^۲ می‌نامند [۱۰]. توصیه‌گرهای دقت-محور با مشکلاتی مواجه می‌شوند که پژوهشگران در سال‌های اخیر به آن‌ها پرداخته‌اند. روش‌های متداول این نوع سیستم‌ها بر مبنای شباهت کار می‌کنند. در این سیستم‌ها، تمرکز بیش از حد روی شباهت، نوعی افزونگی ایجاد می‌کند که منجر به توصیه اقلام مشابه یا تکراری خواهد شد [۳، ۲۰]. به همین دلیل یکی از راه‌های حل این مشکل، توجه به معیار دیگری به نام تنوع^۳ است که به صورت متضاد شباهت تعریف می‌شود [۲۱]. میزان عدم شباهت اقلام موجود موجود در لیست توصیه به منزله متنوع بودن آن‌ها خواهد بود. تعدادی از پژوهشگران روش‌های جدیدی به منظور افزایش میانگین تنوع لیست‌های توصیه ارائه کرده‌اند [۱، ۳، ۱۵، ۱۷، ۱۸].

مطالعات نشان داده‌اند که بین تنوع و دقت، موازنه^۴ وجود دارد و با افزایش یکی از آن‌ها، دیگری کاهش می‌یابد [۱، ۳، ۱۵، ۱۷، ۲۲، ۲۳]. به همین دلیل همراه با افزودن معیار تنوع به الگوریتم توصیه، لازم است دقت نیز در سطح متعادلی نگاه داشته شود. به همین منظور در بسیاری از پژوهش‌ها که در رابطه با تنوع‌بخشی انجام شده، سطح تنوع بر مبنای میزان تأثیری که بر دقت سیستم توصیه‌گر می‌گذارد تعیین شده است. اما در این پژوهش‌ها یک روال ثابت برای تنوع‌بخشی به توصیه‌ها برای همه کاربران به کار گرفته شده است؛ در حالیکه می‌توان میزان تنوع در هر لیست توصیه را مطابق با ترجیحات کاربری که آن را دریافت می‌کند، تنظیم کرد. در واقع معیار تنوع را می‌توان به صورت یک معیار «کاربر-محور» [۱۶] تعریف کرد. با این کار تنوع‌بخشی به صورت شخصی‌سازی شده یعنی بر مبنای نیازها و تمایلات کاربر انجام می‌شود. در تعدادی از پژوهش‌ها نیز ثابت شده است که کاربرانی که نیازها و علاقه‌های متفاوتی دارند، خواستار سطح متفاوتی از تنوع در توصیه‌ها نیز هستند [۱۳، ۲۴-۲۷]. بنابراین می‌توان گفت در صورتی که تنوع‌بخشی به توصیه‌ها بر مبنای نیازهای فردی کاربران انجام شود، رضایت کاربر از سیستم افزایش خواهد یافت. در این پژوهش‌ها روش‌هایی برای تنوع‌بخشی به صورت شخصی‌سازی شده پیشنهاد شده است. موضوعی که در چند سال اخیر به آن توجه شده است این است که محاسبه میزان تنوع‌گرایی کاربران بر اساس خصوصیات اقلام انجام شود و تنوع‌بخشی به لیست توصیه بر مبنای خصوصیات اقلام صورت گیرد. با این حال تحقیق در این زمینه هنوز در مراحل ابتدایی خود قرار دارد [۲۸]. تنوع خصوصیات اقلام به این معنی است که هر قلم کالا به صورت مجموعه‌ای از خصوصیات در نظر گرفته شود و تنوع لیست توصیه برای هر خصوصیت به طور مجزا محاسبه شود. در این دیدگاه این موضوع در نظر گرفته می‌شود که یک کاربر ممکن است برای هر یک از خصوصیات به سطح متفاوتی از تنوع گرایش داشته باشد. در پژوهش‌های پیشین برای شخصی‌سازی تنوع از روش‌های مختلفی استفاده شده است که در بخش دوم مرور خواهند شد. یکی از معیارهایی که در این پژوهش‌ها برای تنظیم درجه تنوع لیست توصیه به کار رفته است، آنتروپی شانون است. در پژوهش‌های گذشته [۱۳، ۲۸] از این معیار برای دسته‌بندی کاربران استفاده شده است و این دسته‌بندی مبنای تنوع‌بخشی به لیست توصیه کاربران قرار گرفته است اما در این پژوهش‌ها آنتروپی ترجیحات کاربر به طور مستقیم مبنای تنوع لیست توصیه قرار نگرفته است. در پژوهش پیش رو، به موضوع شخصی‌سازی تنوع خصوصیات اقلام لیست توصیه پرداخته می‌شود و راهکار جدیدی با رویکرد بهینه‌سازی چندهدفه^۵ پیشنهاد می‌گردد. هدف این است که نشان داده شود آنتروپی ترجیحات کاربر می‌تواند معیاری برای تنظیم درجه تنوع لیست توصیه باشد و بهینه‌سازی چندهدفه روش مناسبی برای کنترل همزمان دقت و تنوع لیست توصیه خواهد بود. بنابراین در روش پیشنهادی، تنوع لیست توصیه به طور مستقیم با مقدار آنتروپی ترجیحات کاربر تعیین می‌شود. با توجه به این که

¹ Accuracy

² Accuracy-centric

³ Diversity

⁴ Trade-off

⁵ Multi-objective optimization

روش شبیه‌سازی تبرید^۶ در بسیاری از مسائل بهینه‌سازی نتایج بسیار خوبی ارائه می‌کند و تاکنون نیز توسط پژوهشگران حوزه سیستم‌های توصیه‌گر به کار گرفته نشده است، راهکار پیشنهادی این پژوهش بر اساس این روش طراحی می‌شود. لازم به ذکر است که در این پژوهش، هدف افزایش تنوع لیست توصیه نیست، بلکه هدف این است که میزان تنوع لیست توصیه با آنتروپی ترجیحات کاربر - که نشان‌دهنده سطح مطلوب تنوع فردی است - متناسب شود. به دلیل وجود موازنه بین دقت و تنوع، با تغییراتی که در تنوع ایجاد می‌شود دقت نیز تحت تاثیر قرار خواهد گرفت. بنابراین لازم است میزان افت دقت روش پیشنهادی نسبت به روش پایه سنجیده شود. به این منظور دقت الگوریتم با روش استاندارد پالایش مشارکتی مقایسه خواهد شد. نتایج ارزیابی‌ها با استفاده از مجموعه داده‌های MovieLens و Netflix نشان می‌دهد که با استفاده از این روش می‌توان با حداکثر ۵/۳۵ درصد افت دقت نسبت به روش استاندارد پالایش مشارکتی، شخصی‌سازی تنوع لیست توصیه را انجام داد. این در حالی است که تنوع‌بخشی بدون شخصی‌سازی افت بیشتری در دقت ایجاد خواهد کرد [۱، ۱۳، ۱۵، ۲۸]. در واقع همواره با افزایش تنوع، دقت کاهش می‌یابد، اما مطالعات نشان داده است که وقتی تنوع‌بخشی به صورت شخصی‌سازی شده انجام شود، کمتر موجب افت دقت می‌گردد و هر چه شخصی‌سازی موفقیت‌آمیزتر انجام شود، افت کمتری در دقت ایجاد خواهد کرد [۱۳]. بنابراین تنوع شخصی‌سازی شده و دقت با هم رابطه مستقیم دارند. به بیان دیگر با شخصی‌سازی تنوع می‌توان دقت و تنوع را در یک جهت قرار داد و شخصی‌سازی تنوع می‌تواند راه حلی برای مسئله موازنه دقت و تنوع باشد. در این پژوهش نیز این موضوع نشان داده می‌شود که وقتی تنوع لیست توصیه متناسب با آنتروپی ترجیحات کاربر باشد، کمتر موجب افت دقت خواهد شد.

در ادامه، ابتدا در بخش دوم پژوهش‌های پیشین مرور خواهند شد. سپس در بخش سوم روش پیشنهادی معرفی می‌شود و در بخش چهارم این روش مورد ارزیابی قرار خواهد گرفت. در پایان نیز در بخش پنجم به نتیجه‌گیری و جمع‌بندی پرداخته می‌شود.

