



یادگیری عمیق در سامانه‌های توصیه‌گر

امید عباسی مهدیه سلیمانی باغشا

دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شریف، تهران، ایران

چکیده

روش پالایش همکارانه یکی از کارآمدترین و پرکاربردترین روش‌های مورد استفاده در بسیاری از سامانه‌های توصیه‌گر است. روش‌های اولیه پالایش همکارانه ویژگی‌های نهان کاربران و گزینه‌ها را با استفاده از تجزیه ماتریس امتیازات به دست می‌آوردند، اما این روش‌ها با مشکل شروع سرد و تنک بودن ماتریس امتیازات مواجه می‌شوند. در سال‌های اخیر استفاده از اطلاعات اضافه موجود، در کنار ماتریس امتیازات برای به دست آوردن ویژگی‌های نهان مورد توجه قرار گرفته است. از طرف دیگر، مدل‌های یادگیری عمیق، توانایی بالایی در یادگیری بازنمایی مناسب، به خصوص در مواقعی که با داده‌های خام سروکار داریم از خود نشان داده‌اند. باتوجه به این قابلیت یادگیری عمیق، در این پژوهش از شبکه‌های عمیق برای به دست آوردن نمایش مناسب از گزینه‌ها استفاده شده است. به‌طور خاص، یک مدل ترکیبی از یادگیری عمیق در کنار تجزیه ماتریسی ارائه شده است که یک ارتباط دوطرفه بین ویژگی‌های به‌دست آمده از تجزیه ماتریسی و ویژگی‌های محتوایی استخراج شده با استفاده از یادگیری عمیق درباره گزینه‌ها ایجاد می‌کند. در این مدل به‌طور همزمان پارامترهای هر دو بخش یادگرفته می‌شود. مقایسه مدل پیشنهادی با برترین روش‌های ارائه شده در سال‌های اخیر بر روی مجموعه داده‌های مختلف دنیای واقعی، برتری روش پیشنهادی بر سایر روش‌های ارائه شده را نشان می‌دهد.

کلمات کلیدی: سامانه‌های توصیه‌گر، شبکه‌های عمیق، پالایش همکارانه، محتوای گزینه‌ها.

۱- مقدمه

از گزینه‌ها، براساس علاقه‌مندی شخصی‌سازی شده آن‌ها نمایش داده می‌شود که گزینه‌های این لیست به کمک سامانه توصیه‌گر انتخاب شده‌اند.

در سامانه‌های ارائه پیشنهاد معمولاً مجموعه‌ای از کاربران، گزینه‌ها و بازخوردهای کاربران نسبت به گزینه‌ها را در اختیار داریم که این بازخوردها می‌توانند به صورت صریح بیان شوند (همانند امتیازی که کاربران به گزینه‌ها می‌دهند) و یا به صورت ضمنی از فعالیت‌های کاربر در سیستم، استنباط شوند. معمولاً بازخوردهای کاربران در ماتریسی به نام ماتریس امتیازدهی ذخیره می‌شود که این ماتریس عموماً بسیار تنک است [۳]. تنک بودن ماتریس امتیازات یکی از بزرگترین چالش‌های سامانه‌های توصیه‌گری است که از روش‌های تجزیه ماتریسی برای ارائه پیشنهاد استفاده می‌کنند. از این رو از روش‌های مختلفی جهت بهبود عملکرد رویکرد تجزیه ماتریسی استفاده می‌شود که از جمله آن می‌توان به استفاده از اطلاعات اضافی موجود همانند محتوای گزینه‌ها، ارتباط کاربران با یکدیگر، نمایه کاربران و یا ارتباط بین گزینه‌ها اشاره کرد. اما با توجه به این که اطلاعات اضافه موجود عموماً به صورت متنی هستند، نمایش آن‌ها به کمک روش‌هایی همانند

امروزه حجم اطلاعاتی که در دسترس ما قرار دارد به صورتی فزاینده افزایش یافته است به طوری که، ما در اقیانوسی از داده‌ها غرق شده‌ایم اما همچنان تشنه‌ی دانش هستیم [۱]. با توجه به این که افراد به روش‌های گوناگون و به سادگی می‌توانند داده‌ها را در اینترنت قرار دهند، حجم داده‌های موجود بسیار زیاد شده است. یکی از راه‌های برخورد با مشکل سربار اطلاعات استفاده از سامانه‌های توصیه‌گر است. سامانه‌های توصیه‌گر برنامه‌هایی هستند که گزینه‌هایی را که احتمال می‌دهند مورد علاقه کاربر باشد به او پیشنهاد می‌دهند [۲]. این پیشنهاد می‌تواند دربرگیرنده‌ی انواع تصمیم‌گیری‌ها همانند انتخاب کالا، فیلم و یا کتاب از بین انبوهی از گزینه‌ها باشد. این سامانه‌ها به صورتی گسترده در بسیاری از وبسایت‌ها (همانند آمازون^۱، اخبار گوگل^۲، نتفلیکس^۳) جهت ارائه پیشنهاد به کاربران استفاده می‌شوند. معمولاً در این وبسایت‌ها به کاربران لیستی مرتب شده

• بررسی نتایج عملی بر روی سه مجموعه داده از دنیای واقعی نشان می‌دهد که روش پیشنهادی بهتر از سایر روش‌های ارائه پیشنهاد عمل می‌کند و توانسته به نتایج بهتری دست یابد.

در ادامه ابتدا در بخش ۲، تعدادی از مهمترین کارهای پیشین در زمینه سامانه‌های توصیه‌گر که از شبکه‌های عمیق در ساختار خود استفاده کرده‌اند معرفی می‌شوند. سپس مدل پیشنهادی به تفصیل ارائه می‌شود. در بخش ارزیابی مدل پیشنهادی، ابتدا مجموعه داده‌های مورد استفاده و روش‌های مقایسه معرفی می‌شوند و پس از آن نتایج عملی روش پیشنهادی گزارش می‌شود. در نهایت نتیجه‌گیری و کارهای آتی ارائه خواهد شد.

۲- کارهای پیشین

سامانه‌های توصیه‌گر معمولاً براساس روشی که جهت انتخاب گزینه‌ها برای پیشنهاد اتخاذ می‌نمایند در سه دسته محتوا-محور، پالایش همکارانه و روش‌های ترکیبی قرار می‌گیرند. رویکرد محتوا-محور از اطلاعات اضافه موجود در نمایه کاربران و توضیحات موجود درباره گزینه‌ها استفاده می‌نماید [۱۰]. رویکرد پالایش همکارانه از فعالیت‌های گذشته کاربران با سیستم همانند امتیازاتی که به گزینه‌ها داده‌اند بهره می‌گیرد و از اطلاعاتی همانند محتوای گزینه‌ها استفاده نمی‌کند [۱۱]. هر کدام از روش‌های محتوا-محور و پالایش همکارانه برای ارائه پیشنهاد از منابع اطلاعاتی متفاوتی استفاده می‌کنند. به همین دلیل، محدودیت‌هایی دارند که سبب می‌شود نتوانند در بعضی حالت‌ها پیشنهاد‌های مناسبی را ارائه کنند. برای جلوگیری از بسیاری از این محدودیت‌ها و افزایش کیفیت پیشنهادها روش‌های ترکیبی ارائه شدند که از ترکیب روش‌های مبتنی بر محتوا و پالایش همکارانه به دست می‌آیند [۲].

روش‌های ترکیبی در سامانه‌های توصیه‌گر با توجه به این که یک ارتباط دوطرفه بین اطلاعات موجود در ماتریس امتیازات و اطلاعات اضافی موجود درباره گزینه‌ها و کاربران در نظر گرفته‌اند یا نه، در دو دسته ارتباط محکم^۱ و ارتباط ضعیف^۲ قرار می‌گیرند [۷]. در روش‌های ترکیبی ارتباط ضعیف، اطلاعات اضافه تنها یک بار مورد بررسی قرار می‌گیرند و ویژگی‌های آن‌ها استخراج می‌گردد و سپس از این ویژگی‌ها در روش‌های پالایش همکارانه استفاده می‌شود. چون ارتباط در این حالت یک طرفه است اطلاعات موجود در جدول امتیازات نمی‌توانند در جهت انتخاب بهتر ویژگی‌ها کمکی بکنند. اما در روش‌های ترکیبی ارتباط محکم، یک ارتباط دوطرفه بین انتخاب ویژگی‌ها از اطلاعات اضافی و جدول امتیازات وجود دارد. این ارتباط دوطرفه از یک سو با استفاده از جدول امتیازات سبب انتخاب ویژگی‌های بهتر از اطلاعات اضافی می‌گردد و از سوی دیگر با استخراج ویژگی‌های بهتر سبب افزایش دقت مدل می‌گردد.

CTR^۱ [۷] یک روش ترکیبی ارتباط محکم است که جهت پیشنهاد مقالات به کاربران ارائه شده است. این روش یک مدل گرافی احتمالی است که از ترکیب مدل عنوانی LDA^۱ [۱۳] و روش تجزیه ماتریسی [۱۴] به دست می‌آید.

روش CTR بر مبنای فرض اساسی موجود در رویکرد تجزیه ماتریسی بنا شده است که طبق آن فرض ویژگی‌های کاربران و گزینه‌ها را می‌توان به یک فضای برداری نهان با ابعاد کوچکتر نگاهت کرد به صورتی که، میزان علاقه یک کاربر به یک گزینه از ضرب داخلی این دو بردار در آن فضا به دست آید.

