

طراحی و ایجاد سامانه توصیه‌گر برچسب‌محور بر مبنای شبکه‌های عصبی عمیق

سعید روحانی^{۱*}، رامین زندوکیلی^۲، منوچهر انصاری^۳

- ۱- استادیار، گروه فناوری اطلاعات، دانشکده مدیریت دانشگاه تهران، تهران، ایران
- ۲- دانشجوی کارشناسی ارشد، گروه MBA، دانشکده مدیریت، دانشگاه تهران، تهران، ایران
- ۳- دانشیار، گروه MBA، دانشکده مدیریت، دانشگاه تهران، تهران، ایران

پذیرش: ۱۳۹۶/۱۲/۸

دریافت: ۱۳۹۶/۷/۱۳

چکیده

هدف اصلی این تحقیق، طراحی و پیاده‌سازی سامانه توصیه‌گر فروشگاه‌های آنلاین برچسب‌محور برای یک فروشگاه فیلم‌های سینمایی، جهت بالا بردن فروش اینترنتی است. روش تحقیق انتخاب‌شده، روش تحقیق علم طراحی و آزمایشی است که در آن، در مرحله ارزیابی روش تحقیق علم طراحی، از طراحی آزمایش استفاده شده است. برای بهبود عملکرد سامانه توصیه‌گر، از برچسب‌های گذاشته‌شده توسط کاربران و الگوریتم شبکه‌های عصبی عمیق برای توصیه فیلم‌های سینمایی به آن‌ها استفاده شده است. آزمایشی طراحی و انجام شده است که در آن، سامانه توصیه‌گر برچسب‌محور (که برای توصیه فیلم‌های سینمایی طراحی و ایجاد شده است) با سامانه توصیه‌گر پالایش گروهی (که از سامانه‌های توصیه‌گر جافتاده و معیار است) در معیارهای ارزیابی دقت، به‌یادآوری و F1 مقایسه می‌شود. براساس نتایج، سامانه توصیه‌گر برچسب‌محور بر مبنای شبکه‌های عصبی عمیق در تمام این معیارهای ارزیابی از سامانه پالایش گروهی بهتر عمل می‌کند.

واژگان کلیدی: سامانه توصیه‌گر؛ برچسب‌محور؛ شبکه‌های عصبی عمیق؛ فروشگاه اینترنتی.

۱- مقدمه

به صورت کلی، سامانه‌های توصیه‌گر مستقیماً به کاربران کمک می‌کنند تا محتوا، کالاها یا خدمات (مانند کتاب، محصولات دیجیتال، فیلم، موسیقی، برنامه‌های تلویزیون و...) را با استفاده از جمع‌آوری و تحلیل پیشنهادهای کاربران دیگر بیابند [۱]. این سامانه‌ها از آغاز نوشته شدن اولین مقاله در زمینه سامانه‌های توصیه‌گر پالایش گروهی در اواسط دهه ۹۰ به رشته تحقیقاتی مهمی تبدیل شده‌اند، اما تحقیق بیشتری در زمینه سامانه‌های توصیه‌گر احتیاج است؛ چراکه این حوزه هنوز گسترده‌تر و خام‌تر از حوزه‌های تحقیقاتی دیگر است [۲]. روش‌های مختلفی برای توصیه به کاربران در این سامانه‌ها به کار گرفته شده است. به دلیل سادگی و نتایج خوب، پالایش گروهی^۱ یکی از موفق‌ترین و پراستفاده‌ترین روش‌ها در سامانه‌های توصیه‌گر بوده است [۳]. تُنکی ماتریس امتیازات کاربران به محصولات در پالایش گروهی باعث مشکل شروع سرد می‌شود [۴]. از این‌رو، در یک دهه گذشته اغلب محققان با رویکردهای جدیدتری به دنبال حل مسائل موجود در سامانه‌های سنتی و به‌کارگیری آن‌ها در سامانه‌های واقعی بوده‌اند؛ به‌خصوص به‌کارگیری روش‌های داده‌کاوی در سامانه‌های توصیه‌گر، در ارائه اطلاعات سفارشی و فردی به کاربر از طریق تحلیل ترجیحاتش مؤثر بوده است [۲]. محققان زیادی برای بهبود عملکرد سامانه‌های توصیه‌گر سنتی، برچسب را به این سیستم اضافه کرده‌اند. این برچسب‌ها به‌منزله پُلی بین کاربران و محصولات هستند که به حل مشکل شروع سرد کمک می‌کنند [۵]. اما برچسب‌های اضافه‌شده توسط کاربران معمولاً مشکلاتی از قبیل تُنک بودن^۲، افزونگی^۳ و ابهام^۴ را دارند [۶]. برای حل این مشکلات باید به نحوی ساختار زیرین ارتباط بین برچسب‌ها، کشف و همچنین برچسب‌های تکراری کنار گذاشته شوند [۶]. همچنین از شبکه‌های عصبی عمیق برای توصیه موسیقی و صفحات وب به کاربران استفاده شده است [۶]. در همین راستا، سؤال این تحقیق عبارت است از اینکه آیا عملکرد سامانه توصیه‌گر برچسب‌محور با استفاده از شبکه عصبی عمیق در توصیه فیلم‌های سینمایی از سامانه پالایش گروهی بهتر عمل

1. Collaborative filtering

2. Sparsity

3. Redundancy

4. Ambiguity

می‌کند؟ برای پاسخ به این سؤال آزمایشی طراحی شده است که در آن، سامانه توصیه‌گر برچسب‌محور با شبکه عصبی عمیق با سامانه توصیه‌گر پالایش گروهی مقایسه می‌شود. در ادامه، ابتدا مبانی نظری این پژوهش و سپس روش تحقیق استفاده شده مرور خواهد شد. سپس تجزیه و تحلیل یافته‌ها، و بحث و بررسی نتایج ارائه شده و در انتها، نتیجه‌گیری ارائه می‌شود.

۲- پیشینه نظری پژوهش

در این بخش پیشینه نظری سه حوزه سامانه‌های توصیه‌گر، یادگیری بازنمایی و الگوریتم LBFSG را بررسی می‌کنیم.