۲. پیشینه تحقیق

در کارهای پیشین، پژوهش‌های متعددی در زمینه تنوع‌بخشی به توصیه‌ها انجام شده است. در اکثر این پژوهش‌ها برای همه کاربران راهکار ثابتی به منظور تنوع‌بخشی به کار گرفته شده است و حد مطلوب تنوع در توصیه‌ها تنها بر اساس میزان تأثیری که بر افت دقت می‌گذارد به دست می‌آید [۳، ۱۵، ۱۷، ۱۸، ۲۰]. به عنوان مثال در پژوهشی با تعریف رابطه‌ای که شباهت و تنوع اقلام لیست توصیه را به طور همزمان مورد توجه قرار می‌دهد سعی شده است موازنه بین دقت و تنوع بهینه شود [۱۷]. در پژوهش دیگری اقلام با استفاده از رده‌بندی موضوعی تفکیک شده‌اند و روشی ارائه شده است که با استفاده از آن، اقلامی برای لیست توصیه انتخاب شوند که به دسته‌های گوناگونی تعلق دارند [۱۵]. در تعدادی از پژوهش‌ها نیز از الگوریتم ژنتیک برای بهینه کردن دقت، تنوع و معیارهای دیگر استفاده شده است [۲۹-۳۲]. در تعداد کمی از پژوهش‌ها به این موضوع نیز توجه شده است که حد مطلوب تنوع در توصیه‌ها به میزان گرایش و نیاز کاربر به تنوع نیز وابسته است. شی^۷ و همکارانش در پژوهش خود روشی برای متناسب کردن سطح تنوع توصیه‌ها با موقعیت و نیاز کاربر ارائه کردند [۲۵]. در روش پیشنهادی آن‌ها میزان عدم قطعیت ترجیحات کاربر با استفاده از واریانس عوامل پنهان کاربر به دست می‌آید و بر مبنای میزان عدم قطعیت اطلاعات مربوط به کاربر و محدوده علاقه‌مندی‌های او، درجه تنوع در توصیه‌ها به دست می‌آید. نتایج نشان داد که با این روش می‌توان میزان نیاز کاربر به تنوع را به دست آورد. چن^۸ و همکارانش ارتباط بین شخصیت کاربران و نیاز آن‌ها به تنوع را مورد مطالعه قرار دادند [۲۴، ۲۷، ۳۳]. آن‌ها نشان دادند که برخی از ابعاد شخصیتی، تاثیر قابل توجهی روی گرایش‌های کاربران به تنوع توصیه‌ها دارند و می‌توان با استفاده از مدل پنج عامل بزرگ شخصیتی، ویژگی‌های شخصیتی افراد را به یک عدد به عنوان سطح نیاز کاربر به تنوع نگاشت کرد. نظرات کاربران نشان داد که ترکیب این اطلاعات با ترجیحات کاربر موجب می‌شود که توصیه‌ها نسبت به روش معمول پالایش مشارکتی^۹ و همچنین روش‌های استاندارد تنوع‌بخشی [۱۵، ۲۰] بسیار بیشتر مورد قبول کاربران واقع شوند. در پژوهشی دیگر که توسط دی‌نویا^{۱۰} و همکارانش انجام شد، مدلی از تمایلات کاربر به انتخاب اقلام متنوع‌تر

⁶ Simulated annealing

⁷ Shi

⁸ Chen

⁹ روش پالایش مشارکتی یکی از محبوب‌ترین و متداول‌ترین الگوریتم‌های توصیه است که در آن تخمین امتیازها بر مبنای شباهت امتیازدهی‌های کاربران به اقلام به دست می‌آید.

¹⁰ Di Noia

ارائه شد [۱۳]. در روش پیشنهادی آن‌ها، تمایل کاربر به تنوع هر یک از ویژگی‌های اقلام از طریق آنتروپی شانون محاسبه شد و کاربران بر اساس آنتروپی و طول پروفایل به چهار دسته تقسیم شدند. نتایج نشان داد که این پارامتر می‌تواند تعیین‌کننده میزان تنوع‌گرایی کاربران باشد. در ادامه در پژوهش دیگری با استفاده از این روش، الگوریتم توصیه‌ای طراحی شد که تنوع‌بخشی در توصیه‌ها را بر مبنای دسته‌ای که کاربر به آن تعلق دارد انجام دهد [۲۸]. نتایج این روش با روش استاندارد پالایش مشارکتی و همچنین با یک روش ثابت تنوع‌بخشی از نظر معیارهای دقت، تنوع فردی، تنوع جمعی و نوآوری مقایسه شد. این مقایسه‌ها نشان داد که تنظیم درجه تنوع توصیه‌ها با علاقه‌مندی‌های کاربران کارایی بیشتری نسبت به روش‌های تنوع‌بخشی بدون شخصی‌سازی دارد.

در پژوهش حاضر با تکیه بر دستاوردهای پژوهش دی‌نویا و همکارانش [۱۳، ۲۸] روشی ارائه خواهد شد که با استفاده از آن بتوان میزان تنوع خصوصیات اقلام لیست توصیه هر کاربر را به سطح تنوع‌گرایی آن کاربر نزدیک کرد و ضمن کمینه کردن فاصله آنتروپی ترجیحات کاربر با تنوع لیست توصیه، دقت نیز تا حد امکان بیشینه شود. در این پژوهش بر خلاف روشی که دی‌نویا و همکاران ارائه کردند از دسته‌بندی کاربران استفاده نشده است بلکه برای هر کاربر مقدار آنتروپی به طور مستقیم مبنای تنوع‌بخشی قرار می‌گیرد. نکته دیگری که در پژوهش‌های پیشین این حوزه به آن پرداخته نشده است، تغییرات احتمالی میزان گرایش کاربر به تنوع است. از آنجا که علاقه‌مندی‌های یک کاربر ممکن است در طول زمان با به دست آوردن اطلاعات جدید یا به سبب تغییر نیازها و موقعیت او تغییر کند [۳۴، ۳۵]، میزان آنتروپی کاربر که از ترجیحات کاربر به دست می‌آید نیز تغییر خواهد کرد. این نکته در پژوهش پیش رو در نظر گرفته خواهد شد. به این منظور، هنگام به دست آوردن آنتروپی موثر کاربران، تاثیر گذشت زمان بر تغییرات آنتروپی با استفاده از داده‌های بلندمدت و کوتاه‌مدت نیز در نظر گرفته خواهد شد.

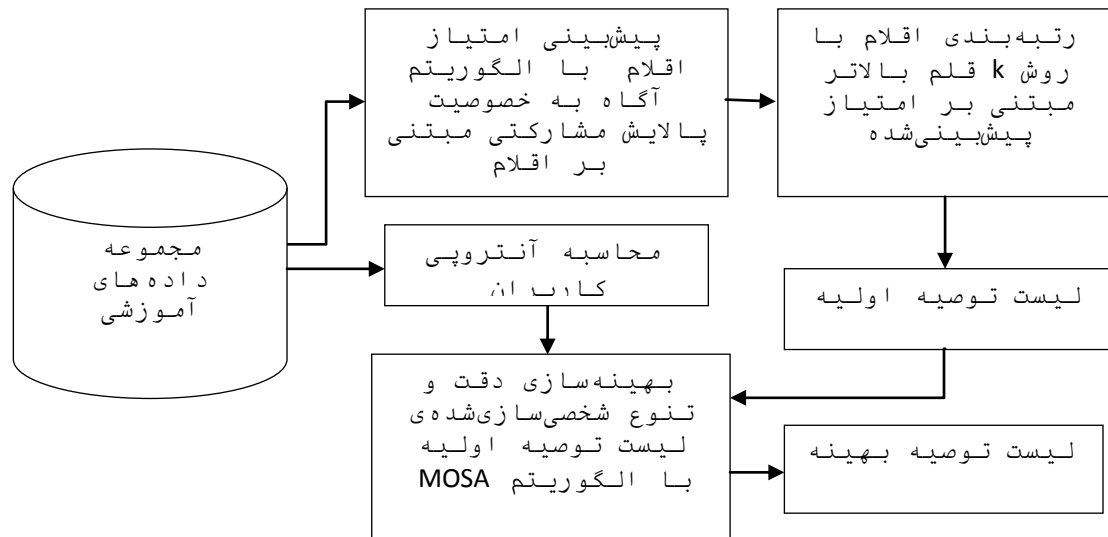
۳. راهکار پیشنهادی

عمل توصیه در توصیه‌گرها معمولاً شامل دو مرحله است [۱۴]: مرحله اول، پیش‌بینی امتیازهای اقلامی است که کاربر به آن‌ها امتیازی نداده است و مرحله دوم، پیدا کردن اقلامی است که بیشترین سودمندی را برای کاربر دارند. این اقلام انتخابی، لیست توصیه نامیده می‌شوند. زمانی که هدف الگوریتم توصیه‌گر تنها بهبود دقت باشد معمولاً روی مرحله اول تمرکز می‌شود. اما در پژوهش‌هایی که بر بهینه کردن معیارهایی غیر از دقت تاکید دارند، تمرکز روی مرحله دوم است. در پژوهش حاضر نیز به منظور کنترل تنوع در توصیه‌ها تمرکز اصلی بر روی مرحله دوم عمل توصیه است. در ادامه این بخش، چگونگی انجام دو مرحله مذکور، یعنی پیش‌بینی امتیاز و به دست آوردن لیست توصیه در روش پیشنهادی معرفی می‌شوند. شکل ۱ نیز چارچوب روش پیشنهادی را نشان می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، ابتدا پیش‌بینی امتیاز اقلام انجام می‌شود. سپس اقلام بر مبنای امتیاز پیش‌بینی شده رتبه‌بندی می‌شوند و k قلم بالاتر آن به عنوان لیست توصیه اولیه انتخاب می‌شوند. برای بهینه‌سازی لیست توصیه اولیه، با استفاده از الگوریتم شبیه‌سازی تبرید چندهدفه (MOSA) دو هدف دقت و تنوع شخصی‌سازی شده بهینه‌سازی می‌شوند. به منظور شخصی‌سازی تنوع از آنتروپی ترجیحات کاربر استفاده می‌شود. خروجی الگوریتم MOSA لیست توصیه نهایی را ایجاد خواهد کرد.

۳-۱ پیش‌بینی امتیاز اقلام

در این پژوهش، به منظور بهره بردن از مزایای دو روش مبتنی بر محتوا و پالایش مشارکتی، از یک رویکرد ترکیبی استفاده شده است. در رویکرد ترکیبی پیشنهادی، شباهت اقلام با ترکیب روش‌های مبتنی بر محتوا و پالایش مشارکتی به دست می‌آید. به این صورت که ابتدا با روش مبتنی بر محتوا، شباهت اقلام بر مبنای خصوصیات آن‌ها به دست می‌آید. سپس با روش پالایش مشارکتی مبتنی بر قلم کالا، مقدار دیگری برای شباهت اقلام بر مبنای امتیازدهی‌های کاربران به دست می‌آید. سپس این دو مقدار با ضریب یکسان با یکدیگر جمع می‌شوند و مقدار شباهت نهایی به دست می‌آید. این روش، پالایش مشارکتی مبتنی بر قلم کالای آگاه به خصوصیت^{۱۱} نامیده می‌شود [۳۶].

