

تنوع بخشی شخصی سازی شده برای توصیه اقلام دنباله طولانی با استفاده از الگوریتم جستجوی ممنوعه چندهدفه

الهه ملکزاده همدانی مرجان کائدی

دانشکده مهندسی کامپیوتر، دانشگاه اصفهان، اصفهان، ایران

چکیده

در الگوریتم‌های توصیه‌ی رایج، تمرکز اصلی بر افزایش دقت توصیه‌ها است. این الگوریتم‌ها ممکن است قادر به یافتن تمامی اقلام مناسب برای توصیه به کاربران نباشند و تعداد زیادی از اقلام که توسط تعداد کمی از کاربران امتیازدهی شده‌اند، به ندرت در توصیه‌ها شرکت کنند. به این اقلام، اقلام دنباله طولانی گفته می‌شود. یکی از روش‌هایی که به مشارکت بیشتر اقلام دنباله طولانی کمک می‌کند توجه به ابعاد دیگری از سیستم توصیه‌گر مانند تنوع است. میزان گرایش کاربران به تنوع توصیه‌ها متفاوت است، بنابراین بهتر است تنوع بخشی متناسب با میزان تنوع گزایی کاربر انجام شود. در این پژوهش راه‌حلی مبتنی بر تنوع بخشی شخصی سازی شده برای مسئله عدم توصیه اقلام دنباله طولانی ارائه می‌شود. روش پیشنهادی یک روش بهینه‌سازی چندهدفه بر مبنای الگوریتم جستجوی ممنوعه است که در آن دو هدف برای توجه بیشتر به اقلام دنباله طولانی و یک هدف برای بهبود دقت لیست توصیه تعریف می‌شود. نتایج ارزیابی نشان می‌دهد که این روش در مقایسه با روش‌های قبلی کارایی بیشتری دارد و منجر به مشارکت بیشتر اقلام دنباله طولانی در توصیه‌ها می‌شود، ضمن اینکه دقت را در حد قابل قبولی حفظ می‌کند.

کلمات کلیدی: سیستم توصیه‌گر، تنوع، دنباله طولانی، بهینه‌سازی چندهدفه، جستجوی ممنوعه.

۱- مقدمه

ترجیحات^۱ یا علاقه‌مندی‌های او دارد [۶]. در یک سیستم توصیه‌گر داده‌ها معمولاً شامل امتیازدهی‌های کاربران به اقلام است. اما در برخی از توصیه‌گرها ممکن است داده‌ها شامل موارد دیگری مانند خریدها، دانلودها، مشاهده‌ها یا اطلاعات شخصی کاربران باشد [۲، ۷].

در اغلب پژوهش‌هایی که تا یک دهه گذشته روی سیستم‌های توصیه‌گر انجام می‌شد، هدف اصلی بهبود الگوریتم توصیه برای تخمین دقیق‌تر امتیازهای کاربران به اقلام بود. [۴]. در این پژوهش‌ها تمرکز بر بُعد دقت و بهبود معیارهای دقت پیش‌بینی بود [۸، ۱۰]. این در حالی است که در سال‌های اخیر توجه پژوهشگران به ابعاد دیگری از سیستم توصیه‌گر جلب شد. آنها معتقد هستند که پژوهش‌های پیشین به طور تک‌بعدی انجام شده است و این موجب بروز مشکلاتی برای توصیه‌گرها می‌شود. در حال حاضر این موضوع پذیرفته شده است که دقت تنها یکی از خصوصیات سیستم توصیه‌گر است و در عین حال که بهبود آن ضروری است، اما کافی نیست [۱، ۳، ۴، ۷، ۱۱، ۱۲].

سیستم‌های توصیه‌گر با پلایش اطلاعات انبوه روی وب، به کاربران کمک می‌کنند تا اطلاعات مورد نیاز خود را سریع‌تر و ساده‌تر بیابند. اگرچه ابزارهای دیگری نظیر موتورهای جستجو در این زمینه کمک بسیاری به کاربران می‌کنند، اما گاهی نیاز به ابزارهایی هوشمندانه‌تر وجود دارد که بتوانند علاقه‌مندی‌های هر کاربر را به طور خاص شناسایی کنند و مرتبط‌ترین اطلاعات را به او ارائه کنند. سیستم‌های توصیه‌گر در سال‌های گذشته به عنوان یکی از قدرتمندترین و محبوب‌ترین ابزارها در تجارت الکترونیکی برای یافتن اطلاعات مورد علاقه و مرتبط مورد استفاده قرار گرفته‌اند [۱-۵]. از اواسط دهه ۱۹۹۰ تاکنون پژوهش‌های فراوانی بر روی آنها انجام شده و سعی در توسعه و بهبود آنها شده است. سیستم‌های توصیه‌گر با تحلیل داده‌هایی که از گذشته‌ی یک کاربر در دسترس است، علاقه‌مندی‌های او را استخراج می‌کنند و اطلاعاتی را به کاربر توصیه می‌کنند که بیشترین تطبیق را با

تنوع^۸ است. تنوع لیست توصیه به معنی میزان عدم شباهت اقلام موجود در لیست توصیه است [۱۷]. مطالعات نشان داده‌اند که بین تنوع و دقت، موازنه^۹ وجود دارد و با افزایش یکی از آنها، دیگری کاهش می‌یابد [۱، ۳، ۱۱، ۱۲، ۱۶]. بنابراین برای رفع مشکلات ناشی از پدیده دنباله طولانی می‌توان تنوع توصیه‌ها را نیز در کنار دقت مورد توجه قرار داد تا با برداشتن تمرکز از روی دقت، توجه به اقلام نامحبوب بیشتر شود [۱۸]. در اکثر پژوهش‌هایی که به تنوع‌بخشی در توصیه‌ها پرداخته‌اند، از یک روال تنوع‌بخشی یکسان برای همه کاربران استفاده شده است؛ در حالی که می‌توان میزان تنوع در هر لیست توصیه را مطابق با ترجیحات کاربری که آن را دریافت می‌کند، تنظیم کرد. با این کار، تنوع‌بخشی به صورت شخصی‌سازی شده یعنی بر مبنای نیازها و تمایلات هر 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 هستند [۵، ۱۰، ۱۹-۲۱]. با این وجود، در پژوهش‌هایی که معیار تنوع را به منظور مشارکت بیشتر اقلام دنباله طولانی به کار گرفته‌اند، به سطح نیاز و علاقه کاربر به تنوع پرداخته نشده است. بنابراین یک خلأ بین دو شاخه از پژوهش‌ها وجود دارد. شاخه اول مشارکت اقلام دنباله طولانی در توصیه‌ها و شاخه دوم تنوع‌بخشی شخصی‌سازی شده در توصیه‌ها است. در پژوهش قبلی [۲۲] به این موضوع پرداخته شد و روشی بر مبنای الگوریتم شبیه‌سازی تبرید برای آن ارائه شد. در پژوهش حاضر نیز برای بهبود کارایی توصیه‌گر از لحاظ مشارکت اقلام دنباله طولانی و دقت توصیه‌ها از طریق تنوع‌بخشی شخصی‌سازی شده راهکار دیگری ارائه خواهد شد که روش قبلی را توسعه و بهبود دهد. در ادامه این مقاله، در بخش دوم پژوهش‌های مرتبط مرور خواهند شد. در بخش سوم روش پیشنهادی معرفی می‌گردد و در بخش چهارم ارزیابی این روش صورت خواهد گرفت. در بخش پنجم به نتیجه‌گیری و جمع‌بندی پرداخته خواهد شد.

۲- مرور پژوهش‌های پیشین


در این بخش ابتدا تعدادی از پژوهش‌هایی که در زمینه تنوع‌بخشی شخصی‌سازی شده انجام شده‌اند مرور خواهند شد. سپس پژوهش‌هایی که برای برطرف کردن مشکل عدم توصیه اقلام دنباله طولانی، انجام شده‌اند توضیح داده می‌شوند. در پایان نیز تعدادی از پژوهش‌هایی که به منظور بهینه‌کردن چندین معیار در سیستم‌های توصیه‌گر با رویکرد بهینه‌سازی چندهدفه انجام شده‌اند مرور خواهند شد.