CTR کاربران را با استفاده از عنوان‌های مورد علاقه آن‌ها که با استفاده از روش LDA و از متن مقالات مورد علاقه آن‌ها به دست آمده است نمایش می‌دهد و فرض می‌کند مقالات با استفاده از یک مدل موضوعی تولید شده‌اند. اما جهت مدل کردن مقالات فرض می‌شود که در بازنمایی هر مقاله علاوه بر موضوع‌های آن که با استفاده از مدل‌های موضوعی به دست می‌آید، به امتیاز کاربران به آن مقاله

TF-IDF انجام می‌پذیرد که این دست از روش‌ها با مشکل ابعاد بالا و تنگ بودن نمایش به دست آمده از داده‌ها مواجه می‌شوند. در سال‌های اخیر و با توجه به پیشرفت چشمگیر در سرعت پردازنده‌ها و استفاده از پردازنده‌های گرافیکی رویکرد شبکه‌های عمیق بسیار مورد توجه قرار گرفته است [۴] و نشان داده شده است این رویکرد به خصوص در مواقعی که با داده‌های خام سروکار داریم توانایی بالایی در یادگیری بازنمایی مناسب داده‌ها دارد و توانسته پیشرفت‌های چشمگیری در زمینه‌هایی نظیر بینایی کامپیوتر [۵]، پردازش زبان طبیعی و بازشناسی گفتار [۶] حاصل نماید.

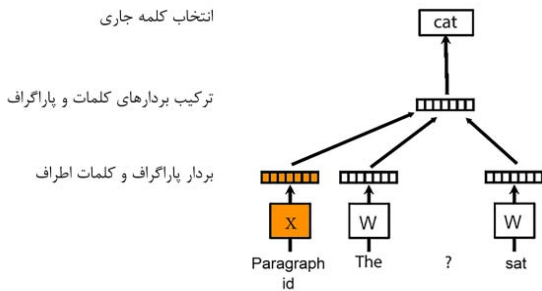
در مدل‌های یادگیری عمیق، ویژگی‌ها می‌توانند به کمک روش‌های ناظر^۴ و بدون ناظر به دست آیند. گرچه این روش‌ها در یادگیری خودکار ویژگی‌ها بیشتر از روش‌های کم عمق مورد توجه قرار دارند، اما نمی‌توانند همانند مدل پالایش همکارانه شباهت و ارتباط‌های ضمنی بین گزینه‌ها را به دست آورند [۷]. این امر نشان می‌دهد می‌توان از ترکیب روش‌های یادگیری عمیق و پالایش همکارانه در بهبود عملکرد سامانه‌های توصیه‌گر بهره برد.

در دست داشتن ارتباط‌های موجود بین گزینه‌های سیستم یکی دیگر از مواردی است که در پیش‌بینی امتیازات کاربران به گزینه‌ها می‌تواند بسیار مفید واقع شود. با استفاده از ارتباط‌های بین گزینه‌ها می‌توان گزینه‌های شبیه به یکدیگر را پیدا کرد که این امر به خصوص در حالت شروع سرد^۵ برای گزینه‌ها می‌تواند بسیار مفید باشد، چرا که در این حالت امتیازی برای گزینه‌ای که تازه وارد سیستم شده است ثبت نشده است و سیستم نمی‌تواند با استفاده از ماتریس امتیازات گزینه‌های شبیه به یکدیگر را بیابد.

در این مقاله، یک مدل ترکیبی ارائه می‌شود که از ماتریس امتیازات، ماتریس ارتباطات بین گزینه‌ها و اطلاعات موجود در مورد محتوای گزینه‌ها در کنار هم، جهت ارائه یک پیشنهاد به کاربر استفاده می‌کند. با توجه به مشکلات ذکر شده برای روش‌هایی نظیر TF-IDF، در روش پیشنهادی از مدل تبدیل پاراگراف به بردار [۸] جهت به دست آوردن نمایش مناسب برای گزینه‌ها استفاده شده است. در واقع شبکه‌ای مشابه skip-gram که در [۹] معرفی شده است جهت استخراج ویژگی‌های مناسب از محتوای گزینه‌ها مورد استفاده قرار می‌گیرد. در مدل ارائه شده با ایده گرفتن از روش مطرح شده در [۷]، یک ارتباط دوطرفه محکم بین ویژگی‌های استخراج شده از محتوای گزینه‌ها و ماتریس امتیازات ایجاد می‌گردد به صورتی که علاوه بر این که ویژگی‌های استخراج شده از محتوای گزینه‌ها با استفاده از اطلاعات اضافه موجود به پیش‌بینی بهتر امتیازات نامشخص کمک می‌کنند، ماتریس امتیازات نیز به شبکه استخراج ویژگی‌ها از محتوا کمک می‌کند تا ویژگی‌های مهمتری را از اطلاعات اضافه موجود استخراج نماید. به این ترتیب ویژگی‌های مهمتری از گزینه‌ها که دقت مدل نهایی را افزایش می‌دهد استخراج می‌گردد.

از مهمترین نوآوری‌های این پژوهش می‌توان به موارد زیر اشاره کرد:

- در این مقاله یک مدل ترکیبی ارائه شده است که از سه منبع متفاوت اطلاعاتی (ماتریس امتیازات، ماتریس ارتباطات بین گزینه‌ها و اطلاعات محتوای گزینه‌ها) در کنار یکدیگر جهت ارائه پیشنهاد استفاده می‌کند و یک ارتباط محکم بین تمام اجزای سیستم با یکدیگر برقرار می‌نماید.
- ارائه یک مدل جهت استفاده از ارتباطات بین گزینه‌ها به منظور ارائه پیشنهاد به کاربر.
- استفاده از یک مرحله پیش‌پردازش داده‌ها با استفاده از روش ارائه شده در [۸] که منجر به پیدا کردن یک فضای معنایی مناسب با ابعاد بسیار کمتر و متراکم‌تر جهت نمایش گزینه‌ها می‌شود. استفاده از این نحوه نمایش برای محتوای گزینه‌ها سبب کاهش بعد داده‌های ورودی می‌گردد که در نهایت سبب افزایش دقت و سرعت یادگیری در مدل نهایی می‌شود.



شکل ۱- ساختار یادگیری بردار پاراگراف. در این مثال از ترکیب بردار یک کلمه قبل و بعد از کلمه جاری به همراه بردار پاراگراف اطراف جهت پیش‌بینی کلمه جاری استفاده شده

۳- روش‌های پیش‌نیاز

در این بخش به‌طور مختصر روش‌های پیش‌نیاز مورد استفاده در روش پیشنهادی معرفی می‌شوند. ابتدا روش تبدیل پاراگراف به بردار [۸] معرفی می‌گردد که با استفاده از آن نمایش گزینه‌ها به دست می‌آید. سپس شبکه SDAE^[۱۶] که جهت استخراج ویژگی‌ها مورد استفاده قرار گرفته است بررسی می‌شود.

۳-۱- روش تبدیل پاراگراف به بردار

یکی از مهمترین بخش‌ها در طراحی سامانه‌های توصیه‌گری که از محتوای اطلاعات گزینه‌ها نیز استفاده می‌کنند، نحوه‌ی به دست آوردن بازنمایی گزینه‌ها با استفاده از متن خام موجود درباره آن گزینه، است. سامانه‌های توصیه‌گر عموماً نیاز دارند که متن مرتبط با هر گزینه ابتدا به یک بردار با طول ثابت و مشخص نگاشت شود تا بتوانند از این اطلاعات استفاده نمایند و پس از این نگاشت هر گزینه به کمک بردار خود شناخته شود. متداول‌ترین روش مورد استفاده جهت به دست آوردن بردار با طول مشخص، استفاده از روش کیسه کلمات [۱۷] است که به علت سادگی و کارایی به نسبت خوب، بسیار مورد توجه قرار گرفته است. اما این روش چندین مشکل دارد از جمله این که:

- در این روش ترتیب کلمات از دست می‌رود، در نتیجه دو متن تا زمانی که کلمات یکسانی داشته باشند بدون توجه به ترتیب کلمات مورد استفاده نمایش یکسانی نیز خواهند داشت.
- این روش تقریباً هیچ دیدی نسبت به معنای کلمات یا به‌طور دقیق‌تر فاصله معنایی کلمات از یکدیگر ندارد.
- بازنمایی به دست آمده برای هر کلمه در این روش بسیار تنک و دارای بعد بسیار بالایی است چرا که در این روش هر کلمه به کمک یک بردار S بعدی (که S نشان‌دهنده تعداد کلمات موجود در دایره واژگان مورد استفاده است) نمایش داده می‌شود که تنها یک عضو این بردار برابر یک است و سایر اعضا صفر هستند. این امر سبب می‌شود روش‌هایی که از روش کیسه کلمات جهت به دست آوردن بردار متن خود استفاده می‌کنند با مشکل ابعاد بالا مواجه شوند.

در مدل پیشنهادی از روش تبدیل پاراگراف به بردار [۸] جهت به‌دست آوردن بازنمایی گزینه‌ها استفاده شده است. بازنمایی به دست آمده از این طریق بسیار مورد توجه است چرا که این بازنمایی بسیاری از ساختارهای زبانی و الگوهای کلمات را حفظ کرده است به‌طوری که بسیاری از این الگوها را می‌توان به صورت ترکیب خطی آن‌ها نمایش داد [۱۸]. به عنوان مثال اگر نمایش به دست آمده از

نیز توجه می‌شود. به عبارت دیگر اگر بردار v_j بازنمایی گزینه j در فضای نهان باشد آن‌گاه $v_j = \theta_j + \epsilon_j$ است که در این نمایش θ_j موضوع‌های استخراج شده از مدل‌های موضوعی برای آن مقاله را نمایش می‌دهد و ϵ_j با استفاده از تجزیه ماتریس امتیازات کاربران به گزینه‌ها به دست آمده است. یکی از مهمترین مزیت‌های CTR نسبت به روش‌های قدیمی‌تر (علاوه بر دقت بالاتر) این است که این مدل می‌تواند گزینه‌هایی که تازه وارد سیستم شده‌اند را نیز با استفاده از محتوای آن‌ها پیشنهاد نماید. در نتیجه مشکل شروع سرد برای گزینه‌ها برطرف می‌گردد.