¹¹ Attribute-aware item-based collaborative filtering



شکل ۱: چارچوب روش پیشنهادی

پیش‌بینی امتیاز طی دو مرحله زیر انجام می‌شود:

(۱) محاسبه شباهت اقلام: ابتدا شباهت هر یک از اقلام داده‌های آزمایشی به سایر اقلام موجود در داده‌های آموزشی و آزمایشی محاسبه می‌شود. شباهت مبتنی بر محتوا بر اساس میزان شباهت اقلام از نظر خصوصیات آن‌ها به دست می‌آید. در این روش هر قلم کالا به عنوان یک بردار از خصوصیات در نظر گرفته می‌شود و فاصله این دو بردار به دست می‌آید. برای به دست آوردن این فاصله روش‌هایی که در بازبایی اطلاعات وجود دارد استفاده می‌شود که از بین آن‌ها روش شباهت کسینوسی متداول‌تر است [۳۶-۳۸]. نحوه محاسبه آن در رابطه (۱) نشان داده شده است.

$$\text{sim}_{\text{attributes}}(i, j) = \frac{\bar{D}_i \cdot \bar{D}_j}{|\bar{D}_i| |\bar{D}_j|} \quad (1)$$

در این رابطه \bar{D}_i و \bar{D}_j نشان‌دهنده بردار خصوصیات اقلام i و j هستند. به این صورت که خصوصیات به صورت دودویی تعریف می‌شوند و اگر یک قلم کالا دارای خصوصیت a باشد مقدار آن در بردار خصوصیات آن قلم کالا برابر با یک، و در غیر این صورت صفر قرار داده می‌شود. در صورت کسر، ضرب داخلی این دو بردار قرار داده شده است و مخرج کسر شامل حاصل ضرب اندازه‌های این دو بردار است.

محاسبه شباهت با استفاده از پالایش مشارکتی مبتنی بر قلم کالا نیز با روش کسینوسی اصلاح شده [۳۹]^{۱۲} طبق رابطه (۲) انجام می‌شود. این روش بین روش‌های محاسبه شباهت در الگوریتم پالایش مشارکتی از محبوبیت و مقبولیت ویژه‌ای برخوردار است [۳۹].

$$\text{sim}_{\text{ratings}}(i, j) = \frac{\sum_{u \in U} (R_{u,i} - \bar{R}_u)(R_{u,j} - \bar{R}_u)}{\sqrt{\sum_{u \in U} (R_{u,i} - \bar{R}_u)^2} \sqrt{\sum_{u \in U} (R_{u,j} - \bar{R}_u)^2}} \quad (2)$$

در این رابطه، $R_{u,i}$ امتیاز کاربر u به قلم کالای i و \bar{R}_u میانگین امتیازهای کاربر u است.

در پایان، جمع وزندار دو مقدار $\text{sim}_{\text{ratings}}$ و $\text{sim}_{\text{attributes}}$ به عنوان مقدار شباهت نهایی از طریق رابطه (۳) محاسبه می‌شود [۳۶]. در این رابطه λ تعیین‌کننده وزن مقادیر مذکور است و مقدار آن می‌تواند بین صفر تا یک باشد. به منظور این‌که دو روش مبتنی بر محتوا و پالایش مشارکتی تاثیر یکسانی در نتیجه داشته باشند این مقدار برابر 0.5 در نظر گرفته شده است. انتخاب مقادیر مختلف برای λ ممکن است روی دقت پیش‌بینی تاثیرگذار باشد. اگرچه دقت پیش‌بینی روی دقت الگوریتم‌های توصیه تاثیرگذار است، اما از آنجا که همه روش‌های مورد مقایسه در این پژوهش بر پایه یک روش طراحی شده‌اند، دقت الگوریتم‌ها نیز به یک میزان تحت تاثیر دقت پیش‌بینی قرار خواهند گرفت. بنابراین تاثیری در مقایسه نهایی نخواهد داشت.

$$\text{Sim}_{\text{combined}} = (1 - \lambda) \text{sim}_{\text{ratings}} + \lambda \text{sim}_{\text{attributes}}, \lambda \in [0, 1] \quad (3)$$

¹² Adjusted cosine similarity

۲ تخمین امتیاز کاربر به اقلام: پس از محاسبه شباهت اقلام، با استفاده از اقلامی که شباهت بیشتری به هر قلم کالا دارند امتیاز آن قلم کالا تخمین زده می‌شود. این کار با روش جمع وزن دار [۳۶, ۳۹] انجام می‌شود. برای تخمین امتیاز کاربر به قلم کالای i ابتدا n قلم کالایی که شباهت بیشتری به آن قلم کالا دارند انتخاب می‌شوند. شباهت هر قلم کالا به قلم کالای i به عنوان وزن در رابطه (۴) در نظر گرفته می‌شود. سپس با قرار دادن امتیاز n قلم کالا در این رابطه، مقدار امتیاز پیش‌بینی شده برای قلم کالای مورد نظر به دست می‌آید.

$$P_{u,i} = \frac{\sum_{\text{all similar items } N} (s_{i,N} * R_{u,N})}{\sum_{\text{all similar items } N} (s_{i,N})} \quad (4)$$

پس از پیش‌بینی امتیاز اقلام، لیست توصیه اولیه با روش استاندارد پالایش مشارکتی [۲۲] به دست می‌آید. ابتدا اقلام بر مبنای امتیاز پیش‌بینی شده به طور نزولی مرتب می‌شوند و سپس k قلم بالای آن انتخاب می‌شود.

۳-۲ به دست آوردن لیست بهینه

در این بخش که نوآوری اصلی این پژوهش را در بر دارد، دو هدف اصلی دنبال می‌شود. یکی تنوع‌بخشی شخصی‌سازی شده و دیگری کنترل موازنه دقت و تنوع. این دو هدف در ادامه توضیح داده خواهد شد. سپس الگوریتم شبیه‌سازی تبرید چندهدفه که برای برآورده کردن این دو هدف استفاده خواهد شد، توضیح داده می‌شود و در نهایت، چگونگی استفاده از این الگوریتم برای به دست آوردن لیست توصیه شرح داده خواهد شد.

۳-۲-۱ هدف اول: تنوع‌بخشی شخصی‌سازی شده

در بخش دوم پژوهش‌هایی که به موضوع تنوع‌بخشی شخصی‌سازی شده پرداخته‌اند مرور شدند. در این پژوهش با تکیه بر رویکرد دی‌نویا و همکارانش [۱۳] که در بخش ۲ توضیح داده شد، از آنتروپی شانون برای تعیین میزان تنوع مورد نیاز کاربر استفاده خواهد شد. تنوع توصیه‌ها را به دو شیوه می‌توان محاسبه کرد [۱۳, ۲۴]: (۱) تنوع خصوصیات اقلام، که در آن شباهت اقلام به یکدیگر بر اساس شباهت خصوصیات آن‌ها به دست می‌آید و سپس تنوع بر مبنای این نوع شباهت محاسبه می‌شود و (۲) تنوع کلی اقلام، که در آن هر قلم کالا به صورت یک موجودیت مستقل و واحد در نظر گرفته می‌شود و شباهت و تنوع بدون توجه به خصوصیات اقلام به دست می‌آید. همان‌طور که در بخش ۱ توضیح داده شد در این پژوهش از شیوه اول استفاده می‌شود و برای به دست آوردن میزان علاقه فرد به تنوع در توصیه‌ها، آنتروپی خصوصیات اقلام از طریق رابطه (۵) محاسبه می‌گردد [۱۳].

$$\mathcal{H}_a(u) = - \sum_{v=1}^k p_v \cdot \log_x p_v \quad (5)$$

در این رابطه، \mathcal{H}_a آنتروپی خصوصیت a برای کاربر u است، k تعداد مقادیر ممکن برای خصوصیت a است و تعداد امتیازدهی‌های کاربر به اقلامی که شامل مقدار v برای خصوصیت a هستند نسبت به کل امتیازدهی‌های او، به عنوان p_v محاسبه می‌شود. از این طریق، برای هر کاربر آنتروپی هر یک از خصوصیات اقلام به دست می‌آید. اگرچه تمایلات یک کاربر ممکن است وابسته به شخصیت کاربر باشد و شخصیت کاربر در طول زمان تغییر چشمگیری نخواهد داشت، اما ممکن است عوامل متغیری نیز بر تمایل او نسبت به پذیرش توصیه‌ها تاثیرگذار باشند. علاقه‌مندی‌های یک فرد ممکن است در طول زمان با به دست آوردن اطلاعات یا تجربیات جدید یا به سبب تغییر نیازها و موقعیت او تغییراتی داشته باشد. در برخی پژوهش‌ها نیز بر این موضوع که علاقه‌مندی‌های کاربر دو بخش ثابت و متغیر دارد تکیه شده است [۳۴, ۳۵]. بخش ثابت اطلاعات با استفاده از داده‌های بلندمدت^{۱۳} و بخش متغیر اطلاعات با داده‌های کوتاه‌مدت^{۱۴} به دست می‌آید. در این پژوهش نیز سعی می‌شود که تغییرات احتمالی علاقه فرد به تنوع در طول زمان در نظر گرفته شود. به این منظور برای به دست آوردن گرایش کاربر به تنوع از جمع وزن دار آنتروپی‌های ماهانه او استفاده شده است. وزن‌دهی به آنتروپی‌ها به نحوی انجام شده است که اطلاعات اخیر تاثیر بیشتری روی محاسبات داشته باشد.