۲-۱- پژوهش‌های مرتبط با تنوع‌بخشی شخصی‌سازی شده

شی و همکارانش در پژوهش خود برای شخصی‌سازی سطح تنوع توصیه‌ها براساس نیاز کاربر، از واریانس عوامل پنهان کاربر^{۱۰} استفاده کردند. آنها با این روش میزان عدم قطعیت ترجیحات کاربر را محاسبه کردند. سپس بر مبنای این عدم قطعیت و با در نظر گرفتن محدوده علاقه‌مندی‌های کاربر، نیاز کاربر به تنوع توصیه‌ها را به دست آوردند [۱۹]. نتایج نشان داد که با این روش می‌توان میزان نیاز کاربر به تنوع را به دست آورد.

چن و همکارانش ارتباط بین شخصیت کاربران و نیاز آنها به تنوع را مورد مطالعه قرار دادند [۵، ۲۳]. آنها نشان دادند که برخی از ابعاد شخصیتی، تأثیر قابل توجهی روی گرایش‌های کاربران به تنوع توصیه‌ها دارند و سپس با استفاده از مدل پنج عامل بزرگ شخصیتی^{۱۱}، ویژگی‌های شخصیتی افراد را به یک عدد به عنوان سطح نیاز کاربر به تنوع نگاشت کردند. نظرات کاربران نشان داد که ترکیب این اطلاعات با ترجیحات کاربر موجب می‌شود که توصیه‌ها نسبت به روش معمول

توصیه‌گرهایی را که تنها بر دقت تمرکز دارند، اصطلاحاً «دقت-محور» می‌نامند [۸]. انواع مشکلاتی که توصیه‌گرهای دقت-محور را تهدید می‌کنند در پژوهش‌ها مورد بررسی قرار گرفته‌اند [۴، ۷، ۸، ۱۳]. همه این مشکلات به نوعی توصیه اقلام تکراری و مشابه را مطرح می‌کنند. یکی از این مشکلات که در این پژوهش به آن پرداخته می‌شود این است که در توصیه‌گرهای دقت-محور تنها متداول‌ترین اقلام توصیه می‌شوند. به این معنی که تعدادی از اقلام که عمومی‌تر هستند به طور مداوم در توصیه‌ها شرکت می‌کنند و توصیه شخصی‌سازی شده و ویژه هر کاربر ارائه نمی‌شود [۹، ۱۴]. این مسئله در ادامه توضیح داده می‌شود. در هر سیستم توصیه‌گر اقلامی وجود دارند که داده‌های تاریخچه‌ای کمی دارند. منظور از داده‌های تاریخچه‌ای امتیازدهی‌های کاربران به اقلام است. این اقلام را اقلام نامحبوب^۲ می‌نامند و اقلامی که دارای داده‌های تاریخچه‌ای زیادی هستند اقلام محبوب نامیده می‌شوند. در پژوهشی که توسط فلدر^۲ و همکارش درباره تأثیر توصیه‌گرها روی تنوع در فروش انجام شد [۷]، نشان داده شد که توصیه‌گرهایی که با روش‌های معمول پالایش مشارکتی^۴ کار می‌کنند به دلیل اتکا به داده‌های تاریخچه‌ای و تلاشی که در بهبود دقت پیش‌بینی امتیازها دارند اقلامی را که داده‌های تاریخچه‌ای بیشتری دارند به تعداد بیشتری از کاربران توصیه می‌کنند. با این کار فروش اقلام محبوب بالاتر می‌رود. در مقابل، اقلامی که در توصیه‌های کمتری شرکت کرده‌اند نامحبوب باقی می‌مانند. در مطالعه دیگری روی داده‌های MovieLens^۵ مشاهده شد که تنها ۲/۵٪ اقلام در توصیه‌ها شرکت کرده‌اند [۱]. به عبارتی می‌توان گفت تعداد زیادی از اقلام توسط سیستم توصیه‌گر کنار گذاشته شده‌اند [۹، ۱]. نمودار سابقه‌نمای داده‌های MovieLens در شکل ۱ نشان داده شده است. در این نمودار مشاهده می‌شود که تعداد کمی از اقلام در سر نمودار و بقیه در یک دنباله طولانی قرار گرفته‌اند. با توجه به این نمودار به اقلام نامحبوب اصطلاحاً اقلام دنباله طولانی^۶ نیز گفته می‌شود [۹، ۱۵]. پیش‌بینی امتیاز اقلام نامحبوب مشکل است. در نتیجه، این اقلام کمتر در توصیه‌ها شرکت می‌کنند و تعداد امتیازهای داده شده به آنها چندان افزایش نمی‌یابد و به تدریج کنار گذاشته می‌شوند. در مقابل، اقلام محبوب به تعداد زیادی از کاربران توصیه می‌شوند و توسط آنها امتیازدهی می‌گردند و پیوسته حجم داده‌های تاریخچه‌ای آنها افزایش می‌یابد و بیشتر در معرض دید کاربران قرار می‌گیرند. بنابراین توصیه‌گر اقلامی را برای توصیه به کاربران پیدا می‌کند که بسیار عمومی هستند و با توصیه اقلام عمومی‌تر، نقش سیستم توصیه‌گر در پیدا کردن اطلاعات خاص هر کاربر تضعیف می‌شود [۷، ۱۴].



شکل ۱- نمودار سابقه‌نمای اقلام امتیازدهی شده در MovieLens [۹]

همان‌طور که اشاره شد تمرکز روی بُعد دقت به عنوان تنها هدف بهبود الگوریتم توصیه، یک علت وقوع این پدیده است [۷، ۱۴، ۱۶]. بنابراین با در نظر گرفتن ابعاد دیگر سیستم توصیه‌گر در کنار دقت، می‌توان از بروز مشکل عدم توصیه اقلام نامحبوب جلوگیری کرد. یکی از مهم‌ترین ابعاد سیستم توصیه‌گر

به چند مورد از آنها اشاره می‌شود.

در پژوهشی به منظور بهینه کردن دو معیار دقت و تنوع از الگوریتم ژنتیک استفاده شد [۲۵]. مقایسه این روش با روش‌های پالایش مشارکتی قدیمی تر نشان داد که این الگوریتم می‌تواند در ازای کمی افت دقت، اقلام جدید و متنوعی را به کاربران توصیه کند.

برای بهینه کردن همزمان سه معیار دقت، تنوع و نوآوری، روشی بر مبنای الگوریتم ژنتیک توسط ریبیرو و همکارانش ارائه شد [۲۶]. در روش پیشنهادی آنها هدف پیدا کردن بهترین ترکیب ممکن از الگوریتم‌های توصیه بود که هر کدام از آنها یکی از معیارها را بهینه می‌کنند.

در پژوهش دیگری برای بهینه کردن سه معیار دقت، تنوع و نوآوری از یک الگوریتم ژنتیک به نام NSGA-II^{۱۷} استفاده شد [۲۷]. برای جبران سرعت پایین اجرای الگوریتم NSGA-II از خوشه‌بندی کاربران استفاده شد. نتایج این روش با یک روش ترکیبی مقایسه شد. نتایج نشان داد که استفاده از الگوریتم بهینه‌سازی نسبت به روش ترکیبی معیارهای مذکور را بهبود می‌دهد. اما با خوشه‌بندی کاربران، افت زیادی در دقت ایجاد شد.

در پژوهشی که توسط نویسندگان مقاله حاضر انجام شد، با استفاده از الگوریتم شبیه‌سازی تبرید دوهدفه و آنتروپی شانون، بهینه‌سازی لیست توصیه بر مبنای دقت و تنوع شخصی‌سازی شده انجام شد [۲۸]. نتایج این پژوهش نشان داد که با استفاده از الگوریتم شبیه‌سازی تبرید می‌توان در ازای حداکثر ۵/۳۵ درصد افت دقت نسبت به الگوریتم پایه، شخصی‌سازی تنوع لیست توصیه را انجام داد. سپس در پژوهش دیگری این روش توسعه داده شد و به منظور مشارکت بیشتر اقلام دنباله طولانی در توصیه‌ها، از الگوریتم شبیه‌سازی تبرید سه‌هدفه برای تنوع‌بخشی شخصی‌سازی شده استفاده شد [۲۲]. در این پژوهش بهینه‌سازی لیست توصیه برای سه هدف دقت، تنوع شخصی‌سازی شده و دنباله طولانی انجام شد. نتایج آن نشان داد که استفاده از این الگوریتم بهینه‌سازی، موجب افزایش مشارکت اقلام دنباله طولانی خواهد شد. به علاوه مقایسه‌ها نشان داد که هدف تنوع‌بخشی شخصی‌سازی شده به تنهایی می‌تواند موجب بهبود مشارکت اقلام دنباله طولانی شود. همچنین در این دو پژوهش نتیجه‌گیری شد که تنوع‌بخشی شخصی‌سازی شده بر خلاف تنوع‌بخشی استاندارد می‌تواند موجب بهبود دقت شود.