۲-۱- سامانه‌های توصیه‌گر

سیستم‌های توصیه‌گر از توانایی پالایش اطلاعات ضمنی برای پیش‌بینی ترجیح یا عدم ترجیح یک محصول خاص به وسیله کاربر در زمان تصمیم‌گیری برای انتخاب برخوردار هستند [۷]. در سالهای اخیر، نسخه‌های متعددی از سیستم‌های پیشنهاددهنده برای پیشنهاد مفاهیم مختلف در سیستم‌های تجارت الکترونیک و شبکه‌های اجتماعی ارائه شده است [۸]. این سامانه‌ها درباره ترجیحات کاربرانشان در مورد مجموعه‌ای از محصولات (مثل فیلم، موسیقی، کتاب، لطیفه، گجت‌ها، اپلیکیشن‌ها، وبسایت‌ها، مقاصد سفر و محتویات یادگیری آنلاین) اطلاعات جمع‌آوری و از آن‌ها برای توصیه به کاربران استفاده می‌کنند [۹]. سامانه توصیه‌گر می‌تواند از عوامل جمعیت‌شناختی کاربران (مثل سن، جنسیت و ملیت) استفاده کند. اطلاعات اجتماعی مانند افراد دنبال‌شده، دنبال‌کننده، توئیتهای، پست‌ها و برچسب‌ها عموماً در سامانه‌های توصیه‌گر وب [۲] استفاده شده‌اند. در حوزه سامانه‌های توصیه‌گر اجتماعی، کاربران می‌توانند برچسب‌هایی به محصولات اختصاص بدهند. یکی از پرکاربردترین روش‌های توصیه به کاربران، روش‌های پالایش گروهی (CF) هستند؛ هرچند که برای بهبود عملکرد، آن‌ها اغلب با دیگر روش‌های پالایش مثل محتوای محور، دانش‌محور و اجتماعی ترکیب می‌شوند [۱۰] اما این سامانه‌ها معمولاً با مشکل شروع سرد درگیر هستند که زمانی اتفاق می‌افتد که پیشنهاد توصیه‌های قابل اعتماد به دلیل عدم وجود امتیازدهی کاربران ممکن نباشد [۳]. مشکل شروع سرد اغلب با استفاده از پالایش ترکیبی بهبود می‌یابد (معمولاً پالایش ترکیبی

محتوای محور، پالایش ترکیبی جمعیت شناختی و پالایش ترکیبی شبکه اجتماعی) [۱]. برای کاستن مشکل میزان بالای تنگی در پایگاه‌های داده سامانه توصیه‌گر، بعضی مطالعات از روش‌های کاهش بُعد، استخراج عوامل و یادگیری بازنمایی استفاده کرده‌اند [۱۱].

۲-۲- یادگیر بازنمایی

یادگیری بازنمایی، یعنی یادگیری بازنمایی‌هایی از داده‌ها که در بیرون کشیدن اطلاعات مفید در هنگام ساختن اپلیکیشن‌های گروه‌بندی یا دیگر پیش‌بینی‌کننده‌ها، بتوانند استفاده شوند [۱۲]. روش‌های یادگیری عمیق یکی از انواع راه‌های یادگیری بازنمایی هستند. این روش‌ها از طریق قرار دادن چندین تبدیل‌گر غیرخطی بعد از یکدیگر به دنبال دستیابی به بازنمایی‌های انتزاعی‌تر و درنهایت، مفیدتر هستند [۱۲]. ایده محوری که با نام «پیش‌تعلیم غیرنظارتی زیاده‌خواه لایه‌ای» خوانده می‌شود، این است که سلسله‌مراتبی از خصوصیت‌ها یکی پس از دیگری با استفاده از یادگیری خصوصیت غیر نظارتی یاد گرفته شود تا در هر لایه بتوانیم با استفاده از تبدیل‌هایی که قبلاً آموخته شده‌اند، یک تبدیل جدید یاد بگیریم [۱۳].

۲-۳- الگوریتم بهینه‌سازی L-BFGS

L-BFGS یک الگوریتم بهینه‌سازی از خانواده روش‌های شبه‌نیوتونی است که در آن برای جستجو در فضای متغیرها به جای استفاده از یک تقریب $n \times n$ (بعد فضای متغیرها است) از وارون ماتریس هسیان، از یک تقریب که حافظه کمتری اشغال می‌کند، استفاده می‌شود. این الگوریتم تنها چند بردار را ذخیره می‌کند که می‌توانند فضای تقریب زده شده را بازنمایی کنند. از این رو، این روش بهینه‌سازی برای مسائل با تعداد متغیر زیاد مناسب است [۱۴].

۳- مبانی تجربی

برای گسترش پالایش گروهی به سامانه‌های برچسب‌زنی اجتماعی، رابطه سه‌تایی بین کاربران، محصولات و برچسب‌ها باید به یک فضا با ابعاد کمتر کاسته شود [۱۵]