علی‌رغم توانایی بالای یادگیری عمیق در به دست آوردن ویژگی‌های مناسب، متأسفانه تا همین اواخر پژوهش‌های اندکی در زمینه استفاده از شبکه‌های عمیق در سامانه‌های توصیه‌گر انجام شده است. CDL^[۹] یکی از موفق‌ترین روش‌های ارائه شده در این زمینه می‌باشد. این روش همانند CTR هم از اطلاعات اضافه موجود درباره گزینه‌ها و هم از ماتریس امتیازات کاربران به گزینه‌ها جهت ارائه پیشنهاد استفاده می‌نماید.

این روش از دو بخش کلی تشکیل شده است: (۱) استخراج ویژگی‌ها و (۲) تجزیه ماتریس امتیازات. روش CDL جهت به دست آوردن بردار ویژگی‌های نهان کاربران از روش تجزیه ماتریس امتیازات استفاده می‌کند، اما این فرض را اضافه می‌کند که ویژگی‌های نهان گزینه‌ها علاوه بر مقادیر به دست آمده از تجزیه ماتریس امتیازات به محتوای گزینه‌ها نیز وابسته است. در نتیجه، ابتدا ویژگی‌های محتوایی گزینه‌ها را با استفاده از یک شبکه خودرمزگذار^[۱۱] از روی توصیف موجود درباره هر گزینه به دست می‌آورد و سپس در آموزش مدل تلاش می‌کند ویژگی‌های نهان به دست آمده برای هر گزینه به صورتی یادگرفته شوند که علاوه بر تأثیر پذیرفتن از تجزیه ماتریس امتیازات به ویژگی‌های محتوایی به دست آمده از شبکه خودرمزگذار نیز نزدیک باشند. در این روش هم به دلیل استفاده از محتوای گزینه‌ها مشکل شروع سرد برای گزینه‌ها وجود ندارد اما همچنان مشکل شروع سرد برای کاربران وجود دارد.

MDA-CF^[۱۵] یکی دیگر از روش‌هایی است که شبکه عمیق را با تجزیه ماتریسی ترکیب کرده است. در این مدل نیز همانند CDL از شبکه عمیق جهت استخراج ویژگی‌های مناسب از اطلاعات اضافی موجود استفاده شده است با این تفاوت که اطلاعات اضافی موجود درباره کاربران نیز مورد استفاده قرار گرفته است. MDA-CF با استفاده از اطلاعات اضافی موجود درباره کاربران این فرض را به مدل CDL اضافه می‌کند که ویژگی‌های نهان کاربران علاوه بر ماتریس امتیازات به محتوای اطلاعات اضافه موجود درباره کاربران نیز وابسته است.


با توجه به این که هر دو مدل CDL و MDA-CF از ماتریس امتیازات در کنار محتوای اطلاعات اضافی موجود جهت ارائه پیشنهاد استفاده می‌نمایند در نتیجه با دقت بالایی قادر به تشخیص امتیازات ناموجود هستند و می‌توانند با مشکل شروع سرد به خوبی مقابله نمایند. در هر سه روش بالا، پس از به دست آوردن بازنمایی کاربران و گزینه‌ها، همانند روش تجزیه ماتریسی پس از ضرب داخلی نمایش‌های به دست آمده در یکدیگر میزان شباهت هر کاربر به هر گزینه محاسبه می‌گردد و گزینه‌هایی که بیشترین شباهت را به هر کاربر دارند به او پیشنهاد می‌گردند.

یکی از مشکلات اساسی در تمام این روش‌ها استفاده از یک بردار با ابعاد بالا و تنک، جهت ورود اطلاعات اضافه به سیستم است. در CDL و MDA-CF از روش TF-IDF جهت به دست آوردن نمایش اطلاعات اضافه موجود استفاده شده است که سبب می‌گردد ورودی با ابعاد بالا و تنک وارد مدل شود و منجر به کاهش دقت مدل و افزایش زمان پردازش داده‌ها گردد. در CTR نیز بازنمایی به دست آمده برای گزینه‌ها به‌خصوص در زمان‌هایی که اطلاعات اضافی تنک هستند، چندان موثر نمی‌باشد، در نتیجه این اطلاعات کمک چندانی به بهبود نتایج نمی‌کنند.

می‌کند با استفاده از این فضا نسخه اصلی داده‌ها را بازسازی نماید و به این صورت ویژگی‌های مهم داده‌های ورودی که همان فضای نهان کوچک است را می‌آموزد. یک نمونه از این شبکه در شکل ۲ آمده است. در نهایت این شبکه تلاش می‌کند مسئله بهینه‌سازی زیر را حل کند:

$$\min_{\{W_1\}, \{b_1\}} \|X_C - X_L\|_2^2 + \lambda \sum_1 \|W_1\|_2^2 \quad (2)$$

که در این نمایش X_C نسخه اصلی ورودی‌ها و X_L خروجی لایه آخر شبکه را نمایش می‌دهد. $\{W_1\}, \{b_1\}$ وزن‌ها و بایاس شبکه را مشخص می‌کنند و λ پارامتر تنظیم است.



شکل ۲- نمایش ساختار شبکه SDAE. در این نمایش X_0 داده نويز وارد شده و X_C داده بدون نويز را نمایش می‌دهند

۴- روش پیشنهادی

در این بخش روش پیشنهادی معرفی می‌گردد. در ابتدا نمادگذاری و تعریف مسئله ارائه می‌شود و سپس مدل پیشنهادی که از ترکیب روش تبدیل پاراگراف به بردار و شبکه SDAE در کنار روش تجزیه ماتریسی به دست می‌آید معرفی خواهد شد.

۴-۱- نمادگذاری و تعریف مساله

در این مقاله مجموعه کاربران را با $\{i_1, i_2, \dots, i_N\}$ نمایش می‌دهیم که هر i_n نشان‌دهنده یک کاربر خاص است و N تعداد کل کاربران را نشان می‌دهد. مجموعه گزینه‌ها را نیز با $\{j_1, j_2, \dots, j_M\}$ نمایش می‌دهیم که در این مجموعه هر j_m نشان‌دهنده یک گزینه خاص (مثلاً مقاله و یا فیلم) خواهد بود و M نیز تعداد کل گزینه‌ها است. به ازای هر گزینه همانند m یک مجموعه توالی^{۱۳} که شامل T_m لغت است وجود دارد. این مجموعه شامل اطلاعات اضافی است که از هر گزینه در اختیار داریم. این اطلاعات اضافی برای مقالات، متن چکیده آن‌ها و برای فیلم‌ها داستان آن فیلم است که عموماً به صورت یک پاراگراف متن خام است که گزینه مورد نظر را به طور کلی توصیف می‌کند. در مجموعه توالی لغات W_{t_m} نشان‌دهنده لغت t -ام در توصیف موجود درباره گزینه m است. هر لغت به کمک بردار S بعدی نمایش داده می‌شود که فقط یک عنصر آن برابر ۱ است و باقی عناصر آن صفر هستند در این جا S تعداد کل کلمات مجزای موجود در دایره لغات است و W^S نشان‌دهنده لغت S -ام در مجموعه لغات می‌باشد.

در این مقاله جهت ثبت تراکنش‌های کاربر با سیستم از یک ماتریس امتیازات دوتایی^{۱۴} استفاده می‌شود و آن را با $R = [R_{nm}]_{N \times M}$ نمایش می‌دهیم. این ماتریس می‌تواند بازخوردهای مستقیم و غیرمستقیم یک کاربر به یک گزینه را در خود ذخیره نماید. به عنوان مثال در مجموعه دادگان citeulike که شامل تعدادی مقاله است کاربران به گزینه‌ها به طور مستقیم امتیازی نمی‌دهند اما می‌توانند هر مقاله را در کتابخانه مقالات خود ذخیره نمایند.

این طریق برای هر کلمه همانند word را با $\text{rep}(\text{'word'})$ نمایش دهیم، نتیجه محاسبه برداری $\text{rep}(\text{'Tehran'}) - \text{rep}(\text{'Iran'}) + \text{rep}(\text{'France'})$ به $\text{rep}(\text{'Paris'})$ نزدیک‌تر از نمایش سایر کلمات می‌باشد. روش تبدیل پاراگراف به بردار به دنبال به دست آوردن یک نمایش با ابعاد پایین برای هر کلمه و هر پاراگراف است به صورتی که با استفاده از نمایش به دست آمده برای کلمات اطراف هر کلمه و پاراگرافی که آن کلمه در آن قرار دارد بتوان کلمه جاری را پیش‌بینی کرد. این مدل در نهایت به دنبال یافتن یک تابع همانند f است که با دریافت کلمات اطراف هر کلمه و پاراگراف جاری، کلمه جاری را پیش‌بینی کند. در نتیجه تابع f را به صورت زیر خواهیم داشت:


$$f(D_i, w_{t-k}, \dots, w_{t-1}, w_{t+1}, \dots, w_{t+k}) = P(w_t = i | \text{context}) \quad (1)$$

که در این رابطه w_t نشان‌دهنده کلمه t -ام در دنباله کلمات است، D_i نمایش پاراگراف جاری را مشخص می‌کند و k تعداد کلمات اطراف هر کلمه که برای پیش‌بینی کلمه جاری استفاده می‌شود را نشان می‌دهد. در عمل این تابع به کمک یک شبکه جلورو به دست می‌آید و به کمک روش پس‌انتشار خطا مقادیر بهینه برای نمایش کلمات و پاراگراف را به دست می‌آورد. در این روش جهت آموزش شبکه در هر مرحله یک نمونه با طول مشخص از محتوای یک پاراگراف انتخاب می‌شود و سپس با محاسبه خطا، پارامترهای شبکه در کنار ماتریس پاراگراف‌ها (D) و کلمات (w) به‌روز می‌شوند. در این روش ماتریس کلمات در تمام پاراگراف‌ها مشترک است و یک کلمه در پاراگراف‌های مختلف بازنمایی یکسانی خواهد داشت و ماتریس پاراگراف نیز در تمام کلمات آن پاراگراف مشترک است.