۳- روش پیشنهادی

در این پژوهش برای مواجهه با مشکل عدم توصیه اقلام دنباله طولانی، از تنوع‌بخشی به توصیه‌ها استفاده می‌شود و این تنوع‌بخشی به صورت شخصی‌سازی شده انجام می‌شود تا مشارکت اقلام دنباله طولانی افزایش یابد و در کنار آن، دقت توصیه‌ها نیز حفظ شود. این رهیافت، به عنوان یک مسئله بهینه‌سازی چندهدفه تعریف می‌گردد که در آن سعی می‌شود که سه هدف تنوع‌بخشی شخصی‌سازی شده، مشارکت اقلام دنباله طولانی و دقت توصیه‌ها به طور همزمان برآورده شوند.

عمل توصیه در توصیه‌گرها معمولاً شامل دو مرحله است [۴]: مرحله اول، پیش‌بینی امتیازهای اقلامی است که کاربر به آنها امتیازی نداده است و مرحله دوم، پیدا کردن اقلامی است که بیشترین سودمندی^{۱۸} را برای کاربر دارند. در پژوهش حاضر، ابتدا مرحله پیش‌بینی امتیاز با استفاده از یک رویکرد ترکیبی انجام می‌شود. این روش از ترکیب دو روش پالایش مشارکتی و مبتنی بر محتوا به دست آمده است و روش پالایش مشارکتی مبتنی بر قلم کالای آگاه به خصوصیت [۲۹] نامیده می‌شود. جزئیات این روش در [۲۸] شرح داده شده است. در مرحله دوم یعنی انتخاب بهترین اقلام برای تشکیل لیست توصیه، سعی خواهد شد براساس بهینه‌سازی چندهدفه، سه هدف مذکور با هم برآورده شوند که در ادامه توضیح

پالایش مشارکتی و همچنین روش‌های استاندارد تنوع‌بخشی [۱۱] بسیار بیشتر مورد قبول کاربران واقع شوند.

دی‌نویا و همکارانش توانستند تمایل کاربر به تنوع را با در نظر گرفتن خصوصیات اقلام از طریق آنتروپی شانون محاسبه کنند [۱۰]. در ادامه در پژوهش دیگری با استفاده از این مدل، الگوریتم توصیه‌های طراحی شد [۲۴]. نتایج نشان داد که آنتروپی می‌تواند تعیین‌کننده میزان تنوع‌گرایی کاربران باشد و پس از انجام مقایسه‌ها نتیجه‌گیری شد که شخصی‌سازی تنوع توصیه‌ها براساس روش پیشنهادی آنها کارایی بیشتری نسبت به روش‌های تنوع‌بخشی بدون شخصی‌سازی دارد.

۲-۲- پژوهش‌های مرتبط با مشارکت اقلام دنباله طولانی

در پژوهشی که با هدف استفاده بیشتر از اقلام دنباله طولانی و افزایش تنوع فروش^{۱۲} انجام شد، روشی برای برقراری موازنه بین دقت و تنوع تجمعی^{۱۳} ارائه شد [۱۶]. در این پژوهش، واریانس هر امتیاز پیش‌بینی شده، از روی امتیاز اقلامی که مستقیماً در پیش‌بینی آن امتیاز دخالت داشته‌اند به دست می‌آید و سپس اقلام بر مبنای واریانس به دست آمده رتبه‌بندی می‌شوند. نتایج نشان داد که تنوع فروش با این روش افزایش می‌یابد.

در پژوهشی دیگر که به منظور بهبود تنوع تجمعی در سیستم توصیه‌گر انجام شد، روشی برای رتبه‌بندی اقلام لیست توصیه بر مبنای محبوبیت آنها ارائه شد [۱]. نتایج نشان داد که در مقابل افزایش تنوع تجمعی، با افت دقت مواجه خواهیم شد که این مقدار افت دقت با تغییر آستانه انتخاب محبوبیت اقلام لیست توصیه تغییر می‌کند. اما در عین حال می‌توان با این روش، مشارکت اقلام دنباله طولانی را در توصیه‌ها افزایش داد.

پارک برای حل مسئله عدم توصیه اقلام دنباله طولانی، از خوشه‌بندی اقلام استفاده کرد [۹، ۱۵]. خوشه‌بندی اقلام براساس پارامترهای میانگین امتیازها، محبوبیت و تعداد کاربران علاقه‌مند به قلم کالا انجام شد. اقلام دنباله طولانی با تعداد زیادی از اقلام دیگر در یک خوشه قرار می‌گیرند و اطلاعات آنها با یکدیگر جمع می‌شود و به این ترتیب حجم داده‌های تاریخچه‌ای برای اقلام دنباله طولانی افزایش می‌یابد. بنابراین اقلامی که محبوبیت کمتری دارند نیز در توصیه‌ها شرکت خواهند کرد.

روش دیگری برای مشارکت اقلام دنباله طولانی در توصیه‌ها، مبنی بر رویکرد تخصیص منابع پیشنهاد شد [۱۴]. در این روش اقلام و لیست‌های توصیه با در نظر گرفتن پنج بُعد، امتیازدهی می‌شوند. این پنج بُعد عبارتند از دقت، تعادل (توزیع اقلام توصیه شده نسبت به کل اقلام)، پوشش^{۱۴} اقلام، میزان مشارکت اقلام دنباله طولانی و کیفیت پیش‌بینی امتیاز اقلام دنباله طولانی. سپس اقلامی که امتیاز بالاتری دارند، بیشتر در توصیه‌ها شرکت می‌کنند و همچنین لیست توصیه هر کاربر به نحوی ایجاد می‌شود که بالاترین امتیاز را داشته باشد. نتایج نشان داد که این روش به افزایش مشارکت اقلام دنباله طولانی و تنوع تجمعی کمک می‌کند ولی دقت لیست توصیه را تا حدی کاهش می‌دهد.

۲-۳- پژوهش‌های مرتبط با بهینه‌سازی چندهدفه در سیستم‌های توصیه‌گر

از آنجا که جنبه‌هایی از سیستم توصیه‌گر مانند دقت، تنوع و نوآوری^{۱۵} برای ایجاد یک توصیه‌گر کارآمد از اهمیت برخوردار هستند، لازم است بهینه کردن همزمان آنها مورد توجه قرار گیرد. در سال‌های اخیر پژوهش‌های معدودی با رویکرد بهینه‌سازی چندهدفه^{۱۶} برای بهبود کارایی توصیه‌گرها انجام شده است که در اینجا

داده می‌شود. در هر مرحله با تولید راه‌حل جدید مقدار انرژی از طریق رابطه ۱ محاسبه می‌شود.

$$\Delta \text{dom}_{\text{new-st.current-st}} = \prod_{i=1}^M f_i(\text{new_st}) \neq f_i(\text{current_st}) (|f_i(\text{new_st}) - f_i(\text{current_st})|) / R_i \quad (1)$$

در این رابطه M تعداد اهداف است و R_i دامنه تغییرات هدف i ام را نشان می‌دهد. f تابع هدف است و به ازای هر یک از اهداف یک تابع هدف تعریف می‌شود.

۳-۱-۱- توابع هدف الگوریتم بهینه‌سازی

برای بهینه‌سازی سه هدف این پژوهش، با استفاده از الگوریتم پیشنهادی لازم است سه تابع هدف تعریف شود. این توابع در ادامه توضیح داده می‌شوند.