1. Greedy layer-wise unsupervised pre-training

که اولین مدل از سامانه‌های توصیه‌گر برچسب‌آگاه است. بر اساس این مدل، یک روش توصیه برچسب‌آگاه بر پایه پالایش گروهی در مقاله اف ریچی، ال رکاج و بی شاپیرا [۱۶] ارائه شده است که ابتدا همسایگی کاربر بر اساس تصویرکردن ماتریس کاربر-برچسب محاسبه می‌شود و بعد توصیه بر اساس تجمیع محصولات همسایگی انجام می‌شود. ایده مشابهی در مقاله سی اس فیران و دیگران [۱۷] ارائه شده است که ماتریس تصویر کاربر-برچسب به منظور محاسبه فهرست رتبه‌بندی‌شده‌ای از برچسب‌ها و سپس استخراج توصیه از آن برچسب‌ها به دست آمده است. کرن و دیگران [۱۸] رویکردی ارائه کردند که ماتریس معمول کاربر-محصول را با استفاده از برچسب‌ها تحت عنوان شبه‌کاربران و شبه‌محصولات گسترش دهند. سپس یک الگوریتم ترکیبی از ترکیب پالایش گروهی کاربرمحور و پالایش گروهی محصول‌محور ارائه دادند. به منظور استفاده بهتر از اطلاعات برچسب‌ها، خوشه‌بندی برچسب‌ها در پالایش گروهی به منظور بهبود عملکرد توصیه استفاده شده است. برای رفع مشکل نویزی بودن برچسب‌ها، لیانگ و دیگران [۱۹] از وزن‌های مختلف برای برچسب‌های مختلف استفاده کرده و آن‌ها را با پالایش گروهی حافظه‌محور سنتی ترکیب کرده‌اند. با بازنمایی رابطه کاربر-محصول-برچسب به صورت یک تانسور ما می‌توانیم ساختار معنایی پسینی شکل داده‌شده توسط همبستگی‌های سه‌تایی بین آن‌ها را استخراج کنیم. می‌توان این کار را با الگوریتم‌های توصیه بر مبنای تجزیه تانسوری انجام داد. این کار در مقاله لاتاور و دیگران [۲۰] به منظور تجزیه تانسور کاربر-محصول-برچسب به ضرب سه ماتریس رتبه پایین و یک تانسور رتبه پایین انجام شده است. انجام آن بر روی دو مجموعه داده واقعی بهبودهای معنی‌داری در معیارهای ارزیابی دقت و به یادآوری نشان می‌دهد. در الگوریتم‌های توصیه گراف‌محور با الهام از الگوریتم جستجوی وب، معروف به Page rank، هوتو و دیگران [۲۱] الگوریتم Folk rank را ارائه کردند که در آن یک محصول با برچسب‌های مهم که توسط کاربران مهم برچسب زده شده است، خودش مهم می‌شود و این اصل به صورت متقارن برای کاربران و برچسب‌ها برقرار است. بر اساس این اصل کاربران، محصولات و برچسب‌ها به صورت دوطرفه وزن‌های یکدیگر را تقویت خواهند کرد. در نهایت، چندین محصول یا برچسب با وزن‌های بزرگ‌تر توصیه خواهند شد. زائو و دیگران [۶] یک سامانه توصیه‌گر برچسبی با

استفاده از شبکه‌های عصبی عمیق برای توصیه وبسایت‌ها و موسیقی ارائه کرده‌اند. در انتهای پژوهش آن‌ها، به‌کارگیری این الگوریتم برای سایر محصولات، از جمله فیلم‌های سینمایی، به‌عنوان پیشنهاد برای تحقیقات آتی ارائه شده است.

۴- روش‌شناسی پژوهش

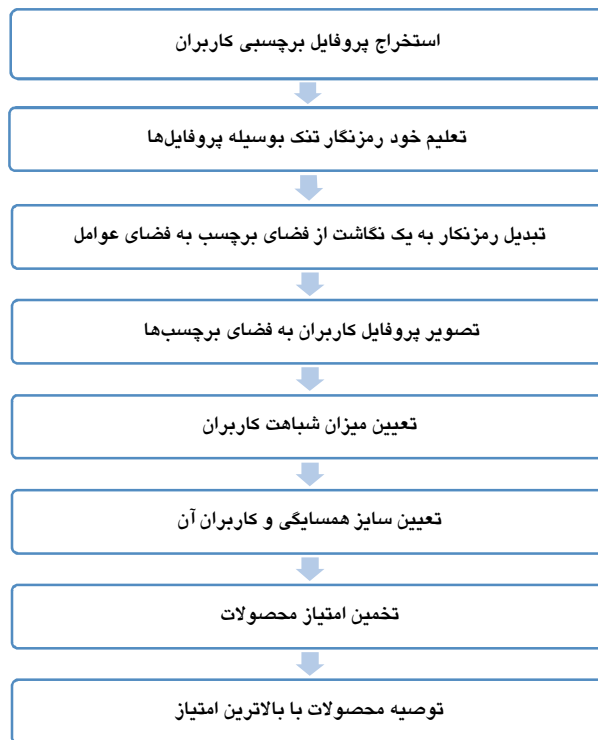
روش تحقیق استفاده‌شده در این پژوهش از نوع طراحی-آزمایش است. با توجه به مسئله و هدف این پژوهش و نیاز به ایجاد و پیاده‌سازی سامانه توصیه‌گر برچسب‌محور، مراحل فرآیند روش تحقیق علم طراحی به‌عنوان گام‌های اصلی فرآیند تحقیق مورد استفاده قرار گرفته‌اند. این روش تحقیق شامل مراحل شناسایی انگیزه‌ها و مسئله، تعریف اهداف راه‌حل، طراحی و ایجاد، نتیجه‌گیری، ارزیابی و ارتباط است [۲۲]. در مرحله شناسایی، مسئله و انگیزه‌ها باید مسئله تحقیق تعریف و ارزش راه‌حل آن تصدیق شود. در مرحله تعریف اهداف راه‌حل، باید از تعریف مسئله و دانش اینکه چه چیز ممکن و شدنی است، اهداف یک راه‌حل را استخراج کنیم. در مراحل طراحی و ایجاد، محقق مصنوع را خلق می‌کند. این مصنوعات به‌صورت بالقوه ساختارها، مدل‌ها، روش‌ها، نمونه‌ها [۲۲]، خصوصیات جدید فنی و اجتماعی یا منابع اطلاعاتی هستند. در مرحله نتیجه‌گیری، کاربرد مصنوع در حل یک یا چند نمونه از مسائل نشان داده می‌شود. در مرحله ارزیابی، از روش تحقیق آزمایش برای یافتن پاسخ سؤالات تحقیق استفاده‌شده است و در مرحله ارتباط مسئله و اهمیت آن، مصنوع، کارکرد و بداعت آن، قدرت طراحی آن و تأثیر آن بر محقق و دیگر مخاطبان مرتبط مانند افراد حرفه‌ای نشر می‌یابد. نمودار مراحل تحقیق در شکل ۱ آمده است. تمامی آزمایش‌ها در MATLAB بر روی یک رایانه با پردازنده Intel (R) Core i7 2.00 GHz و ۱۶ گیگابایت حافظه داخلی انجام شده‌اند. در الگوریتم ارائه‌شده، تابع خطای شبکه عصبی خودرمنزنگار تنک^۱، توسط روش L-EFGS بهینه‌شده است و برای آن از تابع minFunc که توسط مارک اشمیت^۲ ایجاد شده است، استفاده کردیم.