در مرحله بعد جهت محاسبه بردار یک پاراگراف جدید که تاکنون دیده نشده نیز کافی است یک سطر به ماتریس پاراگراف‌ها یا همان D افزوده شود. سپس دوباره شبکه با استفاده از این پاراگراف آموزش داده شود ولی تنها مقادیر بردار پاراگراف جدید به‌روز می‌شوند و سایر پارامترهای شبکه ثابت نگاه داشته می‌شوند. یک شمای کلی از این مدل در شکل ۱ آمده است. در نتیجه با استفاده از این روش مدل پیشنهادی قادر است به یک بردار یکتا برای هر کدام از گزینه‌ها دست یابد که ویژگی‌های اصلی هر گزینه را از متن آن گزینه استخراج کرده است و بسیاری از مشکلات روش‌های معمول مورد استفاده را برطرف کرده است. از جمله این که در این روش اطلاعات بسیاری درباره یک پاراگراف همچون ترتیب کلمات حفظ می‌شود و از این ترتیب در ساخت بردار پاراگراف استفاده می‌شود و نکته‌ی مهم‌تر این‌که با استفاده از این روش می‌توان هر گزینه را به کمک یک بردار با تراکم بالا و بعد کم نمایش داد $[A]$ در نتیجه ورودی سامانه توصیه‌گر حجم کمتری خواهد داشت و پردازش آن سریع‌تر انجام می‌پذیرد.

۳-۲- شبکه خودرمزگذار

پس از بازنمایی گزینه‌ها به کمک روش معرفی شده سامانه توصیه‌گر باید ویژگی‌های مناسب برای هر گزینه را از بازنمایی آن‌ها استخراج کند. در این‌جا منظور از "استخراج ویژگی‌های مناسب" به دست آوردن ویژگی‌هایی از گزینه‌ها است که به سیستم کمک می‌کند که سریع‌تر به کارایی بالاتری که ممکن بود نتواند با استفاده از بازنمایی اولیه گزینه‌ها به آن کارایی برسد، دست یابد [۱۶]. در روش پیشنهادی همانند [۷] از شبکه SDAE جهت استخراج ویژگی‌های مناسب از نمایش اولیه گزینه‌ها استفاده می‌شود. SDAE یک شبکه جلورو جهت یادگیری ویژگی‌های مهم داده‌های ورودی است. این شبکه نسخه نويزی شده داده‌ها را در ورودی دریافت می‌کند و پس از نگاشت آن‌ها به یک فضای نهان کوچک‌تر تلاش



شکل ۳- ساختار کلی روش ارائه شده. ورودی‌ها ماتریس امتیازات، ماتریس ارتباطات گزینه‌ها و اطلاعات اضافی موجود درباره گزینه‌ها هستند. روش ارائه شده همزمان ماتریس‌های امتیازات و ارتباطات را تجزیه می‌کند و ویژگی‌های نهان گزینه‌ها را به کمک تجزیه این دو ماتریس در کنار اطلاعات اضافی موجود درباره گزینه‌ها به دست می‌آورد. بخش مشخص شده در حاشیه قرمز رنگ نمایش گزینه‌ها را به دست می‌آورد و سپس به کمک یک خودرمزگذار که در بخش با حاشیه با رنگ آبی مشخص شده ویژگی‌های مهم گزینه‌ها استخراج می‌شود. این ویژگی‌ها در کنار ویژگی‌های به دست آمده از تجزیه ماتریس امتیازات (حاشیه سبز) و ارتباطات (حاشیه زرد) جهت پیش‌بینی امتیازات نامشخص استفاده می‌شوند

وابسته بودن به ماتریس امتیازات به محتوای آن‌ها نیز وابسته است و محتوای گزینه‌ها نیز در ویژگی‌های نهان آن‌ها تاثیرگذار است.

در مدل پیشنهادی از یک شبکه عمیق جهت به دست آوردن بازنمایی گزینه‌ها و از یک خودرمزگذار جهت استخراج ویژگی‌های مهم از بازنمایی به دست آمده از گزینه‌ها استفاده شده است. با توجه به این که ویژگی‌های نهان به دست آمده برای هر گزینه باید با محتوای آن گزینه نیز ارتباط داشته باشد، در نتیجه ویژگی‌های استخراج شده از شبکه خودرمزگذار باید در ویژگی‌های نهان گزینه‌ها تاثیرگذار باشند. برای این منظور مدل تلاش می‌کند ویژگی‌های نهان گزینه‌ها را به نحوی آموزش دهد که به ویژگی‌های استخراج شده از محتوای گزینه‌ها نزدیک باشد. استفاده از مدل پیشنهادی سبب می‌شود برای گزینه‌هایی که امتیازی برای آن‌ها در دسترس نیست بتوان با استفاده از محتوای آن‌ها، ویژگی‌هایشان را به دست آورد و در نتیجه این گزینه‌ها را نیز به کاربران پیشنهاد داد و مشکل شروع سرد برای گزینه‌ها از این طریق برطرف می‌گردد. به علاوه در این مدل یک ارتباط محکم دوطرفه بین ویژگی‌های استخراج شده از گزینه‌ها و ویژگی‌های به دست آمده از ماتریس امتیازات وجود دارد. این ارتباط سبب می‌شود علاوه بر این که ویژگی‌های محتوای گزینه‌ها به پیش‌بینی بهتر امتیازات کمک می‌کند، ویژگی‌های مهم‌تری نیز از محتوای گزینه‌ها استخراج شده و بازنمایی گزینه‌ها نیز به نحوی به دست آید که ویژگی‌های مهم‌تری از گزینه‌ها را در بر داشته باشد و از این طریق دقت مدل را افزایش دهد.

فرض دیگری که در مدل پیشنهادی در نظر گرفته شده است این است که گزینه‌هایی که به طور صریح مشخص شده است که با یکدیگر ارتباط دارند (مثلاً وجود ارجاع یک مقاله به مقاله دیگر) نیز می‌توانند در یافتن ویژگی‌های نهان گزینه‌ها به ما کمک کنند، چرا که با توجه به ارتباط آن‌ها با یکدیگر ویژگی‌های نهان آن‌ها نیز باید به یکدیگر ارتباط داشته باشد. با توجه به این که در نهایت کلمات موجود در اطلاعات اضافی موجود درباره گزینه‌ها ویژگی‌های محتوایی آن گزینه را می‌سازند در برخی حالت‌ها ممکن است دو گزینه کلمات مشترک بسیاری داشته باشند در نتیجه بردار ویژگی‌های آن‌ها به یکدیگر شبیه باشد اما از لحاظ معنایی با یکدیگر ارتباط چندانی نداشته باشند. به عنوان مثال مطرح شده در [۱۲] در خصوص دو مقاله A و B را در نظر بگیرید که هر دو درباره استفاده از یادگیری ماشین در شبکه‌های اجتماعی ارائه شده‌اند.

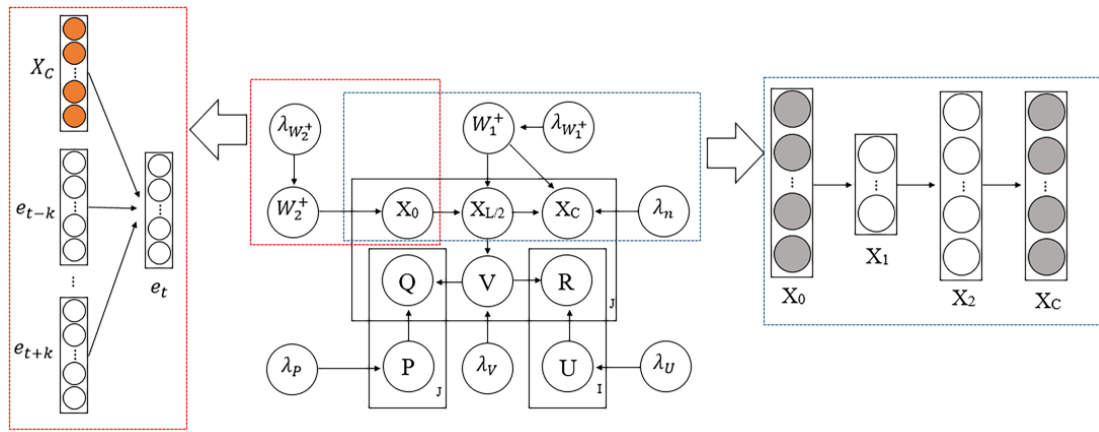
مقدار $R_{nm} = 1$ است اگر کاربر m گزینه n را در کتابخانه شخصی خود ذخیره کرده باشد و در غیر این صورت $R_{nm} = 0$ خواهد بود. در این‌جا در کنار ماتریس امتیازات و مجموعه توالی لغات، یک ماتریس ارتباطات بین گزینه‌ها هم در نظر می‌گیریم و آن را با $G = [G_{mm}]_{M \times M}$ نمایش می‌دهیم. این ماتریس نیز یک ماتریس دوتایی است که نشان‌دهنده ارتباطات بین گزینه‌ها است. به عنوان مثال در مجموعه مقالات به‌زای دو مقاله m و m' مقدار $G_{mm'} = 1$ است اگر یکی از این دو مقاله به دیگری ارجاع داده باشد و در غیر این صورت این مقدار برابر صفر خواهد بود.