تابع هدف اول: فاصله تنوع لیست توصیه با میزان تنوع‌گرایی کاربر

این تابع به منظور بهینه‌سازی لیست توصیه براساس هدف شخصی‌سازی تنوع تعریف می‌شود. همان‌طور که در بخش ۲-۳ گفته شد، وجود هدف تنوع‌بخشی شخصی‌سازی شده در الگوریتم بهینه‌سازی موجب افزایش مشارکت اقلام دنباله طولانی می‌شود. تنوع توصیه‌ها را به دو شیوه می‌توان محاسبه کرد [۵، ۱۰]: (۱) تنوع خصوصیات اقلام^{۲۳}، که در آن شباهت اقلام به یکدیگر براساس شباهت خصوصیات آنها به دست می‌آید و سپس تنوع بر مبنای این نوع شباهت محاسبه می‌شود و (۲) تنوع کلی اقلام^{۲۴}، 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. در این پژوهش از شیوه اول استفاده می‌شود. تابع هدف شخصی‌سازی تنوع به صورت رابطه ۲ تعریف می‌گردد.

$$f_{\text{PrDiv}_a} = |\mathcal{H}_a - \text{Diversity}_a| \quad (2)$$

در رابطه بالا \mathcal{H}_a میزان تنوع‌گرایی کاربر نسبت به خصوصیت a و Diversity_a میزان تنوع لیست توصیه بر مبنای خصوصیت a است. در روش پیشنهادی این پژوهش با تکیه بر رویکرد دی‌نویا و همکارانش [۱۰] که در بخش دوم مرور شد، از آنتروپی شانون برای تعیین میزان تنوع‌گرایی کاربر استفاده می‌شود. آنتروپی هر کاربر برای خصوصیت a از طریق رابطه ۳ محاسبه می‌گردد [۱۰].

$$\mathcal{H}_a(u) = - \sum_{v=1}^k p_v \cdot \log_k p_v \quad (3)$$

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.

برای محاسبه آنتروپی مؤثر هر کاربر، ساده‌ترین راه این است که آنتروپی کل اطلاعاتی را که از یک کاربر در دسترس است محاسبه کرد. در پژوهش‌ها نشان داده شده است که علاقه‌مندی‌های کاربر می‌تواند دو بخش ثابت و متغیر داشته باشد [۳۶، ۳۷]. بخش ثابت اطلاعات با استفاده از داده‌های بلندمدت و بخش متغیر با استفاده از داده‌های کوتاه‌مدت به دست می‌آید. برای محاسبه آنتروپی نیز می‌توان روشی اتخاذ نمود که تغییرات احتمالی در تنوع‌گرایی کاربر در طول زمان

برای انتخاب بهینه اقلام در مرحله تشکیل لیست توصیه از یک الگوریتم بهینه‌سازی چندهدفه استفاده می‌شود. همان‌طور که در بخش دوم بیان شد تاکنون پژوهش‌هایی با رویکرد بهینه‌سازی چندهدفه در سیستم‌های توصیه‌گر انجام شده است و غالباً در آنها نسخه‌هایی از الگوریتم ژنتیک (به عنوان مثال، NSGA-II) به کار رفته است [۲۵-۲۷، ۳۰] و در دو پژوهشی که توسط نویسندگان این مقاله انجام شده است از الگوریتم شبیه‌سازی تبرید چندهدفه بهره برده شده است. در پژوهش حاضر از نوعی از الگوریتم جستجوی ممنوعه احتمالی استفاده می‌شود. جستجوی ممنوعه^{۱۹} یک روش برای حل مسائل بهینه‌سازی است. این الگوریتم یک روش مبتنی بر تکرار است که با استفاده از حرکت به همسایه‌ها مجموعه‌ای از راه‌حل‌ها را کشف^{۲۰} می‌کند. یک الگوریتم تپه‌نوردی ساده نیز همین کار را می‌کند. اما اکتشاف راه‌حل‌ها از طریق تمامی همسایه‌ها کاری بسیار زمان‌بر است و همچنین احتمال متوقف شدن در یک بهینه محلی را افزایش می‌دهد. به همین دلیل در الگوریتم‌هایی مانند شبیه‌سازی تبرید و جستجوی ممنوعه این جستجوها به نحوی محدودتر می‌شوند. در الگوریتم جستجوی ممنوعه هنگام کشف راه‌حل‌های جدید، از دانشی که از حرکات قبلی به دست آمده نیز استفاده^{۲۱} می‌شود. این باعث می‌شود که انتخاب همسایه‌ها بیشتر به صورت راهبردی^{۲۲} انجام شود تا تصادفی.

در این الگوریتم لیستی از آخرین حرکات نگهداری می‌شود که لیست ممنوعه نامیده می‌شود. در هر تکرار الگوریتم، انتخاب حرکت‌هایی که در لیست ممنوعه قرار دارند، غیرمجاز است یا با جریمه همراه است. راه‌حل‌هایی که در لیست ممنوعه قرار دارند، از به دام افتادن الگوریتم در چرخه جلوگیری می‌کنند. بنابراین زمان الگوریتم برای جستجوی راه‌حل‌های تکراری به هدر نمی‌رود. برای تعیین نحوه تشکیل لیست ممنوعه - یعنی نحوه انتخاب راه‌حل‌ها برای قرار گرفتن در لیست ممنوعه - روش‌های مختلفی وجود دارد [۳۱]. نوعی از الگوریتم جستجوی ممنوعه به نام جستجوی ممنوعه احتمالی وجود دارد که در آن برای پذیرش راه‌حل‌ها یا انتقال آنها با لیست ممنوعه از محاسبه یک احتمال استفاده می‌شود. با ترکیب الگوریتم جستجوی ممنوعه و الگوریتم شبیه‌سازی تبرید، نوعی از الگوریتم جستجوی ممنوعه احتمالی ایجاد می‌شود. از آنجا که در پژوهش‌های متعددی نشان داده شده است که ترکیب الگوریتم شبیه‌سازی تبرید با الگوریتم جستجوی ممنوعه موجب بهبود کارایی آن می‌شود [۳۲-۳۵]، در این پژوهش یک الگوریتم ترکیبی بر مبنای این دو الگوریتم طراحی شده و مورد استفاده قرار گرفته است. در روش پیشنهادی نحوه تشکیل لیست ممنوعه بر مبنای شرط‌های الگوریتم شبیه‌سازی تبرید تعیین می‌شود.

۳-۱- الگوریتم بهینه‌سازی پیشنهادی

در الگوریتم ترکیبی پیشنهادی نیز مانند الگوریتم شبیه‌سازی تبرید یک متغیر دما و یک تابع انرژی وجود دارد. در هر تکرار، حالت جدیدی به دست می‌آید. اگر حالت جدید در لیست ممنوعه باشد، از حرکت به آن جلوگیری می‌شود و حالت جدیدی ایجاد می‌شود. در غیر این صورت، انرژی آن با حالت فعلی مقایسه می‌شود. در صورتی که انرژی کاهش یافته باشد جایگزین حالت فعلی می‌شود و در غیر این صورت احتمال پذیرش آن محاسبه می‌شود. اگر این احتمال از یک عدد تصادفی بزرگتر باشد، راه‌حل جدید پذیرفته می‌شود و در غیر این صورت در لیست ممنوعه قرار می‌گیرد. تا زمانی که لیست ممنوعه پر شود به این شیوه عمل می‌شود. بعد از پر شدن لیست ممنوعه، قدیمی‌ترین عضو آن خارج می‌شود و عضو جدید اضافه می‌شود.

استفاده شده است. این رابطه، عکس مجموع امتیازهای پیش‌بینی شده‌ی اقلام لیست توصیه را محاسبه می‌کند.

$$\text{Accuracy} = \frac{1}{\sum_{\text{item}=1}^k \text{Prediction}(\text{item})} \quad (7)$$

۲-۱-۲- جزئیات الگوریتم بهینه‌سازی پیشنهادی

لیست توصیه ورودی این الگوریتم بر مبنای امتیازی که با روش ترکیبی برای اقلام پیش‌بینی شده است ایجاد می‌شود. به این ترتیب که از بین کل اقلام قابل توصیه به کاربر، k قلم با امتیاز بالاتر انتخاب می‌شوند و در لیست توصیه قرار می‌گیرند. این لیست توصیه به عنوان ورودی به الگوریتم ترکیبی پیشنهادی که آن را به اختصار MOSA-TS می‌نامیم، وارد می‌شود. شبه کد این الگوریتم در شکل ۲ نشان داده شده است. مراحل این شبه کد در ادامه توضیح داده می‌شود.

ابتدا لیست توصیه ورودی به عنوان حالت فعلی در الگوریتم در نظر گرفته می‌شود و current-st نامیده می‌شود.

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

۱. یک حالت جدید تصادفی از همسایگی current-st انتخاب می‌شود و در new-st قرار می‌گیرد.

۲. اگر new-st در لیست ممنوعه وجود نداشته باشد مرحله ۳ انجام می‌شود.

۳. 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، به new-st منتقل می‌شویم یعنی current-st با new-st مقادری می‌شود.