1. sparse auto-encoder

2. https://seccn.ucsd.edu/svn/software/tags/EEGLAB7_0_2_5_beta/external/fieldtrip20090727/classification/toolboxes/external/minFunc/minFunc.m

۴-۱- پیاده‌سازی سامانه توصیه‌گر

سامانه توصیه‌گر برچسب‌محور با استفاده از شبکه عصبی عمیق در سه مرحله مختلف طراحی و ایجاد شده است. خلاصه مراحل در نمودار زیر آورده شده‌اند:



شکل ۱ نمودار مراحل پیاده‌سازی

مرحله ۱: پیکربندی داده‌ها

مرحله ۱، داده‌ها را در یک پیکربندی مناسب جهت استفاده در مراحل بعدی آماده می‌کند و آن‌ها را به دو قسمت داده‌های تعلیم (۸۰٪ داده‌ها) و داده‌های آزمون (۲۰٪ داده‌ها) تقسیم می‌کند. پیکربندی مناسب شامل دو جدول کاربر-برچسب و کاربر-محصول است. سطر اول این جدول همه شناسه‌های برچسب‌های موجود و ستون

اول آن آی‌دی‌های کاربران است. اگر کاربری فیلمی را برچسب زده باشد، در سلولی از این جدول که از تقاطع سطر آی‌دی کاربر و ستون آی‌دی برچسب به‌دست آمده است، عدد یک و در غیر این صورت، عدد صفر قرار داده می‌شود. برای کمتر شدن میزان و زمان محاسبات، تنها برچسب‌هایی که در مجموع همه برچسب‌ها بیشتر از چهار بار تکرار شده‌اند، در این جدول نگه داشته شده‌اند و برچسب‌های با کمتر از سه بار تکرار از جمع برچسب‌ها حذف شده‌اند. جدول کاربر-محصول نیز تقریباً به همین صورت ساخته می‌شود.


مرحله ۲: تعلیم سامانه، تحلیل عاملی و استخراج عوامل

در این بخش ما قصد داریم با تحلیل عاملی برچسب‌ها و استخراج عوامل، بُعد فضایی را که سامانه توصیه‌گر بر روی آن عمل می‌کند، کاهش دهیم. پروفایل هر کاربر u به صورت ستون دوم الی ستون آخر سطر u ماتریس کاربر-برچسب تعریف (پروفایل شامل آی‌دی کاربر نیست) و با $X^{(u)}$ نمایش داده می‌شود. اگر m کاربر آزمون و n برچسب داشته باشیم، پروفایل هر یک از آن‌ها به صورت زیر نشان داده می‌شود:

$$X^{(i)} = (X_1^{(i)}, X_2^{(i)}, \dots, X_n^{(i)}), i = 1, 2, 3, \dots, m \quad (۱)$$

$$X_j^{(i)} = 1 \text{ یا } 0 \text{ و } i = 1, 2, \dots, m \text{ و } j = 1, 2, \dots, n \quad (۲)$$

برای تحلیل عاملی از خودرمنگاری تنک استفاده می‌کنیم که یک شبکه عصبی سه لایه‌ای شامل لایه ورودی، یک لایه پنهان و یک لایه خروجی بوده و بین همه گره‌های یک لایه با گره‌های لایه بعدی یال وجود دارد. بُعد لایه ورودی با تعداد برچسب‌ها برابر است و پروفایل هر یک از کاربران به عنوان ورودی به این لایه داده می‌شود. بُعد لایه پنهان برابر تعداد عواملی است که قصد داریم آن‌ها را استخراج کنیم و بُعد لایه خروجی با بُعد لایه ورودی یکسان و برابر تعداد برچسب‌ها است. معماری این شبکه در شکل ۲ نشان داده شده است.



شکل ۲ معماری شبکه عصبی با یک لایه پنهان

در لایه خروجی، ما قصد داریم بردار ورودی را دوباره بازتولید کنیم. هرچقدر میزان اختلاف بردار ورودی X و بردار خروجی \hat{X} کمتر باشد، عوامل استخراج‌شده عوامل بهتری هستند. خودرمزنگار تنک شامل دو بخش رمزنگار و رمزگشا است. بخش رمزگشا شامل لایه ورودی و لایه پنهان است. این لایه با ماتریس وزن W_1 با لایه پنهان ارتباط دارد. خروجی لایه پنهان برابر فعال‌سازی گره‌های لایه پنهان است؛ بنابراین، خروجی لایه پنهان برای کاربر u برابر است با:

$$a^{(u)} = \sigma(W^1 \times X^{(u)} + b) \quad (۳)$$

که در آن $a_i^{(u)}$ خروجی گره i ام لایه پنهان برای ورودی پروفایل کاربر u ، $X^{(u)}$ پروفایل کاربر u و بردار b بایاس لایه ورودی است. k تعداد گره‌های لایه پنهان، n تعداد فیلم‌ها و σ تابع سیگموئید است.