برای متناسب کردن تنوع لیست توصیه با آنتروپی ترجیحات کاربر، درصد آنتروپی به دست آمده برای هر کاربر، به عنوان معیاری برای درصد تنوع لیست توصیه شده به او در نظر می‌شود. بنابراین لازم است اقلامی در لیست توصیه قرار گیرند که فاصله تنوع لیست توصیه را با آنتروپی ترجیحات کاربر به حداقل برسانند. یعنی الگوریتم توصیه باید برای هر کاربر لیست توصیه‌ای ایجاد کند که از لحاظ فاصله بین تنوع و آنتروپی، بهینه باشد. از آنجا که آنتروپی برای خصوصیات اقلام محاسبه شده است، برای هماهنگی آن با تنوع لازم است

¹³ Long-term

¹⁴ Short-term

تنوع لیست توصیه نیز بر مبنای خصوصیات اقلام به دست آید. معادله‌ای که معمولاً در پژوهش‌ها [۱۷] برای محاسبه تنوع لیست توصیه استفاده می‌شود در رابطه (۶) آمده است.

$$\text{Diversity}(c_1, \dots, c_n) = \frac{\sum_{i=1}^n \sum_{j=i}^n (1 - \text{similarity}(c_i, c_j))}{\frac{n}{2} * (n-1)} \quad (6)$$

در رابطه بالا، c_1 تا c_n اقلام لیست توصیه هستند و شباهت بین دو قلم کالا با متغیری با نام *Similarity* نشان داده شده است. به منظور به دست آوردن تنوع بر مبنای خصوصیات، به ازای هر یک از خصوصیات اقلام تنوع لیست محاسبه می‌شود. مقدار شباهت در رابطه (۶) با استفاده از رابطه (۱) برای آن خصوصیت به دست می‌آید. سپس به ازای هر یک از خصوصیات، فاصله بین تنوع و آنتروپی کمینه می‌شود. با این کار سطح تنوع لیست توصیه از نظر هر یک از خصوصیات با میزان آنتروپی ترجیحات کاربر در آن خصوصیت تنظیم می‌شود.

۳-۲-۲ هدف دوم: کنترل موازنه دقت و تنوع

برای به دست آوردن لیستی که کمترین فاصله‌ها را بین تنوع و آنتروپی داشته باشد، باید اقلامی را برای تشکیل لیست توصیه انتخاب کرد که به طور همزمان با کمینه کردن این فاصله‌ها دقت لیست توصیه را نیز در حد متعادلی حفظ کنند. در واقع با توجه به موازنه بین دقت و تنوع، هنگامی که تنوع لیست توصیه تغییر می‌کند، ممکن است دقت لیست توصیه نیز تحت تاثیر قرار بگیرد. بنابراین توجه به این دو هدف به طور همزمان لازم است. برای این کار در این پژوهش، روشی بر مبنای بهینه‌سازی پیشنهاد می‌شود. برای این منظور، با استفاده از یک الگوریتم بهینه‌سازی چندهدفه، اقلامی برای لیست توصیه انتخاب می‌شوند که دو هدف را به طور همزمان بهینه کنند.

۳-۲-۳ الگوریتم شبیه‌سازی تبرید چندهدفه

شبیه‌سازی تبرید (SA) یک الگوریتم جستجو است که برای پیدا کردن حداقل هزینه در حل مسائل بهینه‌سازی استفاده می‌شود و می‌تواند راه حل بهینه را به خصوص در مسائل بهینه‌سازی ترکیبی پیدا کند. در این الگوریتم یک متغیر دما وجود دارد که به تدریج کاهش پیدا می‌کند. همچنین یک تابع انرژی وجود دارد که باید در طول فرآیند تبرید به حداقل برسد. در هر تکرار، حالت جدیدی به دست می‌آید که انرژی آن با حالت فعلی مقایسه می‌شود و در صورتی که انرژی کاهش یافته باشد جایگزین حالت فعلی می‌شود. در غیر این صورت احتمال پذیرش آن محاسبه می‌شود و اگر این احتمال از یک عدد تصادفی بزرگتر باشد پذیرفته می‌شود. با کاهش دما احتمال پذیرش راه حل‌های نادرست کمتر می‌شود [۴۰-۴۲]. دو پژوهشگر در پژوهش خود ثابت کردند که اگر فرآیند تبرید به اندازه کافی آهسته انجام شود این الگوریتم به بهینه سراسری همگرا خواهد شد [۴۳].

شبیه‌سازی تبرید برای بهینه کردن یک هدف در حوزه‌های گوناگونی به کار گرفته شده است، اما کارهای کمی برای توسعه این روش برای بهینه‌سازی چند هدف انجام شده است [۴۰]. بیشتر پژوهش‌های مربوط به شبیه‌سازی تبرید چند هدفه، با رویکرد تبدیل چند هدف به یک هدف انجام شده‌اند و معمولاً این تبدیل با استفاده از روش جمع وزن‌دار انجام شده است. یعنی تابع انرژی به صورت جمع وزن‌دار هدف‌ها تعریف می‌شود. اما به دست آوردن وزن‌های مناسب نیز خود یک مسئله است [۴۰، ۴۱]. در تعداد کمی از پژوهش‌ها از رویکرد دیگری مبتنی بر «غلبه»^{۱۵} استفاده شده است [۴۰، ۴۱]. ایده «غلبه» برای مقایسه دو راه حل a و b به این صورت تعریف می‌شود که: اگر برای تمامی هدف‌ها بدتر از $f(b)$ نباشد و حداقل برای یک هدف بهتر باشد گفته می‌شود a بر b غلبه دارد و نوشته می‌شود: $a < b$. پس a بر b غلبه دارد اگر:

$$f_i(a) \leq f_i(b) \quad \forall i = 1, \dots, D$$

$$f_i(a) < f_i(b) \quad \text{حداقل برای یک هدف}$$

یک مجموعه F از راه‌حل‌ها مجموعه «غیر غالب»^{۱۶} خوانده می‌شود اگر هیچ عضوی از آن بر دیگری غلبه نداشته باشد. اگر این مجموعه در کل فضای حالت مسئله به دست آید، یعنی هیچ راه حل ممکن در فضای حالت بر اعضای آن غلبه نداشته باشد، مجموعه «غیر غالب سراسری»^{۱۷} یا «پارتو-بهینه»^{۱۸} نامیده می‌شود [۴۰، ۴۴].

¹⁵ Dominance

¹⁶ Non-dominating

¹⁷ Globally non-dominating

در پژوهشی در سال ۲۰۰۴ یک الگوریتم شبیه‌سازی تبرید چندهدفه با بهره‌گیری از مفهوم غلبه طراحی شد [۴۴]. در سال ۲۰۰۸ در پژوهشی دیگر این روش توسعه داده شد و روشی به نام الگوریتم شبیه‌سازی تبرید چندهدفه بایگانی شده معرفی شد [۴۰]. نتایج اعمال این الگوریتم روی چندین مجموعه داده برای حل چند مسئله بهینه‌سازی معروف، ثابت کرد که این الگوریتم در مقایسه با الگوریتم NSGA-II (که یک روش محبوب مبتنی الگوریتم ژنتیک است) از لحاظ پیچیدگی زمانی و دقت، بهتر عمل می‌کند. به علاوه این الگوریتم راه‌حل‌های متمایزتری نسبت به NSGA-II ارائه می‌کند. متمایز بودن راه‌حل‌ها در بهینه‌سازی چندهدفه یک ویژگی بسیار مطلوب محسوب می‌شود. یک خصوصیت جالب الگوریتم MOSA این است که همواره یک احتمال غیر صفر را برای پذیرش یک راه حل ضعیف محاسبه می‌کند و این موجب می‌شود که روال حل مسئله کمتر حریصانه باشد و از این طریق کارایی آن برای حل مسائل پیچیده بیشتر می‌شود [۴۰]. به همین دلیل در این پژوهش از روش شبیه‌سازی تبرید چندهدفه استفاده می‌شود.

۳-۲-۴ بهینه‌سازی لیست توصیه با استفاده از الگوریتم شبیه‌سازی تبرید چندهدفه

در الگوریتم شبیه‌سازی تبرید یک تابع انرژی وجود دارد که هدف الگوریتم، کمینه کردن آن است. پس مقدار بهینه برای هدف‌هایی که به دنبال آن‌ها هستیم توسط تابع انرژی به دست می‌آید. بنابراین هدف‌ها در این الگوریتم باید به گونه‌ای تعریف شوند که کمینه کردن آن‌ها مطلوب باشد. بنابراین هدف‌هایی که برای حل مسئله این پژوهش در نظر گرفته می‌شوند به شرح زیر است:

- تنوع‌بخشی شخصی‌سازی شده: آنتروپی ترجیحات کاربر برای هر یک از خصوصیات اقلام با استفاده از رابطه (۵) محاسبه می‌شود. تنوع لیست نیز برای هر یک از خصوصیات اقلام با روشی که در رابطه (۶) توضیح داده شد به دست می‌آید. سپس درصد تنوع و درصد آنتروپی با توجه به دامنه تغییرات آن‌ها به دست می‌آید و در نهایت قدر مطلق اختلاف این دو مقدار محاسبه می‌شود. این محاسبات در رابطه (۷) نشان داده شده است.

$$\text{PersonalizedDiv}_a = |\mathcal{H}_a - \text{Diversity}_a| \quad (7)$$

در این رابطه Diversity_a تنوع لیست توصیه بر مبنای خصوصیت a است. $\mathcal{H}_a(i)$ نیز آنتروپی ترجیحات کاربر برای خصوصیت a است. PersonalizedDiv_a نشان‌دهنده میزان شخصی‌سازی تنوع از نظر خصوصیت a است. به ازای هر یک از خصوصیات اقلام، یک هدف شخصی‌سازی تنوع تعریف می‌شود.