▪ در غیر این صورت، احتمال پذیرش new-st با استفاده از رابطه $P_{\text{acceptance}} = 1 / (1 + \exp(\Delta \text{dom}_{\text{new-st, current-st}} * \text{temperature}))$ محاسبه می‌شود. در این رابطه دلتا یا اختلاف انرژی از رابطه ۲-۷ به دست می‌آید. سپس، یک عدد تصادفی بین صفر و یک تولید می‌شود:

○ اگر این عدد از $P_{\text{acceptance}}$ کمتر باشد، new-st پذیرفته می‌شود و current-st با new-st مقادری می‌شود.

○ در غیر این صورت، new-st در لیست ممنوعه قرار داده می‌شود. اگر لیست توصیه پر شده است، اولین عنصر آن خارج می‌شود.

۴- ارزیابی روش پیشنهادی

در این بخش روش پیشنهادی مورد ارزیابی قرار می‌گیرد. در ابتدا مجموعه داده‌های مورد استفاده معرفی می‌شوند. سپس الگوریتم‌هایی که برای مقایسه با الگوریتم پیشنهادی پیاده‌سازی شده‌اند توضیح داده می‌شوند. در بخش بعد معیارهای ارزیابی روش پیشنهادی معرفی می‌گردند. سپس تنظیم پارامترها و در نهایت نتایج عملی ارائه می‌شوند و جمع‌بندی می‌گردند.

۴-۱- مجموعه داده‌ها

برای ارزیابی روش پیشنهادی از ترکیب دو مجموعه داده [۴۰] Movielens و [۴۱] Netflix استفاده شده است. داده‌های مربوط به خصوصیات اقلام از مجموعه داده Movielens و داده‌های مربوط به امتیازهای کاربران از Netflix به دست آمده است. پس از ترکیب بخشی از این دو مجموعه داده، مجموعه داده جدیدی به دست آمد 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.

نیز در نظر گرفته شود. به منظور تأثیرگذاری بیشتر داده‌های کوتاه مدت بر محاسبه تنوع‌گرایی کاربر این روش به کار گرفته شده است که ابتدا آنتروپی ترجیحات هر کاربر به صورت ماهانه به دست آید و سپس جمع وزن دار آنها محاسبه شود. به طوری که وزن آنتروپی ماه‌های اخیر بیشتر باشد. برای محاسبه تنوع لیست توصیه معادله‌ای که معمولاً در پژوهش‌ها استفاده می‌شود در رابطه ۴ آمده است [۳، ۱۲، ۱۷].

$$\text{Diversity}(c_1, \dots, c_n) = \frac{\sum_{i=1}^n \sum_{j=i+1}^n (1 - \text{similarity}(c_i, c_j))}{\frac{n}{2} * (n-1)} \quad (4)$$

در رابطه بالا، c_1 تا c_n اقلام لیست توصیه هستند. Similarity شباهت بین دو قلم کالا را نشان می‌دهد. به منظور به دست آوردن تنوع بر مبنای خصوصیات، به ازای هر یک از خصوصیات اقلام، تنوع لیست محاسبه می‌شود. مقدار similarity در رابطه ۴ با استفاده از رابطه شباهت کسینوسی (رابطه ۵) برای آن خصوصیت به دست می‌آید.

$$\text{similarity}(i, j) = \frac{D_i \cdot D_j}{|D_i| |D_j|} \quad (5)$$

رابطه ۲ نشان‌دهنده میزان شخصی‌سازی تنوع از نظر خصوصیت a است و هرچه این مقدار کمتر باشد، تنوع لیست توصیه با تنوع ایده‌آل برای کاربر از لحاظ خصوصیت a انطباق بیشتری دارد. آنتروپی ترجیحات کاربر و تنوع لیست توصیه هر دو بر مبنای درصد محاسبه می‌شوند. به ازای هر یک از خصوصیات اقلام، یک تابع هدف شخصی‌سازی تنوع تعریف می‌شود.

تابع هدف دوم: مجموع محبوبیت اقلام لیست توصیه

یکی از راه‌های افزایش مشارکت اقلام دنباله طولانی، کاهش میزان محبوبیت اقلام لیست توصیه است. بنابراین هدف دوم نیز به منظور افزایش مشارکت اقلام دنباله طولانی در توصیه‌ها براساس کاهش محبوبیت اقلام لیست توصیه تعریف می‌گردد. در این پژوهش میزان محبوبیت اقلام با شمارش تعداد دفعات مشارکت هر قلم کالا در کل توصیه‌ها به دست می‌آید [۱، ۳۸، ۳۹]. رابطه ۶ تابع هدف دوم را نشان می‌دهد.

$$\text{LongTail} = \sum_{\text{item}=1}^k \text{Popularity}(\text{item}) \quad (6)$$

در این رابطه Popularity میزان محبوبیت قلم کالا است که با شمارش تعداد دفعات مشارکت آن در کل توصیه‌ها به دست می‌آید و k تعداد اعضای لیست توصیه است. مقادیر کمتر برای این رابطه نشان‌دهنده این است که اقلامی که محبوبیت کمتری دارند بیشتر درون لیست قرار گرفته‌اند و بنابراین احتمال استفاده از اقلام دنباله طولانی افزایش می‌یابد. بنابراین کمینه کردن این مقدار به عنوان هدف دوم الگوریتم بهینه‌سازی در نظر گرفته می‌شود.

تابع هدف سوم: معکوس جمع امتیازات پیش‌بینی شده

با توجه به موازنه بین دقت و تنوع، هنگامی که تنوع لیست توصیه تغییر می‌کند، ممکن است دقت لیست توصیه نیز تحت تأثیر قرار بگیرد. بنابراین لازم است به معیار دقت به طور همزمان با معیارهای دیگر توجه شود. برای سنجیدن میزان دقت لیست توصیه‌ی به دست آمده در هر تکرار الگوریتم شبیه‌سازی تبرید، از مجموع امتیاز پیش‌بینی شده‌ی 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 ۷

پژوهش قبلی نشان داده شد که تنوع‌بخشی شخصی‌سازی شده روی بهبود دقت و مشارکت بیشتر اقلام دنباله طولانی تأثیرگذار خواهد بود. به همین دلیل در ادامه از این معیار صرف‌نظر خواهیم کرد و تنها به هدف اصلی پژوهش یعنی مشارکت اقلام دنباله طولانی خواهیم پرداخت. همچنین معیار دقت برای الگوریتم‌های مورد ارزیابی اندازه‌گیری خواهد شد. تحلیل نتایج براساس این دو جنبه از سیستم توصیه‌گر نشان خواهد داد که الگوریتم پیشنهادی تا چه حد در توجه همزمان به جنبه‌های مختلف سیستم توصیه‌گر موفق بوده است و به عبارت دیگر تا چه حد بین توجه به دو جنبه از سیستم توصیه‌گر تعادل برقرار کرده است.

معیارهای ارزیابی برای مقایسه نتایج به صورت زیر تعریف می‌شوند:

دقت: برای ارزیابی دقت از معیار دقت دسته‌بندی که در پژوهش‌های بسیاری مورد استفاده قرار گرفته است [۱، ۲۵، ۲۷]. رابطه معیار اندازه‌گیری دقت در رابطه ۸ آمده است. در این رابطه N_s تعداد کل اقلام توصیه شده به کاربران است و N_{rs} تعداد اقلام مرتبط توصیه شده به کاربران را نشان می‌دهد. برای استفاده از این معیار، لازم است اقلام به نحوی به دو گروه مرتبط و نامرتبط تقسیم شوند. در بسیاری از پژوهش‌ها میانگین دامنه امتیازهای ممکن را به عنوان حد آستانه در نظر می‌گیرند و اقلام را براساس این حد آستانه به دو قسمت تقسیم می‌کنند. در مجموعه داده مورد استفاده در این پژوهش، امتیازهایی که به اقلام داده شده عددی بین ۱ تا ۵ است و طبق این روش می‌توان مقدار ۳ را به عنوان آستانه در نظر گرفت. اما از آنجا که ممکن است کاربران روش‌های مختلفی برای امتیازدهی داشته باشند در نظر گرفتن یک حد آستانه برای همه کاربران ممکن است نتیجه درستی در پی نداشته باشد [۸]. به عنوان مثال فردی که سخت‌گیرتر است ممکن است اغلب امتیازهایی که به اقلام داده کمتر از ۳ باشد و فردی دیگر به اکثر اقلام امتیازهایی بالاتر از ۳ داده باشد. واضح است که در نظر گرفتن میانگین به عنوان آستانه برای این دو فرد نمی‌تواند تعیین‌کننده میزان علاقه فرد به اقلام بالاتر از آستانه باشد و با این روش ممکن است دقت توصیه‌ها برای فرد سخت‌گیر همواره مقدار بسیار کمی محاسبه شود. به همین دلیل روشی که برای اندازه‌گیری دقت دسته‌بندی در این پژوهش پیشنهاد می‌شود این است که برای هر کاربر میانگین امتیازهای خود او به عنوان آستانه مرتبط بودن اقلام به آن کاربر در نظر گرفته شود.

$$\text{Precision} = \frac{N_{rs}}{N_s} \quad (8)$$

میانگین امتیاز: علاوه بر معیار بالا، می‌توان 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 دسته‌بندی اقلام به دو دسته مورد مرتبط و نامرتبط، میزان علاقه‌مندی کاربر به اقلام به صورت پیوسته به دست می‌آید. این معیار را می‌توان به عنوان تکمیل‌کننده معیار دقت دسته‌بندی که علاقه‌مندی کاربر را به صورت گسسته تفسیر می‌کند، به کار گرفت.