در نهایت سیستم باید بتواند با دریافت برخی از امتیازات موجود در ماتریس R به همراه مجموعه توالی لغات $w_{1m}, w_{2m}, \dots, w_{T_{mm}}$ که همان اطلاعات اضافی موجود درباره گزینه‌ها هستند در کنار ماتریس ارتباطات گزینه‌ها G ، مقادیر نامشخص R را پیش‌بینی نماید. خلاصه‌ای از تمام نمادهای استفاده شده در این مقاله در جدول ۱ قابل مشاهده است.

۴-۲- روش پیشنهادی

مدل پیشنهادی یک روش ترکیبی جهت ارائه پیشنهاد است که هم از ماتریس امتیازات و هم از اطلاعات اضافه موجود جهت ارائه پیشنهاد استفاده می‌کند. ایده‌ی کلی این مدل در شکل ۳ آمده است. در مدل ارائه شده همانند روش تجزیه ماتریسی فرض می‌شود که یک فضای نهان برای کاربران و گزینه‌ها وجود دارد که میزان علاقه هر کاربر به هر گزینه از ضرب داخلی بازنمایی آن‌ها در این فضا به دست می‌آید. در نتیجه می‌توان با تجزیه ماتریس امتیازات به بازنمایی کاربران و گزینه‌ها دست یافت.

با توجه به این که در اکثر موارد اطلاعات چندانی درباره کاربران در دسترس نیست و تنها از ارتباطات کاربر با سیستم می‌توان به ویژگی‌های نهان کاربر دست یافت در روش ارائه شده نیز جهت به دست آوردن ویژگی‌های نهان کاربران تنها از ماتریس امتیازات کاربر به گزینه‌ها استفاده می‌شود و این ویژگی‌ها با استفاده از تجزیه ماتریس امتیازات به دست می‌آید. اما با توجه به در دست بودن اطلاعات اضافی درباره گزینه‌ها در سیستم فرض می‌شود که بردار نهان گزینه‌ها علاوه بر



شکل ۴- بخش مشخص شده در مستطیل با حاشیه نقطه‌چین آبی شبکه یک SDAE دو لایه را مشخص می‌کند و بخش مشخص شده در مستطیل با حاشیه نقطه‌چین قرمز نشان‌دهنده شبکه تبدیل پاراگراف به بردار است

تخمینی که از متغیرهای دیگر تاکنون به دست آمده، استفاده می‌شود و این عمل تا رسیدن به یک کمینه محلی برای تابع خطای تعریف شده ادامه پیدا می‌کند. تابع لگاریتم درست‌نمایی در مدل پیشنهادی به صورت زیر تعریف می‌شود:

$$\begin{aligned} \mathcal{L} = & -\frac{\lambda_q}{2} \sum_j \|p_j\|_2^2 - \frac{\lambda_u}{2} \sum_i \|u_i\|_2^2 - \frac{\lambda_w}{2} (\|W^{(2)}\|_2^2 + \|b^{(2)}\|_2^2) \\ & - \frac{\lambda_s}{2} \sum_j \sum_i \|\sigma(X_{i-1,j} W_1^{(2)} + b_1^{(2)}) - X_{i,j}\|_2^2 \\ & - \frac{\lambda_v}{2} \sum_j \|v_j - X_{L2,j}^T\|_2^2 - \frac{\lambda_n}{2} \sum_j \|X_{L2,j} - X_{C,j}\|_2^2 \\ & - \lambda_p \sum_{ij} \frac{B_{ij}}{2} (G_{ij} - v_j p_j^T)^2 - \sum_{ij} \frac{C_{ij}}{2} (R_{ij} - u_i v_j^T)^2 \end{aligned} \quad (3)$$

در تابع هدف (۳) $\lambda_u, \lambda_w, \lambda_q, \lambda_s, \lambda_e, \lambda_n, \lambda_v, \lambda_p$ پارامترهای منظم‌ساز مدل هستند. خروجی لایه میانی شبکه SDAE را نمایش می‌دهد که نشان‌دهنده ویژگی‌های محتوایی به دست آمده از گزینه z است. در این تابع هدف $X_{0,z}$ برابر $A_j \times D$ است که A_j نیز یک بردار M بعدی می‌باشد که فقط عنصر z آن برابر یک است و سایر مقادیر آن صفر هستند در نتیجه $X_{0,z}$ دقیقاً برابر با سطر z -ام ماتریس D که همان بازنمایی برداری گزینه z است خواهد بود. باتوجه به این که ماتریس امتیازات به صورت غیرمستقیم از فعالیت‌های کاربر در سیستم به دست آمده است.

در نتیجه از مقدار صفر در ماتریس امتیازات می‌توان به دو صورت برداشت کرد، یا کاربر به این گزینه علاقه‌ای ندارد و یا کاربر این گزینه را تا به حال ندیده است و مشخص نیست که به این گزینه علاقه دارد یا نه. در نتیجه در روش پیشنهاد شده همانند [۱۲] و [۷] از پارامتر اطمینان C_{ij} در کنار ماتریس امتیازات استفاده می‌شود که مقدار آن در حالتی که امتیاز $R_{ij} = 1$ است بیشتر از مواقعی است که $R_{ij} = 0$. ماتریس B نیز جهت سنجش مقدار ارتباط بین دو گزینه استفاده شده است و مقادیر آن با توجه به قدرت ارتباط بین دو گزینه تنظیم می‌شود. در این تابع هدف، $X_{0,z}$ نسخه نویزی شده نمایش برداری گزینه z است که از روش تبدیل پاراگراف به بردار به دست آمده است. جمله چهارم و ششم در تابع هدف معرفی شده معادل تابع هدف شبکه SDAE است.

در نتیجه متن این مقالات بسیار به یکدیگر شبیه است و در نتیجه احتمالاً ویژگی‌های استخراج شده از متن آن‌ها نیز بسیار به یکدیگر شبیه خواهد بود. حال فرض کنید مقاله A یک الگوریتم یادگیری ماشین را ارائه می‌کند که در یک کاربرد از شبکه‌های اجتماعی مورد استفاده قرار می‌گیرد و مقاله B از روش‌های استاندارد معرفی شده در یادگیری ماشین جهت بررسی و تحلیل یک ویژگی خاص در شبکه‌های اجتماعی استفاده کرده است. کاربرانی که در زمینه یادگیری ماشین فعالیت می‌کنند مقاله A را ترجیح می‌دهد و کاربرانی که در زمینه شبکه‌های اجتماعی فعالیت می‌کنند مقاله B را ترجیح خواهند داد. اما با توجه به محتوا دو مقاله شبیه یکدیگر هستند و به هر دو دسته کاربر پیشنهاد می‌گردند. اما در صورتی که از ارتباط بین مقالات نیز استفاده گردد با توجه به ارجاع‌های مورد استفاده در مقاله این دو مقاله با توجه به این که در زمینه‌های متفاوتی قرار دارند ویژگی‌های به دست آمده برای آن‌ها نیز متفاوت خواهد بود و در نتیجه به کاربران متفاوتی پیشنهاد خواهند شد [۱۲].

علاوه بر این موارد، استفاده از ارتباطات بین گزینه‌ها برای گزینه‌هایی که به تازگی وارد سیستم شده‌اند می‌تواند بسیار مفید باشد. با توجه به این که استفاده از روش تجزیه ماتریس امتیازات در این حالت نمی‌تواند کمکی به پیدا کردن گزینه‌های مشابه کند و استفاده از محتوا نیز در برخی موارد مشکل اشاره شده در به دست آوردن دسته گزینه را دارد در نتیجه می‌توان از ارتباطات بین گزینه‌ها نیز جهت پیدا کردن گزینه‌های مشابه و پیشنهاد آن به کاربران استفاده کرد. ویژگی مهمی که سبب تمایز روش پیشنهادی نسبت به سایر روش‌ها می‌گردد این است که تمام بخش‌های مدل پیشنهادی با یکدیگر یک ارتباط محکم دارند. این امر سبب می‌گردد که ویژگی‌های به دست آمده در هر بخش بر روی ویژگی‌های نهان به دست آمده در قسمت‌های دیگر تاثیر بگذارد. بنابراین، در صورتی که در یکی از بخش‌ها اطلاعات چندانی وجود نداشته باشد سایر بخش‌ها به مدل کمک می‌کنند که از آن بخش نیز مهمترین ویژگی‌ها استخراج گردد تا مدل در نهایت به پیش‌بینی بهتری از ماتریس امتیازات برسد. نمایش مدل گرافکی روش پیشنهادی در شکل ۴ قابل مشاهده است. ویژگی‌های نهان نهایی به دست آمده برای گزینه‌ها تاثیر مستقیم می‌گذارند.