- دقت: برای سنجیدن میزان دقت لیست به دست آمده در هر تکرار الگوریتم شبیه‌سازی تبرید، از مجموع امتیاز پیش‌بینی شده اقلام موجود در لیست استفاده شده است. از آنجا که در الگوریتم شبیه‌سازی تبرید باید تابع انرژی کمینه شود، لازم است هدفی تعریف شود که با کمینه شدن آن دقت افزایش یابد. به این منظور از رابطه (۸) استفاده شده است. این رابطه، عکس مجموع امتیازهای پیش‌بینی شده اقلام لیست توصیه را محاسبه می‌کند.

$$\text{Accuracy} = \frac{1}{\sum_{\text{item}=1}^k \text{Prediction}(\text{item})} \quad (8)$$

ورودی الگوریتم MOSA لیست توصیه اولیه است که با روش استاندارد پالایش مشارکتی به دست آمده است. در این الگوریتم، مجموعه جواب تولید شده شامل یک عضو است که به عنوان جواب نهایی، یعنی لیست توصیه بهینه در نظر گرفته می‌شود. مراحل این الگوریتم در ادامه توضیح داده می‌شود.

ابتدا لیست توصیه به دست آمده با روش استاندارد پالایش مشارکتی، به عنوان حالت فعلی در نظر گرفته می‌شود و current-st نامیده می‌شود.

تا زمانی که دما بیشتر از دمای کمینه است مراحل زیر انجام می‌شود:

- یک حالت جدید تصادفی از همسایگی current-st انتخاب می‌شود و در new-st قرار می‌گیرد.
- وضعیت غلبه new-st و current-st بررسی می‌شود و یکی از دو حالت زیر اتفاق می‌افتد:
 - اگر new-st بر current-st غلبه داشت، new-st در current-st قرار داده می‌شود.
 - در غیر این صورت، احتمال پذیرش new-st با استفاده از رابطه $1/(1 + \exp(\Delta \text{dom}_{\text{new-st,current-st}} * \text{temperature}))$ دلتا یا اختلاف تابع انرژی برای

new-st و current-st به صورت حاصل ضرب تفاضل مقدار دو هدف معرفی شده در رابطه‌های (۷) و (۸) به دست می‌آید. روش محاسبه دلتا از رابطه (۹) به دست می‌آید. اگر احتمال به دست آمده، از یک عدد تصادفی بین صفر و یک بیشتر باشد، new-st پذیرفته می‌شود و در current-st قرار داده می‌شود.

۴. ارزیابی روش پیشنهادی

در این بخش روش پیشنهادی مورد ارزیابی قرار می‌گیرد. در ابتدا مجموعه داده‌های مورد استفاده معرفی می‌شوند. سپس معیارهای ارزیابی و نتایج عملی توضیح داده می‌شوند.

۴-۱ مجموعه داده‌ها

برای بررسی روش پیشنهادی از ترکیب دو مجموعه داده MovieLens [۴۵] و Netflix [۴۶] استفاده شده است. داده‌های مربوط به خصوصیات اقلام از مجموعه داده MovieLens و داده‌های مربوط به امتیازهای کاربران از Netflix به دست آمده است. مجموعه داده Netflix به این دلیل مورد استفاده این پژوهش قرار گرفت که شامل امتیازدهی‌های هر کاربر در طی مدت زمان طولانی است. این ویژگی به منظور به دست آوردن میانگین و تغییرات آنروپی کاربر در طول زمان مورد نیاز است. مجموعه داده MovieLens نیز به دلیل دارا بودن خصوصیات اقلام مانند سبک^{۱۹} فیلم و سال تولید آن برای محاسبه آنروپی کاربران و شباهت فیلم‌ها به ازای هر یک از خصوصیات، مورد نیاز است [۳۶]. پس از ترکیب بخشی از این دو مجموعه داده، مجموعه داده جدیدی به دست آمد که شامل ۸۳۶ قلم کالا، ۴۴۴۰۵۱ کاربر و ۹۰۳۹۶۶۸ امتیاز که توسط این کاربران به اقلام داده شده است. داده‌ها مربوط به سال‌های ۱۹۹۹ تا ۲۰۰۵ است. داده‌ها به دو قسمت داده‌های آموزشی و آزمایشی تقسیم شده‌اند. امتیازهایی که مربوط به سال ۲۰۰۲ و قبل از آن است در داده‌های آموزشی و امتیازهایی که مربوط به سال ۲۰۰۳ و بعد از آن هستند در داده‌های آزمایشی قرار گرفتند.

۴-۲ معیارهای ارزیابی

در این پژوهش دو هدف برای توصیه‌گر وجود دارد: (۱) نزدیک کردن تنوع لیست به میزان تنوع‌گرایی فرد و (۲) جلوگیری از کاهش بیش از حد دقت. با توجه به اهداف گفته شده، معیارهایی برای ارزیابی روش پیشنهادی در نظر گرفته می‌شود که در ادامه توضیح داده می‌شوند.

۴-۲-۱ معیار اندازه‌گیری تنوع شخصی‌سازی شده

در روش پیشنهادی برای شخصی‌سازی تنوع از آنروپی ترجیحات کاربر استفاده شده است و هدف، کمینه کردن فاصله تنوع لیست با آنروپی ترجیحات کاربر است. به همین دلیل برای سنجش میزان کارایی الگوریتم در مورد شخصی‌سازی تنوع، معیار $PrDiversity$ تعریف شده است. این معیار در رابطه (۹) نشان داده شده است.

$$PrDiversity = \frac{1}{n} \sum_{i=1}^n |\mathcal{H}_{genre}(i) - Diversity_{genre}(list_i)| \quad (9)$$

در این رابطه n تعداد کاربرانی است که در یک دور اجرای الگوریتم توصیه‌گر به آن‌ها توصیه ارائه شده و $list_i$ لیستی است که در این دور به کاربر i توصیه شده است. $Diversity_{genre}(list_i)$ تنوع لیست توصیه شده به کاربر i از نظر خصوصیت سبک فیلم و $\mathcal{H}_{genre}(i)$ آنروپی کاربر i برای این خصوصیت است. در این رابطه تنوع از رابطه (۶) و آنروپی از رابطه (۵) به دست می‌آید. این معیار نشان می‌دهد که به طور میانگین، فاصله تنوع لیست با آنروپی کاربر چقدر است. از آنجا که مقادیر کمتر این معیار نشان‌دهنده مطلوبیت نتیجه است، در ارزیابی‌ها معکوس آن یعنی $1/PrDiversity$ مد نظر قرار داده شده است که مقادیر بالاتر آن، نشان‌دهنده این باشد که شخصی‌سازی تنوع بهتر انجام شده است. در مجموعه داده مورد استفاده، دو خصوصیت سبک فیلم و سال تولید آن وجود دارد. اما با توجه به این که خصوصیت سال مقادیر گوناگونی دارد، در تنوع‌بخشی از آن استفاده نشده است و تنها از خصوصیت سبک فیلم استفاده می‌گردد.

۴-۲-۲ معیار اندازه‌گیری دقت

در این پژوهش برای محاسبه دقت از معیاری استفاده شده است که معادل با معیار دقت در ارزیابی اطلاعات است و در پژوهش‌های بسیاری مورد استفاده قرار گرفته است [۳۱، ۳۰، ۱]. این معیار، در رده معیارهای اندازه‌گیری دقت دسته‌بندی قرار می‌گیرد و در آن

¹⁹ Genre

تعداد اقلام مرتبط توصیه شده نسبت به کل اقلام توصیه شده محاسبه می شوند. رابطه معیار اندازه گیری دقت دسته بندی در رابطه (۱۰) آمده است.

$$\text{Precision} = \frac{N_{r\bar{s}}}{N_s} \quad (10)$$

در این رابطه N_s تعداد کل اقلام توصیه شده به کاربران است و $N_{r\bar{s}}$ تعداد اقلام مرتبط توصیه شده به کاربران را نشان می دهد. برای استفاده از این معیار، لازم است اقلام به نحوی به دو گروه مرتبط و نامرتب تقسیم شوند. در مجموعه داده مورد استفاده در این پژوهش، امتیازهایی که به اقلام داده شده عددی بین یک تا پنج است. در این پژوهش پیشنهاد می شود که برای هر کاربر، میانگین امتیازهای خود او به عنوان آستانه مرتبط بودن اقلام به آن کاربر در نظر گرفته شود.

علاوه بر معیار بالا، می توان مجموع امتیازهایی را که کاربر به اقلام توصیه شده داده است به عنوان میزان توصیه اقلام مورد علاقه کاربر در نظر گرفت. در واقع با این روش، بدون دسته بندی اقلام به دو دسته مورد مرتبط و نامرتب، میزان علاقه مندی کاربر به اقلام به صورت پیوسته به دست می آید. برای ارزیابی روش پیشنهادی این پژوهش، این معیار به عنوان تکمیل کننده معیار دقت دسته بندی که علاقه مندی کاربر را به صورت گسسته تفسیر می کند، به کار گرفته خواهد شد و «میانگین امتیازها» نامیده می شود.