دنباله طولانی: برای سنجش تأثیر الگوریتم توصیه‌گر روی استفاده از اقلام دنباله طولانی، تعداد اقلام دنباله طولانی که در یک دور اجرای الگوریتم در توصیه‌ها شرکت کردند در نظر گرفته می‌شود. به این منظور اقلامی که در داده‌های آموزشی در ۸۰٪ توصیه‌ها شرکت کرده‌اند به عنوان اقلام محبوب و مابقی به عنوان اقلام دنباله طولانی برچسب‌گذاری شده‌اند.

نوآوری: معیار نوآوری، توانایی توصیه‌گر را در ارائه اقلام جدید و ناشناخته برای کاربر نشان می‌دهد. این معیار در تعدادی از پژوهش‌ها به صورت تابعی از میزان محبوبیت اقلام توصیف شده است [۲۵، ۲۷، ۴۲]. در این پژوهش نیز با توجه به اینکه میزان استفاده از اقلام نامحبوب روی هدف اصلی این پژوهش تأثیرگذار است، از معیار نوآوری نیز برای سنجش کارایی سیستم استفاده شده است. در این

داده‌ها به دو قسمت داده‌های آموزشی و آزمایشی تقسیم شده‌اند. به دلیل اینکه در روش پیشنهادی براساس گذشته یک کاربر میزان علاقه او به تنوع محاسبه می‌شود، و گذشت زمان بر تنوع‌گرایی کاربر مؤثر است، ترتیب زمانی برای انتخاب داده‌های آموزشی و آزمایشی مهم است، به همین دلیل داده‌ها به صورت تصادفی انتخاب نشده‌اند بلکه براساس زمان ثبت آنها انتخاب شده‌اند. کل مجموعه داده و همچنین مجموعه داده آموزشی از نظر توزیع توصیه‌ها بین اقلام بررسی شد و مشاهده شد که در این دو مجموعه داده پدیده دنباله طولانی وجود دارد.

Algorithm MOSA-TS

Input: List1

Set Temperature, minTemperature, alpha

current-st: = List1

while (Temperature < minTemperature)

new-st: = GenerateNext(current-st)

if (new-st is not in TabuList)

CheckDomination (new-st, current-st)

If (new-st dominates current-st)

current-st = new-st

else /* current-st dominates new-st */

Prob = Random (0, 1)

If (Prob < 1 / 1 + Exp (Δdomavg * Temperature))

current-st: = new-st

else

if (TabuList is full)

remove the first item from TabuList

Add next-state to TabuList

Temperature: = Temperature * alpha

Return current-st

شکل ۲- شبه کد الگوریتم پیشنهادی

در مجموعه داده مورد استفاده، دو خصوصیت سبک فیلم و سال تولید آن وجود دارد. اما با توجه به اینکه خصوصیت سال مقادیر گوناگونی دارد، در تنوع‌بخشی از آن استفاده نشده است. به عنوان مثال فرض می‌کنیم فیلم a مربوط به سال ۱۹۹۸، فیلم b مربوط به سال ۱۹۹۹ و فیلم c مربوط به سال ۲۰۰۵ باشد. اگر فردی به فیلم‌های a و b علاقه داشته باشد این طور برداشت می‌شود که این فرد به فیلم‌های قدیمی علاقه‌مند است. در مقابل، اگر فرد دیگری به فیلم‌های a و c علاقه‌مند باشد این طور تفسیر می‌شود که این فرد به گستره متنوع‌تری از فیلم‌ها از لحاظ سال تولید آنها علاقه‌مند است. بنابراین میزان تنوع‌گرایی باید برای فرد اول کمتر و برای فرد دوم بیشتر محاسبه شود. اما با روشی که برای محاسبه آنتروپی در نظر گرفته شده است، آنتروپی برای هر دو فرد یکسان محاسبه می‌شود و همین که دو مقدار سال فیلم با هم متفاوت باشند به منزله تنوع‌گرایی فرد تعبیر می‌شود. بنابراین برای استفاده از خصوصیت سال لازم است روش دیگری استفاده شود که در این پژوهش به آن پرداخته نشده است. بنابراین تنها از آنتروپی سبک فیلم استفاده خواهد شد.

۴-۲- نتایج عملی

در این بخش نتایج اعمال روش پیشنهادی روی مجموعه داده‌ها بررسی می‌شود. نتایج روش پیشنهادی با روش ارائه شده در [۲۲] مقایسه خواهد شد. در دو

الگوریتم MOSA برای مشارکت اقلام دنباله طولانی در لیست توصیه پنج عضو مناسبتر است. برای لیست توصیه هفت عضو، الگوریتم HTabuMOSA-10 مشارکت اقلام دنباله طولانی را با توجه به معیار تنوع تجمعی نسبت به الگوریتم MOSA بهبود داده است و از نظر معیار دنباله طولانی مقداری مساوی با آن دارد. همچنین این الگوریتم دقت را نیز نسبت به الگوریتم MOSA افزایش داده است. بنابراین الگوریتم HTabuMOSA-10 برای لیست توصیه هفت عضو نیز کارایی دارد. به طور کلی الگوریتم HTabuMOSA در لیست هفت عضو بهتر از الگوریتم MOSA عمل کرده است. در مورد لیست ۱۰ عضو نیز الگوریتم HTabuMOSA-25 از نظر مشارکت اقلام دنباله طولانی و همچنین دقت توصیه‌ها بهتر از MOSA عمل کرده است. بنابراین نسخه‌های مختلف الگوریتم HTabuMOSA بر الگوریتم MOSA برتری دارند.

نتایج ارائه شده در این بخش نشان داد که الگوریتم بهینه‌سازی چندهدفه پیشنهادی که از ترکیب الگوریتم‌های جستجوی ممنوعه و شبیه‌سازی تبرید به دست آمده است، کارایی بهتری در مقایسه با الگوریتم شبیه‌سازی تبرید چندهدفه دارد.

۵- نتیجه‌گیری

عدم توجه به تمامی جنبه‌های سیستم‌های توصیه‌گر در بسیاری از الگوریتم‌های توصیه رایج موجب شده است که از توصیه برخی از اقلام جلوگیری شود. این اقلام، اقلام نامحبوب یا اقلام دنباله طولانی نامیده می‌شوند. در این پژوهش برای حل مسئله عدم توصیه اقلام دنباله طولانی از تنوع‌بخشی شخصی‌سازی شده استفاده شد. برای این منظور یک روش بهینه‌سازی ترکیبی چندهدفه با هدف بهینه‌سازی دقت، شخصی‌سازی تنوع و مشارکت اقلام دنباله طولانی در توصیه‌ها ارائه شد. این روش بر مبنای دو الگوریتم شبیه‌سازی تبرید و جستجوی ممنوعه طراحی شد. سه تابع هدف برای الگوریتم بهینه‌سازی تعریف شد. برای شخصی‌سازی تنوع ابتدا میزان تنوع‌گرایی کاربر با استفاده از آنتروپی ترجیحات کاربر به دست آمد و سپس با استفاده از الگوریتم بهینه‌سازی پیشنهادی سعی شد که فاصله تنوع لیست توصیه با آنتروپی ترجیحات کاربر کمینه شود. برای بهینه‌سازی مشارکت اقلام دنباله طولانی، مجموع محبوبیت اقلام لیست توصیه محاسبه شد و کمینه شدن آن توسط الگوریتم پیشنهادی انجام شد. بهینه‌سازی دقت نیز از طریق بیشینه کردن مجموع امتیازات پیش‌بینی شده اقلام لیست توصیه انجام شد. ارزیابی الگوریتم پیشنهادی با استفاده از داده‌های Netflix و ترکیب آن با داده‌های Movielense انجام شد.