۴-۳- تخمین مقادیر متغیرها

در مدل پیشنهادی جهت به دست آوردن مقادیر بهینه متغیرها از روش تخمین بیشینه کردن امید استفاده می‌کنیم. به این صورت که در به‌روزرسانی هر متغیر

جدول ۱- خلاصه نمادها

نماد	توصیف
N	تعداد کاربران
M	تعداد گزینه‌ها
d	تعداد ویژگی‌های پنهان گزینه‌ها و کاربران
H	تعداد ویژگی‌های نمایش اولیه گزینه‌ها
T _m	تعداد لغات مورد استفاده در توصیف گزینه m
k	تعداد لغات مجاور مورد استفاده در تبدیل کلمه به بردار
S	تعداد کل لغات موجود در دایره لغات
$W_{tm} \in \mathbb{R}^{1 \times S}$	نمایش لغت t-ام در دنباله لغات توصیف گزینه m
$W^t \in \mathbb{R}^{1 \times S}$	نمایش لغت t-ام در مجموعه تمام کلمات موجود در دایره واژگان
$e^t \in \mathbb{R}^{1 \times H}$	بردار ویژگی‌های کلمه t-ام در دایره واژگان
$e_w \in \mathbb{R}^{1 \times H}$	بردار ویژگی‌های کلمه w
$E \in \mathbb{R}^{S \times H}$	ماتریس نمایش تمام بردارهای کلمات موجود در دایره واژگان
$D \in \mathbb{R}^{M \times H}$	ماتریس نمایش تمام بردارهای گزینه‌های موجود در سامانه
$G \in \mathbb{R}^{M \times M}$	ماتریس ارتباطات بین گزینه‌ها
$X_c^m \in \mathbb{R}^{1 \times H}$	بردار ویژگی‌های اولیه به دست آمده از طریق شبکه تبدیل پاراگراف به بردار برای گزینه m
$R \in \mathbb{R}^{M \times N}$	ماتریس امتیازات
$U \in \mathbb{R}^{N \times d}$	ویژگی‌های پنهان کاربران
$V \in \mathbb{R}^{M \times d}$	ویژگی‌های پنهان گزینه‌ها
$P \in \mathbb{R}^{d \times M}$	ویژگی‌های پنهان ارتباطات گزینه‌ها
$W^{(1)} \in \mathbb{R}^{H \times S}$	ماتریس وزن‌های شبکه تبدیل پاراگراف به بردار
$b^{(1)} \in \mathbb{R}^{1 \times S}$	بردار بایاس شبکه تبدیل پاراگراف به بردار
K_1	تعداد گرهای لایه ۱-ام شبکه SDAE
$W_1^{(2)} \in \mathbb{R}^{K_1-1 \times K_1}$	ماتریس وزن‌های لایه ۱-ام شبکه SDAE
$b_1^{(2)} \in \mathbb{R}^{1 \times K_1}$	بردار بایاس لایه ۱-ام شبکه SDAE

$$U = U - \alpha[(C \odot (U \times V^T - R)) \times V + \lambda_u U] \quad (۴)$$

$$P = P - \alpha[(B \odot (V \times P^T - G)) \times V + \lambda_p P] \quad (۵)$$

$$V = V - \alpha[(C \odot (U \times V^T - R))^T \times U + \lambda_p (B \odot (V \times P^T - G))^T \times P + \lambda_v (V - X_{Lj}^T)] \quad (۶)$$

در این روابط \odot نشان‌دهنده ضرب عنصر به عنصر مقادیر دو ماتریس است و \times ضرب دو ماتریس را نمایش می‌دهد. α نیز پارامتر گام یادگیری است. با در دست داشتن مقادیر به‌روز شده برای ماتریس‌های U, V و P سایر پارامترهای مدل تنها وزن‌های شبکه SDAE هستند که آن مقادیر را می‌توان به کمک روش پس‌انتشار خطا به‌روزرسانی کرد. در نتیجه با چندین بار به‌روزرسانی پی‌درپی پارامترهای مدل می‌توان به یک جواب بهینه محلی برای تابع خطای تعریف شده در معادله (۳) دست یافت.

الگوریتم ۱- الگوریتم پیش‌پردازش داده‌های ورودی

- ورودی:** اطلاعات اضافه موجود درباره گزینه‌ها (دنباله کلمات توصیف گزینه $W_{1,m}, \dots, W_{T,m}$)
- خروجی:** مقادیر بهینه اولیه برای وزن‌های شبکه SDAE و شبکه تبدیل پاراگراف به بردار.
- تا رسیدن به خطای اعتبار سنجی کمتر از ϵ
 - برای تمام گزینه‌های $j = 1, \dots, M$
 - برای تمام کلمات موجود در دنباله کلمات، بردار احتمال این کلمه را با استفاده از شبکه تبدیل پاراگراف به بردار محاسبه کن.
 - با استفاده از خطای به دست آمده در گام قبل و روش پس انتشار خطا پارامترهای شبکه $(W^{(1)}, b^{(1)}, D, E)$ را به‌روز کن.
 - مقدار X_{Cj} را برابر سطر j ماتریس D قرار بده. $(X_{Cj} \leftarrow D[j,:])$
 - یک نویز گوسی با واریانس λ_j به X_{Cj} اضافه کن و حاصل را در X_{0j} قرار بده. $(X_{Cj} \leftarrow D[j,:])$
 - مقدار X_{Lj} را با استفاده از شبکه SDAE محاسبه کن و خطای شبکه را برابر $X_{Cj} - X_{Lj}$ قرار بده.
 - با استفاده از مجذور خطای به دست آمده در مرحله قبل و روش پس انتشار خطا پارامترهای شبکه $(W^{(2)}, b^{(2)})$ را به‌روزرسانی کن.

الگوریتم نهایی جهت به دست آوردن مقادیر بهینه برای U, V و P از دو قسمت تشکیل شده است. در مرحله اول مقادیر اولیه بهینه برای وزن‌های شبکه SDAE و شبکه تبدیل پاراگراف به بردار محاسبه می‌گردند (که در الگوریتم ۱ آمده است). مدل تلاش می‌کند با استفاده کلمات موجود در توصیف یک گزینه، بردار ویژگی‌های آن گزینه را با استفاده از شبکه تبدیل پاراگراف به بردار محاسبه نماید و سپس از این بردار به عنوان ورودی اولیه شبکه SDAE استفاده می‌نماید و با تکرار این فرایند برای تمام گزینه‌ها وزن‌های اولیه این دو شبکه را محاسبه می‌نماید. این مرحله پیش‌پردازش داده‌ها کمک می‌کند تا برای مدل نهایی سریع‌تر و با دقت بالاتری مقادیر بهینه پیدا شود. در مرحله بعد با استفاده از مقادیر به دست آمده برای بردار توصیف گزینه‌ها روش تلاش می‌کند مقادیر بهینه برای پارامترهای نهایی مدل را محاسبه نماید. فرایند اجرای این مرحله در الگوریتم ۲ آمده است.

۴-۴- پیش‌بینی امتیازات

پس از این که مقادیر بهینه محلی برای پارامترهای مدل محاسبه شدند، اگر داده‌های مشاهده شده را با D نمایش دهیم امتیازات نامشخص را می‌توان به کمک رابطه زیر محاسبه کرد:

مشابه روش CDL [۷] با استفاده از این جمله، شبکه تلاش می‌کند ویژگی‌هایی را از ورودی به دست آورد که به کمک آن‌ها بتوان نسخه اصلی ورودی را به کمک نسخه نویزی شده آن ساخت. در نتیجه به کارگیری شبکه SDAE سبب انتخاب ویژگی‌های مهم گزینه‌ها خواهد شد. جمله پنجم نیز معادل تابع خطای یک شبکه جلورو است که مقدار j_z را به عنوان هدف در نظر گرفته و X_{Cj} ورودی آن شبکه است. با الهام از روش CDL، این جمله به‌عنوان پل بین محتوای گزینه‌ها و ماتریس امتیازات به کار گرفته شده است. این لایه میانی در کنار بردار ویژگی‌های به دست آمده از ماتریس امتیازات قرار می‌گیرد و یک ارتباط دوطرفه بین ویژگی‌های محتوایی و ویژگی‌های استخراج شده از ماتریس امتیازات ایجاد می‌کند که از یک طرف سبب انتخاب بهتر ویژگی‌های نهان گزینه‌ها می‌گردد و از طرف دیگر این انتخاب ویژگی‌های مناسب سبب افزایش دقت مدل در پیش‌بینی عناصر خالی امتیازات خواهد شد.

از جمله مهمترین تفاوت‌های روش پیشنهادی و روش CDL استفاده از ارتباطات بین گزینه‌ها با یکدیگر است که در جمله هفتم تابع هدف معرفی شده مورد استفاده قرار گرفته است و سبب نزدیک شدن نمایش گزینه‌های مرتبط با یکدیگر می‌گردد و تفاوت دیگر استفاده از روش تبدیل پاراگراف به بردار جهت به دست آوردن نمایش اولیه گزینه‌ها است که سبب کاهش بعد داده‌های ورودی و در نتیجه کاهش تعداد پارامترهای آزاد می‌شود و از این طریق باعث جلوگیری از بیش‌برازش و همچنین کاهش زمان رسیدن به حالت پایدار می‌گردد. جهت به دست آوردن مقادیر جدید بردارهای U_i, V_j و P_j نیز در هر مرحله با در نظر گرفتن مقادیر جاری برای وزن‌های شبکه، گرادینان L را نسبت به بردارهای U_i, V_j و P_j محاسبه کرده و مقدار آن را برابر صفر قرار می‌دهیم و در نتیجه به قوانین به‌روزرسانی زیر می‌رسیم:

عوامل فیلم استفاده شده است، به این صورت که بین فیلم‌هایی که کارگردان مشترک دارند یک ارتباط با قدرت ۱۰ و به ازای هر بازیگر مشترک ارتباط با قدرت ۱ در نظر گرفته شده است.