۳-۴ الگوریتم های مورد ارزیابی

در این بخش به منظور بررسی کارایی راهکار پیشنهادی، دو روش دیگر برای مقایسه در نظر گرفته شده است. جزئیات این روش ها در ادامه توضیح داده خواهد شد و در نهایت نتایج آن ها مقایسه خواهد شد.

۳-۴-۱ روش استاندارد پالایش مشارکتی

روش اول، ساده ترین حالت الگوریتم پالایش مشارکتی است. در این روش اقلام بر حسب امتیاز پیش بینی شده آن ها به طور نزولی مرتب می شوند. سپس k قلم بالای لیست به عنوان لیست توصیه انتخاب می شود. تعداد اعضای لیست مرتب اصلی ۳۰ است. لیست توصیه نیز با تعداد اعضای متفاوتی آزمایش شده است. این روش به اختصار CF نام گذاری می شود.

۳-۴-۲ روش شبیه سازی تبرید تک هدفه

برای بهبود الگوریتم استاندارد پالایش مشارکتی می توان از یک الگوریتم بهینه سازی استفاده کرد. با توجه به این که راهکار پیشنهادی این پژوهش مبتنی بر روش شبیه سازی تبرید است، این الگوریتم به عنوان محک و مقایسه با الگوریتم معمول پالایش مشارکتی به کار گرفته شده است. این الگوریتم با هدف بهبود میزان شخصی سازی تنوع نسبت به الگوریتم توصیه پالایش مشارکتی پیاده سازی شده است. در این الگوریتم لیست اصلی ۳۰ عضوی به عنوان فضای حالت در نظر گرفته می شود. معیاری که در این الگوریتم برای شخصی سازی تنوع تعریف شده، رابطه (۷) است. این روش به اختصار SA-div نام گذاری می شود.

۳-۴-۴ تنظیم پارامترهای روش پیشنهادی

در الگوریتم پیشنهادی چند پارامتر وجود دارد که ممکن است مقادیر متفاوت برای آن ها روی عملکرد الگوریتم تاثیرگذار باشد. در این بخش به معرفی این عامل ها پرداخته می شود. در هر مورد آزمایش با استفاده از الگوریتم MOSA روی مجموعه ای تصادفی از کاربران برای لیست توصیه هفت عضوی انجام شده است. پس از انجام آزمایش ها مقادیر زیر برای پارامترها به دست آمده است.

(۱) دمای بیشینه و دمای کمینه در الگوریتم شبیه سازی تبرید برابر ۵۰۰ و دمای کمینه برابر ۰/۰۰۰۱ در نظر گرفته شده است.

(۲) نرخ کاهش دما در الگوریتم شبیه سازی تبرید به صورت غیریکنواخت^{۲۰} و با مقدار اولیه ۰/۹۶۹ برای آلفا در نظر گرفته شده است و پس از هر ۱۰۰ تکرار مقدار آلفا ۰/۰۱ کاهش می یابد.

(۳) روش محاسبه احتمال در الگوریتم شبیه سازی تبرید به صورت $\frac{1}{1 + e^{\text{delta} \cdot \text{temperature}}}$ انتخاب شده است. این روش در پژوهش های پیشین [۴۰، ۴۱، ۴۴، ۴۷] معرفی شده است.

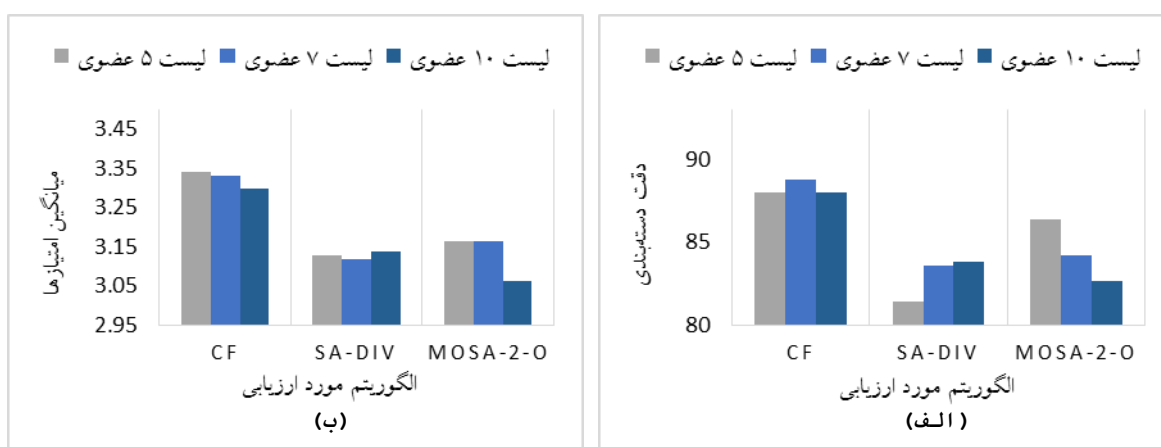
(۴) در پژوهش هایی نشان داده شده است که ممکن است برخی معیارهای ارزیابی در لیست های توصیه با تعداد اعضای متفاوت، نتایج متفاوتی داشته باشند [۱، ۳، ۲۲، ۴۸، ۴۹]. به همین دلیل، نتایج این پژوهش، برای لیست هایی با تعداد اعضای پنج، هفت و ۱۰ ارزیابی خواهد شد.

۴-۵ مقایسه نتایج

نتایج روش پیشنهادی که آن را به اختصار MOSA-2-O می‌نامیم، با دو روشی که در بخش ۴-۳ توضیح داده شدند، مقایسه شده‌اند. نتایج در ادامه این بخش ارائه می‌گردند.

۴-۵-۱ ارزیابی دقت

دقت دسته‌بندی و میانگین جمع امتیازهای واقعی اقلام لیست‌های توصیه برای ارزیابی دقت به دست آورده شده‌اند. نتایج در شکل (۲) نشان داده شده است. این نمودارها نشان می‌دهند که غیر از لیست ۱۰ عضوی در بقیه موارد دقت روش پیشنهادی (یعنی MOSA-2-O) بالاتر از شبیه‌سازی تبرید تک‌هدفه است و به طور کلی میزان کاهش دقت نسبت به الگوریتم CF در حدی است که در ازای بهبود تنوع شخصی‌سازی شده قابل چشم‌پوشی است. جدول ۱ نیز داده‌های حاصل از ارزیابی دقت را نشان می‌دهد.




شکل ۲: ارزیابی الگوریتم‌ها با معیار دقت: (الف) - ارزیابی با معیار دقت دسته‌بندی، (ب) - ارزیابی با معیار میانگین امتیازها

جدول ۱: داده‌های حاصل از ارزیابی الگوریتم‌ها با معیارهای دقت دسته‌بندی و میانگین امتیازها

میانگین امتیازها			دقت دسته‌بندی			تعداد اعضای لیست توصیه
۱۰	۷	۵	۱۰	۷	۵	
۳/۳	۳۳/۳۳	۳/۳۳	۸۸/۰۲	۸۸/۷۵	۸۸/۰۱	CF
۳/۱۴	۳/۲	۳/۱۳	۸۳/۸۴	۸۳/۵۵	۸۱/۴۳	SA-div
۳/۰۶	۳/۱۶	۳/۱۶	۸۲/۶۷	۸۴/۲۲	۸۶/۳۴	MOSA-2-O

۴-۵-۲ ارزیابی تنوع شخصی‌سازی شده

نتایج الگوریتم‌ها بر اساس معیار تنوع شخصی‌سازی شده که در بخش ۴-۲-۱ معرفی شد، در شکل (۳) نشان داده شده است. همان‌طور که مشاهده می‌شود، روش MOSA-2-O در شخصی‌سازی تنوع موفق بوده است و این معیار را نسبت به دو روش دیگر بهبود داده است. به علاوه روش شبیه‌سازی تبرید تک‌هدفه نیز این معیار را بهبود داده است اما نتایج بخش قبلی نشان داد که نسبت به الگوریتم MOSA-2-O افت بیشتری در دقت ایجاد کرده است. بنابراین الگوریتم MOSA-2-O توانسته است تعادل مناسبی بین این دو معیار ایجاد کند. در جدول (۲) نیز داده‌های حاصل از ارزیابی با معیار تنوع سبک فیلم و تنوع شخصی‌سازی شده نشان داده شده است.



شکل ۳: ارزیابی الگوریتم‌ها با معیار تنوع شخصی سازی شده

جدول ۲: داده‌های حاصل از ارزیابی الگوریتم‌ها با معیارهای تنوع سبک فیلم و تنوع شخصی سازی شده

تنوع شخصی سازی شده			تنوع سبک فیلم			
۱۰	۷	۵	۱۰	۷	۵	تعداد اعضای لیست توصیه
۱۲/۲۴	۱۴/۲۹	۱۵/۱۷	۴۳/۷۵	۴۸/۸۲	۲۶/۹۹	CF
۱۲/۹۵	۱۶/۷۷	۱۵/۲	۴۴/۱۳	۵۰/۱۵	۲۶/۹۹	SA-div
۱۴/۹۱	۱۹/۵۱	۱۶/۵۱	۴۴/۹۴	۴۹/۳	۲۸/۲۲	MOSA-2-O

۵. بحث و تحلیل روش پیشنهادی

ارزیابی راهکار پیشنهادی نشان داد که روش پیشنهادی نتایج را نسبت به روش استاندارد پالایش مشارکتی بر اساس معیار تنوع شخصی سازی شده بهبود می‌دهد. نتایجی را که از این ارزیابی‌ها به دست می‌آید می‌توان در سه مورد خلاصه کرد:

(۱) در جدول (۳) نتایج دو روش SA-div و MOSA-2-O از نظر دو معیار دقت دسته‌بندی و تنوع شخصی سازی شده برای اندازه‌های مختلف لیست توصیه مقایسه شده‌اند. همان‌طور که مشاهده می‌شود در مواردی که تنوع بخشی شخصی سازی شده بهتر انجام شده است، دقت نیز بالاتر است در حالی که افزایش تنوع بدون شخصی سازی موجب کاهش دقت می‌شود. بنابراین می‌توان نتیجه گرفت که شخصی سازی تنوع به ایجاد تعادل بین دقت و تنوع کمک خواهد کرد و نه تنها موجب کاهش دقت نخواهد شد بلکه در صورت بهینه شدن آن، در دقت نیز بهبود ایجاد خواهد شد.