برای ارزیابی الگوریتم پیشنهادی، نتایج آن با روشی که توسط الگوریتم شبیه‌سازی تبرید چندهدفه در پژوهش قبلی ارائه شده بود مقایسه شد. پنج معیار ارزیابی دقت، میانگین امتیاز، دنباله طولانی، نوآوری و تنوع تجمعی تعریف شد. نتایج مقایسه الگوریتم پیشنهادی برای لیست‌های توصیه با اندازه‌های ۳، ۵، ۷ و ۱۰ نشان داد که روش ترکیبی پیشنهادی این پژوهش نسبت به الگوریتم شبیه‌سازی تبرید تنها، کارایی بیشتری دارد و در اکثر موارد ضمن افزایش مشارکت اقلام دنباله طولانی، دقت توصیه نیز بهبود پیدا کرده است. بنابراین استفاده از روش بهینه‌سازی ترکیبی پیشنهادی برای بهبود همزمان چند معیار در سیستم توصیه‌گر موفق بوده است.

به منظور ارزیابی بهتر روش پیشنهادی و بهبود آن، در آینده می‌توان از مجموعه داده‌های بیشتری برای ارزیابی استفاده کرد. همچنین می‌توان با گرفتن بازخورد از کاربران سیستم توصیه‌گر ارزیابی بهتری از مشارکت اقلام دنباله طولانی داشت. به علاوه در کارهای آینده می‌توان الگوریتم‌های بهینه‌سازی ترکیبی دیگری را مورد آزمایش و مقایسه قرار داد.

پژوهش نوآوری به صورت عکس مجموع محبوبیت اقلام توصیه شده اندازه‌گیری می‌شود که در رابطه ۹ نشان داده شده است.

$$\text{Novelty} = \frac{1}{\sum_{\text{All recommended items}} \text{Popularity}(\text{item})} \quad (9)$$

تنوع تجمعی: در پژوهش‌ها با استفاده از مجموع اقلام متمایزی که به در کل توصیه‌ها شرکت کرده‌اند، اندازه‌گیری شده است [۱، ۱۶، ۳۸، ۳۹، ۴۳]. در این پژوهش نیز از این روش استفاده می‌شود. مقادیر کمتر برای این معیار نشان‌دهنده این است که تمرکز توصیه‌گر روی درصد کمی از اقلام است و بیشتر به توصیه‌ی اقلام محبوب می‌پردازد و مقادیر بیشتر نشان می‌دهد که توصیه‌گر به زیرمجموعه بزرگتری از اقلام توجه دارد و احتمال توصیه اقلام دنباله طولانی توسط توصیه‌گر بیشتر است.

نتایج ارزیابی الگوریتم‌ها در جدول ۱ نشان داده شده است. روش پیشنهادی این پژوهش با سه اندازه مختلف برای لیست ممنوعه ارزیابی شده است. نتایج تمامی الگوریتم‌ها نیز برای چهار اندازه مختلف برای لیست توصیه به دست آمده است. در این جدول الگوریتم پیشنهادی در پژوهش قبلی با عنوان MOSA نشان داده شده است. الگوریتم پیشنهادی این پژوهش با اندازه لیست ممنوعه ۱۰ با عنوان HTabuMOSA-10 و دو الگوریتم دیگر نیز به همین روش نام‌گذاری شده‌اند.

جدول ۱- نتایج ارزیابی

معیارها	الگوریتم‌ها	۳	۵	۷	۱۰
دقت	MOSA	۸۳/۳۳	۸۸/۰	۸۶/۰۷	۸۴/۵
	HTabuMOSA-10	۸۱/۰۱	۸۹/۵	۸۶/۲	۸۶/۰
	HTabuMOSA-25	۸۶/۰۵	۸۷/۵	۸۳/۷۱	۸۵/۰
	HTabuMOSA-50	۸۴/۸۸	۸۴/۰	۸۵/۲۲	۸۴/۷۵
میانگین امتیاز	HTabuMOSA-50	۳/۱۷	۳/۳۲	۳/۱۸	۳/۱۶
	HTabuMOSA-10	۲/۹۵	۳/۳۷	۳/۱۷	۳/۱۸
	HTabuMOSA-25	۳/۰۹	۳/۲۶	۳/۱۳	۳/۲
	HTabuMOSA-50	۳/۱۷	۳/۲۳	۳/۱۶	۳/۰۹
دنباله طولانی	MOSA	۶۹/۷۷	۷۵/۰	۷۱/۲۶	۶۷/۵
	HTabuMOSA-10	۶۸/۲۲	۷۰/۰	۷۱/۲۶	۷۰/۲۵
	HTabuMOSA-25	۶۹/۳۸	۷۱/۰	۷۰/۴۳	۷۱/۲۵
	HTabuMOSA-50	۷۳/۲۶	۷۲/۵	۷۰/۵۹	۶۶/۵
نوآوری	MOSA	۶۱/۴	۱۱/۵۸	۱۱/۲۳	۲۳/۰۵
	HTabuMOSA-10	۵۹/۲۵	۹/۹۱	۱۱/۲۸	۲۶/۰۲
	HTabuMOSA-25	۵۹/۳۴	۱۱/۰۵	۱۱/۶۲	۲۶/۴۴
	HTabuMOSA-50	۶۳/۵۸	۱۰/۱۲	۱۱/۷۴	۲۲/۸۳
تنوع تجمعی	MOSA	۲۰/۹۳	۲۵/۵	۱۷/۶۱	۱۳/۷۵
	HTabuMOSA-10	۲۰/۱۶	۲۴/۰	۱۷/۹۴	۱۳/۲۵
	HTabuMOSA-25	۱۹/۷۷	۲۳/۰	۱۷/۶۱	۱۴/۰
	HTabuMOSA-50	۲۰/۵۴	۲۳/۵	۱۶/۴۷	۱۲/۷۵

با بررسی این جدول می‌توان برای اندازه‌های مختلف لیست توصیه، بهترین الگوریتم را از بین الگوریتم‌های مورد ارزیابی انتخاب کرد. برای لیست توصیه سه عضو، می‌توان الگوریتم HTabuMOSA-50 را به عنوان بهترین الگوریتم انتخاب کرد. به دلیل اینکه از لحاظ دقت و مشارکت اقلام دنباله طولانی بهتر از سایر الگوریتم‌های مورد ارزیابی عمل کرده است و تنها از نظر معیار تنوع تجمعی در رتبه اول قرار نگرفته است. برای لیست توصیه پنج عضو، الگوریتم HTabuMOSA-10 دقت توصیه‌ها را افزایش داده است اما قادر به افزایش مشارکت اقلام دنباله طولانی نسبت به الگوریتم MOSA نبوده است. بنابراین

Berlin, Heidelberg, 2001, pp. 347-361.