بخش رمزگشا شامل لایه پنهان و لایه خروجی است که تلاش می‌کند ورودی به لایه اول شبکه (پروفایل کاربران) را بازسازی کند. خروجی لایه خروجی که خروجی لایه رمزگشا هم هست برابر است با:

$$\hat{X}^{(u)} = \sigma(W^2 \times a^{(u)} + c) \quad (۴)$$

که در آن $\hat{X}^{(u)}$ خروجی شبکه عصبی و خروجی رمزگشا برای کاربر u ، W^2 ماتریس وزن بین لایه پنهان و لایه خروجی و c بایاس لایه دوم است. $a^{(u)}$ بردار بازنمایی پروفایل $X^{(u)}$ کاربر u است و بر اساس عوامل استخراج‌شده که خروجی‌های لایه پنهان شبکه عصبی هستند، نوشته شده است. ما سعی می‌کنیم در تعلیم شبکه، تفاوت بین ورودی به شبکه و خروجی شبکه کمترین مقدار ممکن شود. برای این کار یک تابع خطا تعریف می‌کنیم و آن را روی مولفه‌های این تابع که ماتریس وزن W^1 است، کمینه می‌کنیم. به خاطر تقارن شبکه مقادیر W^2 برابر W^{1T} که برابر با ترانهاده ماتریس W^1 است، انتخاب می‌شود. با اضافه کردن واگرایی کولبک-لیبلر^۱ به خطا به خاطر تنگی داده‌های ورودی، مقدار خطا برابر است با [۶]:

$$\begin{aligned} J &= \frac{1}{2m} \sum_{i=1}^m \|X^{(i)} - \hat{X}^{(i)}\|^2 + \beta P \\ &= \frac{1}{2m} \sum_{i=1}^m \|X^{(i)} - \sigma(W^{1T} \times \sigma(W^1 X^{(i)} + b) + c)\|^2 + \beta P \end{aligned} \quad (۵)$$

که در آن:

$$P = \sum_{j=1}^n D_{KL}(\rho || \hat{\rho}_j) \quad (۶)$$

1. Kullback-Liebler

$$D_{KL}(\rho|\hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (7)$$

و

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m \sigma(X^{(i)}; W^1, b) \quad (8)$$

که در آن m برابر است با تعداد داده‌های تعلیم. در رابطه بالا، مقادیر $X^{(i)}$ ها همان ورودی‌های داده‌های تعلیم و مشخص هستند و متغیرهایی که باید تابع فوق را روی آن‌ها کمینه کنیم، درایه‌های ماتریس W^1 و بردارهای b و c هستند. بنابراین داریم:

$$\min_{W^1, b, c} J(W^1, b, c) \quad (9)$$

برای کمینه کردن خطا، از الگوریتم l-bfgs پیاده‌سازی شده در تابع minFunc استفاده کردیم.

از این بهینه‌سازی ماتریس وزن‌های بهینه، W^1 و b برای ساختن بهترین عوامل از پروفایل کاربران به دست می‌آید. با استفاده از این وزن‌های بهینه، یک نگاشت $T: X \rightarrow a$ از فضای برچسب‌ها به فضای عوامل استخراج‌شده، به صورت زیر تعریف می‌کنیم:

$$T := \sigma(W^1 X + b) \quad (10)$$

با این نگاشت تمام پروفایل‌های جدول‌های آزمون و تعلیم را به‌روزرسانی می‌کنیم تا از آن‌ها در مرحله ۳ برای تعیین میزان شباهت کاربران با کاربر هدف و توصیه به او استفاده کنیم.

مرحله ۳: توصیه به کاربر

در این قسمت، قصد داریم با استفاده از کاربران تعلیم به یک کاربر u که کاربر هدف نامیده می‌شود و از کاربران آزمون انتخاب‌شده، توصیه کنیم. در این مرحله ابتدا میزان شباهت پروفایل تصویر شده در فضای عوامل استخراج‌شده کاربر هدف با پروفایل تصویرشده دیگر کاربران مقایسه می‌شود. کاربران برحسب این میزان شباهت مرتب می‌شوند و تعدادی برابر با متغیر همسایگی که از قبل تعیین‌شده از بین آن‌ها انتخاب می‌شود. از ضرب میزان شباهت هریک از کاربران همسایگی در بردار کاربر-فیلم آن‌ها و جمع آن‌ها با یکدیگر میزان امتیاز پیش‌بینی‌شده هریک از فیلم‌ها برای کاربر هدف تعیین می‌شود و از بین آن‌ها به تعداد طول فهرست توصیه فیلم‌های با بیشترین امتیاز انتخاب می‌شوند.

برای تعیین میزان شباهت بین کاربر هدف u که از بین کاربران آزمون انتخاب‌شده است و سایر کاربران تعلیم از معیار شباهت کسینوسی استفاده می‌کنیم. میزان شباهت بین کاربر u و کاربر v از رابطه زیر به دست می‌آید [۱۰].

$$sim_{u,v} = \frac{\langle a_u, a_v \rangle}{\|a_u\| \times \|a_v\|} \quad (11)$$

که در آن a_u و a_v پروفایل‌های تصویر شده در فضای عوامل هستند. $\langle \rangle$ نشان‌دهنده مجموع ضرب تک‌به‌تک درایه‌های متناظر دو بردار و $\| \|$ نشان‌دهنده اندازه یک بردار هستند. به مجموعه کاربرانی که قرار است در توصیه به کاربر u شرکت کنند همسایگی این کاربر گفته می‌شود و تعداد آن‌ها را با متغیر N_u مشخص می‌کنیم. میزان امتیاز پیش‌بینی‌شده هریک از فیلم‌ها برای کاربر u به‌صورت زیر مشخص می‌شود.

$$S_{u,i} = \sum_{v \in N_u} sim_{u,v} \times (\pi_{UI}Y)_{v,i} \quad (12)$$

که در آن، $(\pi_{UI}Y)_{v,i}$ سلول سطر مربوط به کاربر v و ستون فیلم با آی‌دی i جدول کاربر-فیلم است. به عبارت دیگر، $(\pi_{UI}Y)_{v,i}$ برابر یک است، اگر کاربر v فیلم با آی‌دی i را برچسب‌گذاری کرده باشد و در غیر این صورت، صفر است.

خروجی فرآیند فوق یک بردار است که تعداد درایه‌های آن به تعداد فیلم‌ها است، اگر سطر اول جدول کاربر-فیلم را به بالای این بردار اضافه کنیم، جدولی تشکیل می‌شود که به ما نشان می‌دهد امتیاز پیش‌بینی شده هر فیلم برای کاربر u چقدر است. بسته به مقدار طول فهرست توصیه فیلم‌های با بیشترین امتیاز برای توصیه به کاربر انتخاب می‌شوند.