جدول ۲- خلاصه اطلاعات آماری مجموعه داده‌های مورد استفاده

MovieLens	citenlike-T	citenlike-A	مجموعه داده
۲.۱۰۳	۷.۹۴۷	۵.۵۵۱	تعداد کاربران
۹.۴۲۳	۲۵.۹۷۵	۱۶.۹۸۰	تعداد گزینه‌ها
۱۶۰.۳۳۲	۱۳۴.۸۶۰	۲۰۴.۹۸۷	تعداد امتیازات
٪۹۹.۳	٪۹۹.۹۳	٪۹۹.۸	تنکی ماتریس امتیازات
۱.۴۶۱.۹۷۲	۳۲.۵۶۵	۴۴.۷۰۹	تعداد ارتباط‌های گزینه‌ها
۷۶	۱۷	۳۷	میانگین تعداد امتیازات کاربر
۱۴۳.۴	۱.۳	۲.۶	میانگین ارتباط‌های گزینه‌ها
۲۹۶.۰۰	۲۰.۰۰۰	۸.۰۰۰	تعداد تگ
۱۵۷	۶۴	۶۷	میانگین تگ هر گزینه

خلاصه‌ای از اطلاعات آماری این مجموعه‌های داده در جدول ۲ آمده است. با توجه به این که روش‌های مورد نظر برای مقایسه با روش پیشنهادی از تگ برای نمایش گزینه‌ها استفاده می‌کنند، خلاصه‌ای از اطلاعات آماری تگ‌ها نیز در این جدول آمده است.

علاوه بر مجموعه داده‌های معرفی شده جهت بهبود عملکرد روش تبدیل پاراگراف به بردار یک مجموعه داده دیگر نیز از وبسایت IMDB استخراج شد. این مجموعه داده شامل متن تمام نظرات کاربران درباره فیلم‌های موجود در مجموعه داده movielens است که شامل ۱,۱۰۸,۵۷۹ پاراگراف متن است که نظر هر کاربر را درباره یک فیلم بیان می‌کند. این مجموعه داده در مرحله پیش‌آموزش جهت بهبود عملکرد روش تبدیل پاراگراف به بردار مورد استفاده قرار می‌گیرد و سبب می‌شود برای کلمات بردارهای بازنمایی بهتری به دست آید و در نتیجه ارتباط بین کلماتی که از لحاظ معنایی به یکدیگر نزدیک هستند بهتر مشخص گردد.

۵-۲- معیار ارزیابی

سامانه‌های توصیه‌گر را می‌توان از جنبه‌های مختلفی همانند کارایی، دقت و مقیاس‌پذیری الگوریتم ارائه شده مورد بررسی قرار داد. از این بین، دقت مهمترین ویژگی‌ای است که سامانه‌های توصیه‌گر را با توجه به آن با یکدیگر مقایسه می‌کنند، چرا که هدف در سامانه‌های توصیه‌گر فهمیدن کاربر و ارائه پیشنهادهایی به او است که به آن‌ها علاقه دارد تا از این طریق اعتماد کاربر به سیستم جلب شود [۱۹]. برای اندازه‌گیری دقت در روش ارائه شده، ابتدا کاربران را به صورت تصادفی به دو دسته آموزش و آزمون جدا می‌کنیم. در اینجا از ۹۰٪ کاربران برای آموزش و ۱۰٪ مابقی کاربران برای آزمون استفاده کرده‌ایم. از بین کاربران آزمون نیز Q گزینه مورد علاقه کاربر را که به صورت تصادفی انتخاب شده‌اند به داده‌های آموزش اضافه می‌کنیم و سایر گزینه‌های مورد علاقه کاربر را در داده‌های آموزش قرار نمی‌دهیم. برای ارزیابی و مقایسه روش ارائه شده با سایر روش‌ها در شرایط مختلف، دو حالت داده‌های تنک و متراکم را در نظر گرفته‌ایم. مقدار Q را در آزمایشات برای این دو حالت به ترتیب برابر ۱ و ۱۰ قرار داده‌ایم. همانند روش‌های پایه مورد مقایسه [۷] [۱۲] با توجه به این که امتیازات از بازخورد غیرمستقیم کاربر به دست آمده‌اند ما نیز از معیار فراخوان^{۱۷} جهت ارزیابی و مقایسه روش پیشنهادی استفاده می‌کنیم. به‌خصوص با توجه به این که امتیاز صفر در ماتریس امتیازات می‌تواند ناشی از عدم علاقه کاربر به آن گزینه و یا عدم اطلاع کاربر از آن گزینه باشد، استفاده از معیارهایی همچون معیار دقت^{۱۸} نمی‌تواند دقیق باشد چرا که این معیار

$$\mathbb{E}[R_{ij}|D] \approx \mathbb{E}[u_i|D](\mathbb{E}[\theta_j|D] + \mathbb{E}[\epsilon_j|D] + \mathbb{E}[\pi_j|D])^T \quad (7)$$

که در این رابطه θ_j از ماتریس امتیازات، ϵ_j از اطلاعات محتوای گزینه‌ها و π_j از ارتباطات بین گزینه‌ها به دست آمده‌اند. اگر هر کدام از این سه دسته اطلاعات برای یک گزینه در دسترس نباشند از دسته‌های اطلاعاتی دیگر برای پیش‌بینی استفاده می‌شود. به عنوان مثال اگر برای یک گزینه هیچ امتیازی ثبت نشده باشد در نتیجه از ویژگی‌های به دست آمده از ماتریس امتیازات نمی‌توان استفاده کرد. پس در پیش‌بینی امتیاز این گزینه فقط از اطلاعات محتوا و ارتباطات آن استفاده می‌شود. در نتیجه برای این گزینه خواهیم داشت:

$$R_{ij} = u_i(\epsilon_j + \pi_j)^T \quad (8)$$

با استفاده از این رابطه می‌توان برای هر گزینه با استفاده از اطلاعات موجود رای را پیش‌بینی کرد. به عنوان مثال برای گزینه‌هایی که تازه وارد سیستم شده‌اند می‌توان با استفاده از محتوای آن‌ها در کنار ارتباطات بین گزینه‌ها آن‌ها را پیشنهاد کرد و در نتیجه یکی از بزرگترین چالش‌های موجود در سامانه‌های توصیه‌گر را با استفاده از این روش برطرف نمود. از طرف دیگر در روش پیشنهادی با استفاده از منابع اطلاعاتی مختلف دقت پیش‌بینی سیستم افزایش می‌یابد.

۵- ارزیابی روش پیشنهادی

جهت ارزیابی روش پیشنهادی از ۳ مجموعه داده که از فعالیت‌های کاربران در دنیای واقعی به دست آمده استفاده شده است و میزان دقت روش پیشنهادی در این مجموعه داده‌ها با سایر روش‌ها مورد بررسی قرار گرفته است.

۵-۱- مجموعه داده‌ها

در این مقاله ما از ۳ مجموعه داده از دنیای واقعی استفاده کرده‌ایم. دو مجموعه داده از داده‌های citeulike^{۱۵} و یک مجموعه داده از داده‌های movielens^{۱۶} هستند. Citeulike یک وبسایت است که به کاربران خود کمک می‌کند از بین تعداد انبوهی از مقالات چاپ شده مقاله‌های مورد علاقه خود را پیدا کنند. در این وبسایت هر کاربر برای خود یک کتابخانه شخصی می‌سازد و می‌تواند مقالات مورد علاقه خود را در کتابخانه شخصی خود قرار دهد. برای هر مقاله هم معمولاً عنوان، چکیده و ارجاعات آن مقاله در دسترس قرار دارد. دو مجموعه داده اول از این وبسایت به وسیله نویسندگان مقالات CTR و CDL جمع‌آوری شده‌اند. اما جمع‌آوری این داده‌ها با رویکردهای مختلفی انجام شده است و در نتیجه این دو مجموعه داده تفاوت‌های بسیاری از لحاظ بعد داده‌ها، میزان تنک بودن داده‌ها و موارد دیگر دارند. مجموعه داده سوم، movielens است که از دو قسمت تشکیل شده است. قسمت اول که شامل عناوین فیلم‌ها، امتیاز کاربران به فیلم‌ها و عوامل فیلم است در همین مجموعه داده قرار دارد. با توجه به این که در این پژوهش به محتوای گزینه‌ها نیز جهت ارائه پیشنهاد نیاز داریم و در این مجموعه داده از محتوای گزینه‌ها اطلاعاتی وجود ندارد، قسمت دوم این مجموعه داده که شامل داستان و خلاصه فیلم‌ها است را ما از وبسایت IMDB استخراج کردیم. همانند [۷] به جهت این که این مجموعه داده نیز با دو مجموعه داده اول که از بازخورد غیرمستقیم کاربر به دست آمده همخوانی داشته باشد، تنها از بازخوردهای مثبت کاربران به فیلم‌ها (امتیاز ۵ از ۵) استفاده شده است و سایر امتیازات در نظر گرفته نشده‌اند. در این مجموعه داده نیز کاربرانی که کمتر از ۳ امتیاز دارند در نظر گرفته نشده‌اند. برای ایجاد ارتباط بین گزینه‌ها در این مجموعه داده که فیلم‌ها هستند، از

آمده‌اند و از یک شبکه ۲ لایه SDAE که ۶۰ نورون در لایه پنهان دارد استفاده شده است.