جدول ۳: مقایسه الگوریتم‌های SA-div و MOSA-2-O از نظر معیارهای دقت و تنوع شخصی سازی شده

MOSA-2-O	SA-div	معیارها	تعداد اعضای لیست توصیه
۸۶/۳۴	۸۱/۴۳	دقت دسته‌بندی	۵
۱۶/۵۱	۱۵/۲	تنوع شخصی سازی شده	
۸۴/۲۲	۸۳/۵۵	دقت دسته‌بندی	۷
۱۹/۵۱	۱۶/۷۷	تنوع شخصی سازی شده	
۸۲/۶۷	۸۳/۸۴	دقت دسته‌بندی	۱۰
۱۴/۹۱	۱۲/۹۵	تنوع شخصی سازی شده	

(۲) با توجه به نتایج جدول (۳) می‌توان این‌طور نتیجه‌گیری کرد که بین میزان تنوع انتخاب‌های قبلی کاربر و میزان گرایش او به دریافت لیست‌های متنوع رابطه مستقیم وجود دارد. تاثیر تنوع بخشی شخصی سازی شده بر بهبود دقت نشان می‌دهد که این نوع تنوع بخشی مورد رضایت کاربر بوده است.

۳) با توجه به این که راهکار پیشنهادی موجب بهبود اهداف تعریف شده نسبت به روش استاندارد پالایش مشارکتی شده است، این طور نتیجه گیری می شود که استفاده از یک روش بهینه سازی چندهدفه مناسب می تواند لیست توصیه ای ایجاد کند که از نظر اهداف تعیین شده بر روش استاندارد پالایش مشارکتی برتری دارند.

یکی از محدودیت های این پژوهش پیچیدگی زمانی نسبتا بالای الگوریتم بهینه سازی بخصوص برای لیست هایی با تعداد اعضای بالا است. الگوریتم های بهینه سازی فرااکتشافی^{۲۱} اصولا زمان نسبتا زیادی برای اجرا نیاز دارند. البته در بخش ۳-۲-۳ به این موضوع اشاره شد که الگوریتم شبیه سازی تبرید مورد استفاده در راهکار پیشنهادی، نسبت به الگوریتم متداول دیگر یعنی NSGA-II (که در پژوهش های پیشین در توصیه گرها به کار گرفته شده است)، پیچیدگی زمانی کمتری دارد. در این پژوهش روشی که برای جبران پیچیدگی زمانی بالای این الگوریتم پیشنهاد می شود این است که الگوریتم بهینه سازی به صورت برون خط^{۲۲} انجام شود. یعنی زمانی که اطلاعات جدیدی برای یک کاربر به دست می آید، در مواقع بیکاری سیستم لیست توصیه مربوط به او ایجاد گرد. سپس با استفاده از اطلاعاتی که از زمان مراجعه فعلی کاربر به سیستم به دست می آید، با الگوریتم استاندارد پالایش مشارکتی، یک لیست توصیه جدید ایجاد شود. آنگاه این دو لیست توصیه با یکدیگر ترکیب شوند. ترکیب دو لیست توصیه به این صورت انجام خواهد شد که تعدادی اعضای لیست توصیه جدید به صورت تصادفی انتخاب می شوند و جایگزین اعضای از لیست توصیه برون خط می شوند که بیشترین شباهت را به آن ها دارند. به این ترتیب ضمن سرعت اجرای بالای الگوریتم توصیه، میزان تنوع لیست توصیه به طور تقریبی حفظ خواهد شد و اطلاعات جدید کاربر نیز در ایجاد لیست توصیه اعمال خواهد شد. به دلیل پیچیدگی زمانی بسیار کم الگوریتم استاندارد پالایش مشارکتی، ایجاد لیست توصیه بهینه در مدت زمان بسیار کوتاهی انجام خواهد شد. زمان اجرای الگوریتم های CF و MOSA-2-O در جدول (۴) نشان داده شده است.

جدول ۴: میانگین زمان اجرای الگوریتم ها

میانگین زمان اجرا			
۱۰	۷	۵	تعداد اعضای لیست توصیه
۰/۵۴ ثانیه	۰/۵۴ ثانیه	۰/۵۲ ثانیه	CF
۱۰/۵ دقیقه	۶/۱۶ دقیقه	۳/۶۶ دقیقه	MOSA-2-O

برای بررسی این که آیا نتایج روش پیشنهادی این مقاله با روش های CF و SA-Div تفاوت معنی داری دارد یا خیر، از آزمون t یک طرفه^{۲۳} در سطح معنی داری^{۲۴} ۰/۰۵ استفاده شد. نتایج این آزمون در جدول (۵) مشاهده می شود. همانطور که در جدول مشاهده می شود، روش پیشنهادی نسبت به دو روش CF و SA-div تفاوت معنی داری داشته است.

جدول ۵: نتایج آزمون t بر روی نتایج روش پیشنهادی و نتایج روش های دیگر (S نشان دهنده معنی دار و N نشان دهنده بی معنی است)

SA-div			CF			الگوریتم مقایسه شده
۱۰	۷	۵	۱۰	۷	۵	اندازه لیست توصیه
S	S	S	S	S	S	دقت
S	S	S	S	S	S	تنوع
S	S	S	S	S	S	تنوع شخصی سازی شده
S	S	S	S	S	S	میانگین امتیازها

²¹ Metaheuristic

²² Offline

²³ One-tailed t-test

²⁴ Significance level

۶. نتیجه‌گیری

سیستم‌های توصیه‌گر به عنوان ابزاری برای ارائه اقلام مرتبط به هر کاربر، در بسترهای مختلف تجارت الکترونیکی مورد استفاده قرار می‌گیرند. برای این سیستم‌ها خصوصیات متعددی تعریف شده است که هر یک به نوبه خود اهمیت دارند. یکی از مهم‌ترین خصوصیات توصیه‌گرها دقت آن‌ها است که اغلب پژوهش‌ها برای بهبود آن انجام شده‌اند. در سال‌های اخیر، پژوهشگران نشان دادند که این روند تک‌بعدی منجر به بروز برخی مشکلات برای توصیه‌گرها می‌شود. در این پژوهش، راهکار جدیدی برای توجه به تنوع - که یکی دیگر از ابعاد مهم سیستم توصیه‌گر محسوب می‌شود - ارائه شد. راهکار پیشنهادی بر مبنای رویکرد بهینه‌سازی چندهدفه و با استفاده از الگوریتم شبیه‌سازی تبرید طراحی شد. در روش پیشنهادی با استفاده از آنتروپی ترجیحات کاربر، مقدار تنوع‌گرایی او به دست آمد و میزان تنوع در لیست توصیه مطابق با آن مقدار تنظیم شد. این روش با استفاده از مجموعه داده‌های Netflix و Movielens مورد آزمایش قرار گرفت. روش پیشنهادی از نظر دقت و تنوع شخصی‌سازی شده مورد ارزیابی قرار گرفت و مقایسه آن با روش استاندارد پالایش مشارکتی نشان داد که با استفاده از این روش می‌توان تنوع لیست توصیه را مطابق با نیاز و گرایش کاربر به تنوع تنظیم کرد بدون آن که کاهش چشمگیری در دقت ایجاد شود.