۵- آزمایش

معیارهای دقت و به‌یادآوری به ترتیب نشان‌دهنده این موضوع هستند که از بین فیلم‌های توصیه‌شده چه تعداد از آن‌ها موردعلاقه کاربر است و چه تعداد از کل فیلم‌های موردعلاقه کاربر به او توصیه شده است. این معیارهای ارزیابی سامانه توسط روابط زیر محاسبه می‌شوند [۱۰].

$$\text{دقت} = \left(\frac{\text{فیلم‌های توصیه شده که کاربر به آن‌ها امتیاز مثبت داده است}}{\text{تعداد کل فیلم‌های توصیه شده به کاربر}} \right) \quad (13)$$

$$\text{به‌یادآوری} = \frac{\text{فیلم‌های توصیه شده که کاربر به آن‌ها امتیاز مثبت داده است}}{\text{تعداد کل فیلم‌هایی که کاربر به آن‌ها امتیاز مثبت داده است}} \quad (14)$$

معیار دقت $f1$ در ترکیبی از دو معیار فوق است و از رابطه ۱۶ به‌دست می‌آید.

$$F1 = 2 \times \frac{(\text{یادآوری} \times \text{دقت})}{\text{یادآوری} + \text{دقت}} \quad (15)$$

در آزمایش طراحی‌شده مقادیر معیارهای ارزیابی دقت، به‌یادآوری و $f1$ سامانه برچسب‌محور بر مبنای شبکه عصبی عمیق با یک لایه پنهان با ۱۰۰۰ گره برای داده‌های وبسایت www.movielens.org با سامانه پالایش گروهی برای طول‌های مختلف فهرست توصیه با یکدیگر مقایسه شده‌اند. مجموعه داده این سامانه شامل


۱۷۱۵ کاربر، ۵۴۶۰ فیلم و ۱۹۳۴ برچسب است که هر برچسب حداقل چهاربار تکرار شده است.

مولفه‌های زیر برای هر دو سامانه یکسان در نظر گرفته شده است.

- فعال‌سازی متوسط: $\rho = 0.1$
- وزن جمله تنکی: $\beta = 3$
- سایز همسایگی: $N_u = 90$

۶- یافته‌ها

در شکل زیر نمودارهای دقت، به یادآوری و F1 برای دو سامانه برچسب‌محور بر مبنای شبکه عصبی عمیق (مدل برچسبی) و سامانه پالایش گروهی آورده شده است.



شکل ۳ مقایسه سامانه برچسب‌محور و پالایش گروهی

همین‌طور که در شکل ۳ مشخص است، سامانه برچسب‌محور بر مبنای شبکه عصبی عمیق در هر سه معیار ارزیابی دقت، به یادآوری و F1 برای تمام طول

فهرست‌های توصیه از یک تا ۲۰۰ مقدار بیشتری را در توصیه فیلم‌های سینمایی به نسبت سامانه پالایش گروهی سنتی کسب کرده است. از شکل بالا مشخص است که نمودار یادآوری، برای هر دو سامانه صعودی است. علت این موضوع آن است که با افزایش طول فهرست توصیه، تعداد فیلم‌هایی از کاربر که قبلاً موردعلاقه او بوده‌اند و حالا هم توصیه شده‌اند، بیشتر می‌شود؛ یعنی از نقطه‌نظر معیار یادآوری، هرچقدر تعداد فیلم‌های توصیه شده بیشتر باشد، سامانه بهتر عمل می‌کند. نمودار دقت برحسب طول فهرست توصیه برای هر دو سامانه نزولی است؛ چراکه هرچقدر طول فهرست توصیه بیشتر می‌شود، تعداد فیلم‌های غلط توصیه شده هم بیشتر می‌شوند که این موضوع به کاهش دقت منجر می‌شود. با افزایش طول فهرست توصیه، دقت دو سامانه به یکدیگر نزدیک می‌شوند؛ چراکه سامانه توصیه‌گر برچسبی به خاطر زیادشدن تعداد توصیه‌ها برتری خود را در دقت از دست می‌دهد. معیار ارزیابی $f1$ که ترکیبی از دو معیار دقت و یادآوری است، یک حداکثر دارد؛ بنابراین طول فهرست توصیه نزدیک به ۱۵، بهترین عملکرد برای سامانه توصیه‌گر برچسب‌محور را داراست.

۷- بحث و بررسی

سؤال پژوهش حاضر این بود که آیا سامانه برچسب‌محور بر مبنای شبکه عصبی عمیق در توصیه فیلم‌های سینمایی از سامانه پالایش گروهی بهتر عمل می‌کند؟ با توجه به نتایج آزمایش طراحی شده در بخش ۵، سامانه توصیه‌گر برچسب‌محور در هر سه معیار ارزیابی دقت، به یادآوری و $f1$ که از پرکاربردترین و معمول‌ترین معیارهای ارزیابی در تحقیقات سامانه‌های توصیه‌گر هستند، برای تمام طول‌های فهرست توصیه از یک تا ۲۰۰ در توصیه فیلم‌های سینمایی داده‌های وبسایت movielens.org که از سایت‌های معروف توصیه فیلم‌های سینمایی است، از سامانه پالایش گروهی بهتر عمل می‌کند. بنابراین می‌توان در پاسخ سؤال تحقیق گفت که این سامانه از سامانه پالایش گروهی برای توصیه فیلم‌های سینمایی بهتر عمل می‌کند. علت این عملکرد بهتر این است که به خاطر تنگی داده‌های سامانه‌های با محصولات زیاد، سامانه‌های توصیه‌گر پالایش گروهی نمی‌توانند به خوبی کاربرهای شبیه به کاربر، هدف را شناسایی و بر مبنای آن‌ها به او توصیه کنند؛ اما در سامانه برچسب‌محور با استفاده از شبکه عصبی عمیق، ابتدا با