مراجع

- [13] 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.
- [14] 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," In *Proceedings of the 7th ACM international conference on Web search and data mining*, 2014, pp. 253-262.
- [15] Y. J. Park, and A. Tuzhilin, "The long tail of recommender systems and how to leverage it," In *Proceedings of the 2008 ACM conference on Recommender systems*, 2008, pp. 11-18.
- [16] G. Adomavicius, and Y. Kwon, "Overcoming accuracy-diversity tradeoff in recommender systems: a variance-based approach," In *Proceedings of the 18th workshop on information technology and systems (WITS'08)*, Paris, vol. 8, 2008.
- [17] I. Avazpour, T. Pitakrat, L. Grunske, and J. Grundy, "Dimensions and metrics for evaluating recommendation systems," in *Recommendation systems in software engineering*, pp. 245-273, 2014.
- [18] Ò. Celma, "The Long Tail in Recommender Systems," In *Music Recommendation and Discovery*, Springer, pp. 87-107, 2010.
- [19] Y. Shi, X. Zhao, J. Wang, M. Larson, and A. Hanjalic, "Adaptive diversification of recommendation results via latent factor portfolio," In *Proceedings of the 35th international ACM SIGIR conference on Research and development in information retrieval*, 2012, pp. 175-184.
- [20] S. Vargas, and P. Castells, "Exploiting the diversity of user preferences for recommendation," In *Proceedings of the 10th Conference on Open Research Areas in Information Retrieval*, 2013, pp. 129-136.
- [21] L. Chen, W. Wu, and L. He, "How personality influences users' needs for recommendation diversity?," In *CHI'13 Extended Abstracts on Human Factors in Computing Systems*, pp. 829-834, 2013.
- [۲۲] ۱. ملک‌زاده همدانی و م. کاندی، "توصیه اقلام دنباله طولانی با استفاده از تنوع‌بخشی شخصی‌سازی‌شده در سیستم‌های توصیه‌گر"، در مجموعه مقالات بیست و دومین کنفرانس ملی سالانه انجمن کامپیوتر ایران، تهران، ۱۳۹۵.
- [23] L. Chen, W. Wu, and L. He, "Personality and Recommendation Diversity," In *Emotions and Personality in Personalized Services*, pp. 201-225, 2016.
- [24] T. Di Noia, J. Rosati, P. Tomeo, and E. Di Sciascio, [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] F. Ricci, L. Rokach, and B. Shapira, "Introduction to Recommender Systems Handbook," In *Recommender systems handbook*, (pp. 1-35). Springer, Boston, MA, US, 2011.
- [3] K. Bradley, and B. Smyth, "Improving recommendation diversity," In *Proceedings of the Twelfth Irish Conference on Artificial Intelligence and Cognitive Science* Maynooth, Ireland, 2001, pp. 85-94.
- [4] 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.
- [5] W. Wu, L. Chen, and L. He, "Using personality to adjust diversity in recommender systems," In *Proceedings of the 24th ACM Conference on Hypertext and Social Media*, 2013, pp. 225-229.
- [6] 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.
- [7] 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.
- [8] S. M. Mcnee, "Meeting user information needs in recommender systems," University of Minnesota, 2006.
- [9] 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.
- [10] T. Di Noia, V. C. Ostuni, J. Rosati, P. Tomeo, and E. Di Sciascio, "An analysis of users' propensity toward diversity in recommendations," In *Proceedings of the 8th ACM Conference on Recommender systems*, 2014, pp. 285-288.
- [11] C. N. Ziegler, S. M. McNee, J. A. Konstan, and G. Lausen, "Improving recommendation lists through topic diversification," In *Proceedings of the 14th international conference on World Wide Web*, 2005, pp. 22-32.
- [12] B. Smyth, and P. McClave, "Similarity vs .Diversity," In *International Conference on Case-Based Reasoning*,

Power & Energy Systems, vol. 82, pp. 87-91, 2016.

[36] 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.

[37] P. Basile, A. Caputo, M. de Gemmis, P. Lops, and G. Semeraro, "Modeling Short-Term Preferences in Time-Aware Recommender Systems," In Proceedings of UMAP Workshop, Dublin, 2015.

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

[39] S. Singh, S. Bag, and M. Jenamani, "Relative similarity based approach for improving aggregate recommendation diversity," In 2015 Annual IEEE India Conference (INDICON), 2015, pp. 1-6.

[40] Movielens. Available: <http://grouplens.org/datasets/movielens/>, Mar. 2015.

[41] Netflix Prize Dataset. Available: <http://academictorrents.com/>, May. 2015.

[42] S. Vargas, "Novelty and diversity enhancement and evaluation in Recommender Systems," Master's Thesis, Autonomous University of Madrid, 2012.

[43] L. Shi, "Trading-off among accuracy, similarity, diversity, and long-tail: a graph-based recommendation approach," In Proceedings of the 7th ACM conference on Recommender systems, 2013, pp. 57-64.

[43] 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

الهه ملک‌زاده همدانی مدرک کارشناسی را در رشته

مهندسی کامپیوتر از دانشگاه پیام نور همدان و مدرک

کارشناسی ارشد را در رشته مهندسی فناوری اطلاعات از

دانشگاه اصفهان دریافت کرده است. زمینه‌های تحقیقاتی

مورد علاقه وی گردشگری الکترونیکی، سیستم‌های



توصیه‌گر و داده‌کاوی است.

آدرس پست‌الکترونیکی ایشان عبارت است از:

elaheh.malekzadeh@yahoo.com

"Adaptive multi-attribute diversity for recommender systems," Information Sciences, vol. 382, pp. 234-253, 2017.

[25] 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.

[26] M. T. Ribeiro, A. Lacerda, A. Veloso, and N. Ziviani, "Pareto-efficient hybridization for multi-objective recommender systems," In Proceedings of the sixth ACM conference on Recommender systems, 2012, pp. 19-26.

[27] 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.

[۲۸] ا. ملک‌زاده همدانی و م. کاندی، "نوع‌بخشی شخصی‌سازی‌شده در سیستم توصیه‌گر با استفاده از الگوریتم شبیه‌سازی تبرید دوده‌دانه،" مجله علوم رایانشی، شماره ۳، ص ۶۷-۸۲، ۱۳۹۵.

[29] K. Tso, and L. Schmidt-Thieme, "Attribute-aware collaborative filtering," In Proceedings of the 29th Annual Conference of the Gesellschaft für Klassifikation e.V. University of Magdeburg, Berlin, Heidelberg, 2006, pp. 614-621.

[30] S. Wang, M. Gong, H. Li, and J. Yang, "Multi-objective optimization for long tail recommendation," Knowledge-Based Systems, vol. 104, pp. 145-155, 2016.

[31] F. Glover, E. Taillard, and E. Taillard, "A user's guide to tabu search," Annals of operations research, vol. 41, no. 1, pp. 1-28, 1993.

[32] I. H. Osman, and N. Christofides, "Capacitated clustering problems by hybrid simulated annealing and tabu search," International Transactions in Operational Research, vol. 1, no. 3, pp. 317-336, 1994.

[33] S. R. Thangiah, I. H. Osman, and T. Sun, "Hybrid genetic algorithm, simulated annealing and tabu search methods for vehicle routing problems with time windows," Computer Science Department, Slippery Rock University, Technical Report SRU CpSc-TR-94-27, vol. 69, 1994.

[34] Y. A. Katsigiannis, P. S. Georgilakis, and E. S. Karapidakis, "Hybrid simulated annealing-tabu search method for optimal sizing of autonomous power systems with renewables," IEEE Transactions on Sustainable Energy, vol. 3, no. 3, pp. 330-338, 2012.

[35] K. Lenin, B. R. Reddy, and M. Suryakalavathi, "Hybrid Tabu search-simulated annealing method to solve optimal reactive power problem," International Journal of Electrical

مرجان کائدی کارشناسی مهندسی کامپیوتر را از دانشگاه صنعتی اصفهان اخذ کرده است و مقاطع کارشناسی ارشد و دکتری را در دانشگاه اصفهان سپری کرده است. ایشان از سال ۱۳۹۱ عضو هیات علمی دانشکده مهندسی کامپیوتر دانشگاه اصفهان است و زمینه تحقیقاتی مورد علاقه وی شامل تجارت الکترونیکی، یادگیری ماشین و بهینه‌سازی است.



آدرس پست‌الکترونیکی ایشان عبارت است از:

kaedi@eng.ui.ac.ir

اطلاعات بررسی مقاله:

تاریخ ارسال: ۱۳۹۶/۰۴/۱۵

تاریخ اصلاح: ۱۳۹۶/۱۰/۲۰

تاریخ قبول شدن: ۱۳۹۷/۰۴/۰۹

نویسنده مرتبط: دکتر مرجان کائدی، دانشکده مهندسی کامپیوتر، دانشگاه اصفهان، اصفهان، ایران.

-
- ¹Preferences
 - ²Unpopular
 - ³Fleder
 - ⁴Collaborative Filtering
 - ⁵www.movielen.com
 - ⁶Histogram
 - ⁷Long Tail Items
 - ⁸Diversity
 - ⁹Trade-Off
 - ¹⁰User Latent Factors
 - ¹¹Big-5 Personality Model
 - ¹²Sale Diversity
 - ¹³Aggregate Diversity
 - ¹⁴Coverage
 - ¹⁵Novelty
 - ¹⁶Multi-Objective Optimization
 - ¹⁷Non-Dominated Sorting Genetic Algorithm
 - ¹⁸Utility
 - ¹⁹Tabu Search
 - ²⁰Explore
 - ²¹Exploit
 - ²²Strategically
 - ²³Attribute-Based Diversity
 - ²⁴Overall Diversity