مراجع

- [1] G. Adomavicius and Y. Kwon, "Improving aggregate recommendation diversity using ranking-based techniques", IEEE Transactions on Knowledge and Data Engineering, vol. 24, no. 5, pp. 896-911, 2012.
- [2] R. Forsati, M. Mahdavi, M. Shamsfard, and M. Sarwat, "Matrix factorization with explicit trust and distrust side information for improved social recommendation", ACM Transactions on Information Systems (TOIS), vol. 32, no. 4, p. 17, 2014.
- [3] K. Bradley and B. Smyth, *Improving recommendation diversity*, Proceedings of the Twelfth Irish Conference on Artificial Intelligence and Cognitive Science, pp. 85-94, Maynooth, Ireland, 2001.
- [4] Z. D. Champiri, S. R. Shahamiri, and S. S. B. Salim, "A systematic review of scholar context-aware recommender systems", Expert Systems with Applications, vol. 42, no. 3, pp. 1743-1758, 2015.
- [5] L. F. T. Tamayo, *SmartParticipation: a fuzzy-based recommender system for political community-building*, Ph.D. Thesis, University of Fribourg, Switzerland, 2014.
- [6] J. Bobadilla, F. Ortega, A. Hernando, and A. Gutiérrez, "Recommender systems survey", Knowledge-Based Systems, vol. 46, pp. 109-132, 2013.
- [7] Z. Qingbiao, F. Jie, and G. Xu, *Incorporating Sentiment Analysis for Improved Tag-Based Recommendation*, IEEE Ninth International Conference on Dependable, Autonomic and Secure Computing (DASC), pp. 1222-1227, 2011.
- [8] J. Borrás, A. Moreno, and A. Valls, "Intelligent tourism recommender systems: A survey", Expert Systems with Applications, vol. 41, no. 16, pp. 7370-7389, 2014.
- [9] F. Ricci, L. Rokach, and B. Shapira, "Introduction to Recommender Systems Handbook," in *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira, and B. P. Kantor, Eds. Boston, MA: Springer US, pp. 1-35, 2011.
- [10] S. M. Mcnee, *Meeting user information needs in recommender systems*, Proquest, 2006.
- [11] H. Chandrashekar and B. Bhasker, "Personalized recommender system using entropy based collaborative filtering technique", Journal of Electronic Commerce Research, vol. 12, no. 3, pp. 214-237, 2011.
- [12] Y.-J. Park, "The adaptive clustering method for the long tail problem of recommender systems", IEEE Transactions on Knowledge and Data Engineering, vol. 25, no. 8, pp. 1904-1915, 2013.
- [13] T. Di Noia, V. C. Ostuni, J. Rosati, P. Tomeo, and E. Di Sciascio, *An analysis of users' propensity toward diversity in recommendations*, Proceedings of the 8th ACM Conference on Recommender systems, pp. 285-288, 2014.
- [14] G. Adomavicius and 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, no. 6, pp. 734-749, 2005.
- [15] C.-N. Ziegler, S. M. McNee, J. A. Konstan, and G. Lausen, *Improving recommendation lists through topic diversification*, Proceedings of the 14th international conference on World Wide Web, pp. 22-32, 2005.
- [16] S. M. McNee, J. Riedl, and J. A. Konstan, *Being accurate is not enough: how accuracy metrics have hurt recommender systems*, CHI'06 extended abstracts on Human factors in computing systems, pp. 1097-1101, 2006.
- [17] B. Smyth and P. McClave, *Similarity vs. Diversity*, Case-Based Reasoning Research and Development: 4th International Conference on Case-Based Reasoning, ICCBR 2001 Vancouver, pp. 347-361, Berlin, Heidelberg, 2001.

- [18] M. Zhang and N. Hurley, *Avoiding monotony: improving the diversity of recommendation lists*, Proceedings of the 2008 ACM conference on Recommender systems, pp. 123-130, 2008.
- [19] D. Fleder and K. Hosanagar, "*Blockbuster culture's next rise or fall: The impact of recommender systems on sales diversity*", Management science, vol. 55, no. 5, pp. 697-712, 2009.
- [20] N. Hurley and M. Zhang, "*Novelty and diversity in top-n recommendation--analysis and evaluation*", ACM Transactions on Internet Technology (TOIT), vol. 10, no. 4, p. 14, 2011.
- [21] I. Avazpour, T. Pitakrat, L. Grunske, and J. Grundy, "Dimensions and metrics for evaluating recommendation systems," in *Recommendation systems in software engineering*, P. M. Robillard, W. Maalej, J. R. Walker, and T. Zimmermann, Eds. Berlin, Heidelberg: Springer, pp. 245-273, 2014.
- [22] G. Adomavicius and Y. Kwon, *Overcoming accuracy-diversity tradeoff in recommender systems: a variance-based approach*, Proceedings of the 18th workshop on information technology and systems (WITS'08), Paris, 2008.
- [23] L. Shi, *Trading-off among accuracy, similarity, diversity, and long-tail: a graph-based recommendation approach*, Proceedings of the 7th ACM conference on Recommender systems, pp. 57-64, 2013.
- [24] W. Wu, L. Chen, and L. He, *Using personality to adjust diversity in recommender systems*, Proceedings of the 24th ACM Conference on Hypertext and Social Media, pp. 225-229, 2013.
- [25] Y. Shi, X. Zhao, J. Wang, M. Larson, and A. Hanjalic, *Adaptive diversification of recommendation results via latent factor portfolio*, Proceedings of the 35th international ACM SIGIR conference on Research and development in information retrieval, pp. 175-184, 2012.
- [26] S. Vargas and P. Castells, *Exploiting the diversity of user preferences for recommendation*, Proceedings of the 10th Conference on Open Research Areas in Information Retrieval, pp. 129-136, 2013.
- [27] L. Chen, W. Wu, and L. He, *How personality influences users' needs for recommendation diversity?*, CHI'13 Extended Abstracts on Human Factors in Computing Systems, pp. 829-834, 2013.
- [28] T. Di Noia, J. Rosati, P. Tomeo, and E. D. Sciascio, "*Adaptive Multi-attribute Diversity for Recommender Systems*", Information Sciences, 2016.
- [29] S. Wang, M. Gong, H. Li, and J. Yang, "*Multi-objective optimization for long tail recommendation*", Knowledge-Based Systems, vol. 104, pp. 145-155, July 2016.
- [30] B. Geng, L. Li, L. Jiao, M. Gong, Q. Cai, and Y. Wu, "*NNIA-RS: A multi-objective optimization based recommender system*", Physica A: Statistical Mechanics and its Applications, vol. 424, pp. 383-397, 2015.
- [31] Y. Zuo, M. Gong, J. Zeng, L. Ma, and L. Jiao, "*Personalized Recommendation Based on Evolutionary Multi-Objective Optimization*", IEEE Computational Intelligence Magazine, vol. 10, no. 1, pp. 52-62, 2015.
- [32] M. T. Ribeiro, A. Lacerda, A. Veloso, and N. Ziviani, *Pareto-efficient hybridization for multi-objective recommender systems*, Proceedings of the sixth ACM conference on Recommender systems, pp. 19-26, 2012.
- [33] L. Chen, W. Wu, and L. He, "Personality and Recommendation Diversity," in *Emotions and Personality in Personalized Services: Models, Evaluation and Applications*, M. Tkalčić, B. De Carolis, M. de Gemmis, A. Odić, and A. Košir, Eds. Cham: Springer International Publishing, pp. 201-225, 2016.
- [34] P. Basile, A. Caputo, M. de Gemmis, P. Lops, and G. Semeraro, *Modeling Short-Term Preferences in Time-Aware Recommender Systems*, Proceedings of DeCAT - 1st Workshop on Deep Content Analytics Techniques for Personalized and Intelligent Services, co-located with UMAP 2015, Dublin, 2015.
- [35] S. X. Zhao and C. Wang, "*Research on Personalized Recommendation System Based on LBS*", Research in Electronic Commerce Frontiers, vol. 2, pp. 1-5, 2014.
- [36] K. Tso and L. Schmidt-Thieme, *Attribute-aware collaborative filtering*, Proceedings of the 29th Annual Conference of the Gesellschaft für Klassifikation e.V. University of Magdeburg, pp. 614-621, Berlin, Heidelberg, 2006.
- [37] T. Lehinevych, N. Kokkinis-Ntrenis, G. Siantikos, A. S. Dogruöz, T. Giannakopoulos, and S. Konstantopoulos, *Discovering similarities for content-based recommendation and browsing in multimedia collections*, Tenth International Conference on Signal-Image Technology and Internet-Based Systems (SITIS), pp. 237-243, 2014.
- [38] M. J. Pazzani and D. Billsus, "Content-based recommendation systems," in *The adaptive web*: Springer, pp. 325-341, 2007.
- [39] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, *Item-based collaborative filtering recommendation algorithms*, Proceedings of the 10th international conference on World Wide Web, pp. 285-295, 2001.
- [40] S. Bandyopadhyay, S. Saha, U. Maulik, and K. Deb, "*A simulated annealing-based multiobjective optimization algorithm: AMOSA*", IEEE transactions on evolutionary computation, vol. 12, no. 3, pp. 269-283, 2008.
- [41] L. Liu, H. Mu, J. Yang, X. Li, and F. Wu, "*A simulated annealing for multi-criteria optimization problem: DBMOSA*", Swarm and Evolutionary Computation, vol. 14, pp. 48-65, 2014.
- [42] R. W. Eglese, "*Simulated annealing: A tool for operational research*", European Journal of Operational Research, vol. 46, no. 3, pp. 271-281, 1990.
- [43] S. Geman and D. Geman, "*Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images*", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. PAMI-6, no. 6, pp. 721-741, 1984.
- [44] K. I. Smith, R. M. Everson, and J. E. Fieldsend, *Dominance measures for multi-objective simulated annealing*,

Congress on Evolutionary Computation, CEC2004., pp. 23-30, 2004.

[45] *Movielens*. Available: <http://grouplens.org/datasets/movielens/>. 2015/03.

[46] *Netflix Prize Dataset*. Available: <http://academictorrents.com/>. 2015/05.

[47] B. Suman, "*Study of self-stopping PDMOSA and performance measure in multiobjective optimization*", *Computers & Chemical Engineering*, vol. 29, no. 5, pp. 1131-1147, 2005.

[48] G. Adomavicius and Y. Kwon, *Maximizing aggregate recommendation diversity: A graph-theoretic approach*, *Proceedings of the 1st International Workshop on Novelty and Diversity in Recommender Systems (DiveRS 2011)*, pp. 3-10, Chicago, 2011.

[49] Y.-C. Ho, Y.-T. Chiang, and J. Y.-J. Hsu, *Who likes it more?: mining worth-recommending items from long tails by modeling relative preference*, *Proceedings of the 7th ACM international conference on Web search and data mining*, pp. 253-262, 2014.