استفاده از یک خودرمنزنگار تنک عوامل انتزاعی‌تر از برچسب‌ها استخراج می‌شوند و با استخراج این عوامل مشکل تنکی داده‌ها حل می‌شود. بنابراین، سامانه می‌تواند با دقت بیشتری کاربران شبیه به کاربر هدف را شناسایی و به او توصیه کند. در سامانه‌های توصیه‌گر مدل محور ابتدا یک مدل بر مبنای داده‌ها ساخته می‌شود و سپس سامانه بر مبنای مدل توصیه می‌کند؛ مدل ساخته شده به صورت برخط نیست و هرچند وقت یکبار به روزرسانی می‌شود [۱۰]. این موضوع باعث می‌شود زمان توصیه به کاربر نسبت به پالایش گروهی کمتر شود؛ چراکه تعداد عوامل استخراج شده از تعداد برچسب‌های اولیه کمتر است. در مقایسه با دیگر تحقیقات پیشین ال. بی. مارینو [۲۳]، یک سامانه توصیه‌گر ترکیبی از پالایش گروهی کاربر محور و محصول محور گسترش یافته با برچسب برای توصیه موسیقی طراحی کردند که برای طول فهرست توصیه ده تایی معیار به یادآوری آن، ۰/۳۴ گزارش شده است. این سامانه بهتر از سامانه برچسب محور بر مبنای شبکه عصبی عمیق در این معیار ارزیابی عمل می‌کند. لیانگ و دیگران [۱۹] یک سامانه توصیه‌گر با استفاده از برچسب‌های موزون برای توصیه کتاب و وبسایت طراحی کردند که معیار ارزیابی به یادآوری آن برای مقادیر طول فهرست توصیه یک تا ۱۰ از سامانه برچسب محور کمتر است، ولی مقدار دقت آن از این سامانه بیشتر است. در حالت کلی، یک رابطه معکوس بین معیارهای به یادآوری و دقت وجود دارد؛ یعنی هرچقدر یک سامانه یادآوری بیشتری داشته باشد و تعداد بیشتری از محصولاتی را که قبلاً مورد توجه کاربر بوده‌اند و نشان‌دهنده توصیه‌های خوب هستند، توصیه کند، تعداد بیشتری از فیلم‌هایی را که قبلاً مورد توجه کاربر نبودند هم توصیه خواهد کرد. این موضوع دقت را کاهش خواهد داد. در مجموع در مقایسه با تحقیقات قبلی می‌توان نتیجه گرفت که این سامانه در به یادآوری بهتر از دقت عمل می‌کند؛ یعنی این سامانه، در مقایسه، تعداد بیشتری از فیلم‌های مورد توجه کاربر را توصیه می‌کند، ولی در کنار آن تعداد بیشتری از این توصیه‌ها هم در مقایسه با سامانه‌های دیگر فیلم‌هایی هستند که ممکن است مورد توجه کاربر نباشند.

۸- نتیجه‌گیری و پیشنهادها

در این پژوهش، ما سامانه توصیه‌گر برچسب محور بر مبنای شبکه عصبی عمیق را که بیشتر برای توصیه موسیقی و وبسایت‌ها ایجاد شده بود، برای اولین بار برای

فیلم‌های سینمایی ایجاد کردیم و با طراحی یک آزمایش و محاسبه شاخص‌های ارزیابی دقت، به‌یادآوری و F1 [۱۰] این سامانه را با سامانه توصیه‌گر پالایش گروهی سنتی مقایسه کردیم و مشاهده کردیم که سامانه توصیه‌گر برچسب‌محور بر مبنای شبکه عصبی عمیق در هر سه معیار ارزیابی از سامانه سنتی پالایش گروهی که یکی از سامانه‌های پرکاربرد در اپلیکیشن‌های واقعی است، بهتر عمل می‌کند. علت این عملکرد بهتر، کشف عوامل زیرین و انتزاعی‌تر از داده‌ها و حذف عوامل تکراری است که می‌تواند به رفع مشکل شروع سرد در سامانه‌های سنتی کمک کند. از لحاظ کاربردی می‌توان این سامانه را در هر سیستمی که کاربران چیزی را در آن برچسب می‌زنند، استفاده کرد. یکی از این استفاده‌ها در خود شبکه‌های اجتماعی است که می‌توان کاربران را برحسب شباهت برچسب‌هایشان به یکدیگر توصیه کرد. کاربرد دیگر، استفاده در فروشگاه‌هایی است که امکان برچسب‌گذاری کالا در آن‌ها وجود داشته باشد. علاوه بر این، این سامانه در سامانه‌هایی که افراد در آن‌ها اسناد را برچسب‌گذاری می‌کنند (مانند سیستم‌های مدیریت دانش) و موتورهای جستجو هم می‌تواند مورد استفاده قرار بگیرد. این سامانه را می‌توان به صورت آزمایشی، در کنار سامانه‌های فعلی به کار گرفت و با برطرف کردن اشکالات احتمالی از آن استفاده کرد. به علاوه، این سامانه را می‌توان در اپلیکیشن‌های فروش آنلاین، شبکه‌های اجتماعی یا اپلیکیشن‌های ایجاد محتوا برای توصیه محتوای مناسب به کار گرفت. از جمله محدودیت‌های تحقیق حاضر از لحاظ دامنه ارزیابی بحث ارزیابی و قیاس زمان اجرای الگوریتم‌هایی است که با توجه به نبود صورت مسئله عظیم در دامنه این تحقیق واقع نشده است، لیکن در این موضوع باید یک نمونه داده‌ای مناسب وجود داشته باشد تا بر اساس قیاس این مسئله با همان داده‌ها آزمون شود.

از آنجاکه بسامد تکرار برچسب‌ها توسط یک کاربر لحاظ نشده‌اند، یک پیشنهاد برای تحقیقات آتی این است که این موضوع در سیستم لحاظ شود. علاوه بر این، در این سامانه از امتیاز یک تا پنجی که کاربران به بعضی از فیلم‌ها داده‌اند، برای توصیه استفاده نشده است. پیشنهاد دیگری برای پژوهش‌های آتی این است که سامانه از این امتیازها هم در کنار برچسب برای تعیین میزان شباهت بین کاربران و توصیه به کاربران استفاده کند. علاوه بر این، آزمون کردن این سامانه با مجموعه داده‌های

بزرگ‌تر و استفاده از روش‌های تحلیل بزرگ داده مانند هادوپ^۱ یا تقلیل نگاشت^۲ می‌تواند پیشنهادی برای پژوهش‌های آتی باشد تا مشخص کند که این سامانه در مقیاس‌های بزرگ‌تر چه عملکردی دارد. با استفاده از حس‌کاوی می‌توان بار احساسی برچسب‌ها را مشخص و آن‌ها را در توصیه به کاربران لحاظ کرد. پیشنهاد دیگر این است که عملکرد این سامانه برای کالاهای دیگر مانند کتاب یا فروشگاه‌های ترکیبی با چند کالا بررسی شود. می‌توان بعد از توصیه به کارکنان، معیارهای ارزیابی سامانه را با استفاده از پرسشنامه واقع‌بینانه‌تر ارزیابی کرد. در این سامانه از شبکه‌های عصبی خودرمنگار تنک استفاده شده است. به‌عنوان تحقیقات آتی می‌توان از الگوریتم‌های ژنتیکی، روش‌های فازی یا شبکه‌های عصبی با معماری شبکه متفاوتی استفاده و نتیجه را با نتیجه تحقیق حاضر مقایسه کرد.

۹- منابع

- [1] Kim, H. N., Ji, A. T., Ha, I., & Jo, G. S., Collaborative filtering based on collaborative tagging for enhancing the quality of recommendation. *Electronic Commerce Research and Applications*, 9(1), 2010, 73-83.
- [2] Park, D. H., Kim, H. K., Choi, I. Y., & Kim, J. K., A literature review and classification of recommender systems research. *Expert Systems with Applications*, 39(11), 2012, 10059-10072.
- [3] Schafer, J. B., Frankowski, D., Herlocker, J., & Sen, S., Collaborative filtering recommender systems. In *The adaptive web*. Springer, Berlin, Heidelberg, 2007, 291-324.
- [4] Su, X., & Khoshgoftaar, T. M., A survey of collaborative filtering techniques. *Advances in artificial intelligence*, 2009, 2009-2010.
- [5] Zhang, Z. K., Liu, C., Zhang, Y. C., & Zhou, T., Solving the cold-start problem in recommender systems with social tags. *EPL (Europhysics Letters)*, 92(2), 2010, 28002.

1. Hadoop
2. Map Reduce

- [6] Zuo, Y., Zeng, J., Gong, M., & Jiao, L., Tag-aware recommender systems based on deep neural networks. *Neurocomputing*, 204, 2016, 51-60.
- [7] Sohrabi, B., Raeesi Vanani, I., Zareh Mirkabad, F. Designing a Recommender System for Optimizing and Managing Bank Facilities through the Utilization of Clustering and Classification Algorithms. *Modern Research in Decision Making*, 1(2), 2016, 53-76.
- [8] Motaharnejad, M., Zolfagharzadeh, M., Khadangi, E., Sadabadi, A. Designing a Model for Improving Banking Recommender Systems Based on Predicting Customers' Interests: Application of Data Mining Techniques. *Journal of Information Technology Management*, 8(2), 2016, 393-314.
- [9] Núñez-Valdéz, E. R., Lovelle, J. M. C., Martínez, O. S., García-Díaz, V., De Pablos, P. O., & Marín, C. E. M., Implicit feedback techniques on recommender systems applied to electronic books. *Computers in Human Behavior*, 28(4), 2012, 1186-1193.
- [10] Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A., Recommender systems survey. *Knowledge-based systems*, 46, 2013, 109-132.
- [11] Sarwar, B., Karypis, G., Konstan, J., Riedl, J., Application of dimensionality reduction in recommender system-a case study. No. TR-00-043. Minnesota Univ Minneapolis Dept of Computer Science, 2000, 6, 100-105.
- [12] Bengio, Y., Courville, A., & Vincent, P., Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 2013, 1798-1828.
- [13] Bengio, Y., Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 2009, 1-127.
- [14] Liu, D. C., & Nocedal, J., On the limited memory BFGS method for large scale optimization. *Mathematical programming*, 45(1-3), 1989, 503-528.
- [15] Marinho, L. B., & Schmidt-Thieme, L., Collaborative tag recommendations. In *Data Analysis, Machine Learning and Applications*, Springer, Berlin, Heidelberg, 2008, 533-540.

- [16] Ricci, Francesco, Lior Rokach, and Bracha Shapira. "Introduction to recommender systems handbook." In *Recommender systems handbook*, springer, US, 2011, 5-35.
- [17] Firan, C. S., Nejdil, W., & Paiu, R., The benefit of using tag-based profiles. In *Web Conference. LA-WEB 2007. Latin American IEEE*, 2007, 32-41.
- [18] Koren, Y., Bell, R., & Volinsky, C., Matrix factorization techniques for recommender systems. *Computer*, (8), 2009, 30-37.
- [19] Liang, H., Xu, Y., Li, Y., Nayak, R., & Tao, X., Connecting users and items with weighted tags for personalized item recommendations. In *Proceedings of the 21st ACM conference on Hypertext and hypermedia*. ACM, 2010, 51-60.
- [20] De Lathauwer, L., De Moor, B., & Vandewalle, J., A multilinear singular value decomposition. *SIAM journal on Matrix Analysis and Applications*, 21(4), 2000, 1253-1278.
- [21] Hotho, A., Jäschke, R., Schmitz, C., & Stumme, G., Information retrieval in folksonomies: Search and ranking. In *European Semantic Web conference*. Springer, Berlin, Heidelberg, 2006, 411-426.
- [22] Hevner, A., & Chatterjee, S., *Design research in information systems: theory and practice (Vol. 22)*. Springer Science & Business Media, Springer, Berlin, Heidelberg, 2010, 136-215.
- [23] Marinho, L. B., Nanopoulos, A., Schmidt-Thieme, L., Jäschke, R., Hotho, A., Stumme, G., & Symeonidis, P., Social tagging recommender systems. In *Recommender systems handbook*. Springer, Boston, MA., 2011, 615-644.