در شبکه تبدیل پاراگراف به بردار نیز از $H = 300$ نورون برای توصیف هر کلمه و پاراگراف و از پنجره $k = 10$ کلمه در هر طرف هر کلمه برای به دست آوردن بردار کلمه جاری استفاده شده است. تعداد ویژگی‌های نهان مورد استفاده جهت نمایش گزینه‌ها و کاربران نیز که در تمام روش‌ها مورد استفاده قرار می‌گیرد به صورت مشترک برابر $D = 50$ در نظر گرفته شده است.

۵-۴- ارزیابی روش‌ها

در این بخش کارایی روش پیشنهادی را با روش‌های CDL [۷] و تجزیه ماتریسی [۳] مقایسه می‌کنیم. جهت مقایسه این سه روش از معیار recall@M با مقادیر $M = [50, 100, 150, 200, 250, 300]$ استفاده می‌شود. نتایج حاصل از این آزمایش در مجموعه داده‌های مختلف در شکل ۵ آمده است. نتایج به دست آمده از مقایسه این روش‌ها نشان می‌دهد استفاده از اطلاعات اضافی تأثیر چشم‌گیری بر روی نتایج دارد و این تأثیر با افزایش تعداد نمونه‌های بازگردانده شده به کاربر نمایان‌تر می‌گردد و در مقادیر بالاتر M فاصله نتایج از یکدیگر افزایش می‌یابد. دلیل این امر این است که زمانی که تعداد اندکی گزینه باید به کاربر بازگردانده شود گزینه‌های معروف به احتمال زیادی انتخاب می‌شوند چون که اکثر کاربران به آن‌ها علاقه دارند. در نتیجه فاصله در مقادیر پایین‌تر M کم است و با افزایش M با توجه به محدود بودن گزینه‌های مشهور روش‌هایی همانند تجزیه ماتریسی که بر این اساس عمل می‌کنند نمی‌توانند عملکرد خوب خود را در مقادیر بالای M حفظ نمایند.

بازخوردهای منفی کاربر را نیز در نظر می‌گیرد. اما چون معیار یادآوری تنها به بازخوردهای مثبت کاربر وابسته است می‌تواند به درستی محاسبه گردد.

برای محاسبه مقدار یادآوری برای یک کاربر ابتدا میزان امتیاز یک کاربر به تمامی گزینه‌ها را پیش‌بینی می‌کنیم و سپس آن‌ها را به صورت نزولی مرتب کرده و M گزینه اول را به کاربر باز می‌گردانیم. سپس مقدار یادآوری در M گزینه اول با استفاده از رابطه زیر محاسبه می‌شود:

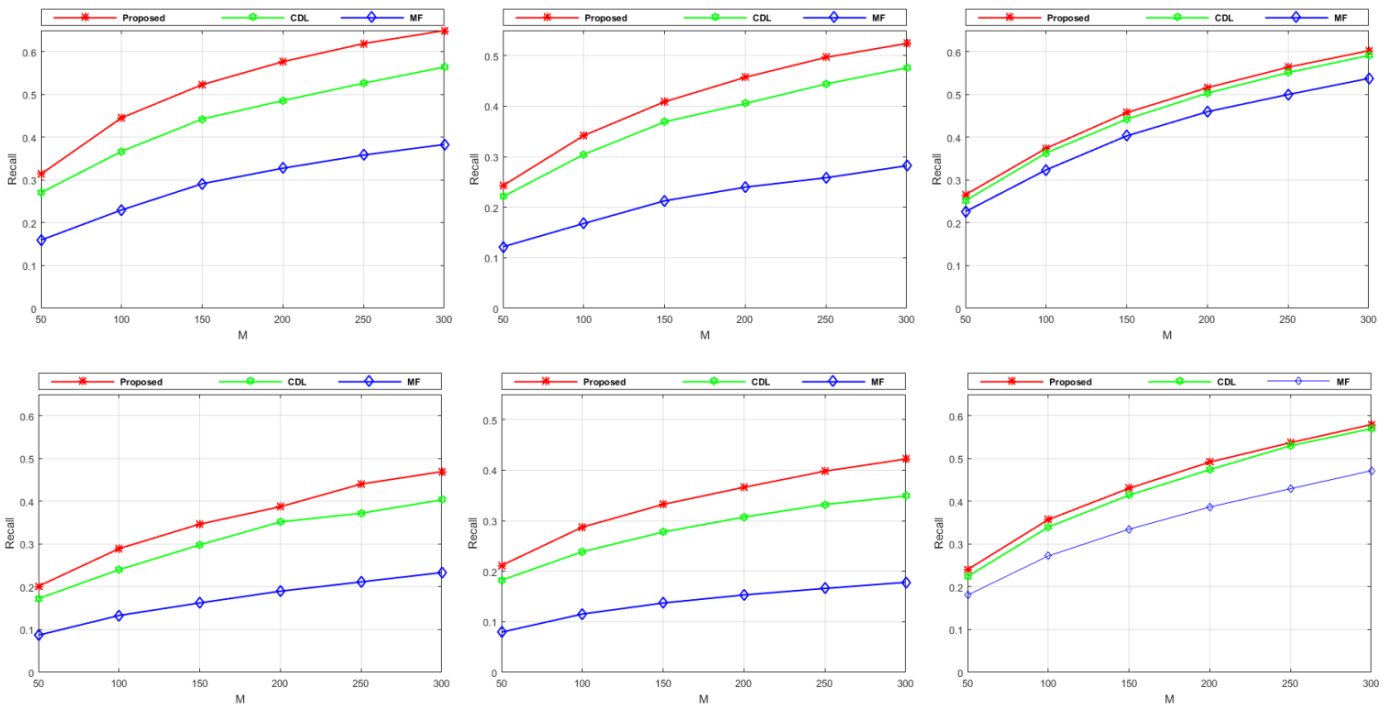
$$\text{recall@M} = \frac{\text{تعداد گزینه‌های مورد علاقه کاربر از بین } M \text{ گزینه اول انتخاب شده}}{\text{تعداد کل گزینه‌هایی که کاربر به آن‌ها علاقه دارد}} \quad (9)$$

این مقدار برای تمام کاربران محاسبه می‌گردد و سپس میانگین یادآوری برای تمام کاربران مقدار یادآوری کل سیستم را مشخص می‌کند.

۵-۳- مدل‌های مورد مقایسه و تنظیمات آزمایش

جهت بررسی عملکرد مدل پیشنهادی، این مدل را با روش CDL که در زمان نوشتن این مقاله بهترین نتایج در سامانه‌های توصیه‌گر روی هر دو مجموعه داده citeulike داشته‌است، مقایسه می‌کنیم. برای اجرای این روش از پیاده‌سازی ارائه‌دهندگان این روش [۷] استفاده شده است و پارامترهای کد نیز همان مقادیر پیش‌فرض مشخص شده در مقاله قرار داده شده است.

روش دیگری که مورد مقایسه قرار گرفته است روش تجزیه ماتریسی است. با توجه به این که این روش از اطلاعات محتوای گزینه‌ها استفاده نمی‌کند مقایسه این روش با روش پیشنهادی منصفانه نخواهد بود و نتایج تنها برای مشخص نمودن اهمیت اطلاعات اضافی مورد استفاده، گزارش شده‌اند. جهت به دست آوردن پارامترهای مدل در روش پیشنهادی داده‌های اعتبارسنجی مورد استفاده قرار گرفته است و با استفاده از این تکنیک اعتبارسنجی متقابل مقادیر



شکل ۵- کارایی روش‌های مورد بررسی در مجموعه داده‌های مختلف. در این نمودارها محور افقی نشان‌دهنده تعداد گزینه‌هایی است که برای کاربر بازگردانده می‌شود. سطر اول مربوط به مجموعه داده‌های متراکم است که در آن‌ها $Q=10$ است و در سطر دوم مربوط به مجموعه داده‌های تنک است که در آن‌ها $Q=1$ قرار داده شده است. ستون سمت چپ مربوط به مجموعه داده citeulike-A، ستون وسط citeulike-T و ستون سمت راست مربوط به داده‌های MovieLens می‌باشد.

مشهور در سیستم را نیز شناسایی کرد. به عنوان مثال در مجموعه داده citeulike که از ارجاعات بین مقالات ارتباطات بین آن‌ها ایجاد شده است می‌توان مقالاتی که پایه مباحث مختلف هستند را با استفاده از ارجاعاتی که به آن مقاله شده است شناسایی کرد چرا که مقالات پایه‌ای و اساسی هر مبحث عموماً بسیار مورد ارجاع قرار می‌گیرند و کاربرانی که به تازگی وارد یک مبحث شده‌اند به دنبال این مقالات هستند. به علاوه استفاده از ارتباطات بین گزینه‌ها به خصوص در مجموعه داده‌های تنک و حالت شروع سرد برای گزینه‌ها می‌تواند بسیار مفید باشد چرا که ماتریس امتیازات در این حالت نمی‌تواند کمک چندانی در پیدا کردن گزینه مشابه بکند ولی با استفاده از ارتباطات بین گزینه‌ها می‌توان گزینه‌های مشابه با یکدیگر را حتی در حالتی که تاکنون امتیازی برای یک گزینه ثبت نشده است پیدا کرد.

در این پژوهش از ارجاعات بین مقالات جهت ایجاد ارتباط بین گزینه‌ها استفاده شده است نمودارهای ستون سمت چپ شکل ۶ میزان تاثیر این ارتباطات را نمایش می‌دهند. نتایج حاصل اجرای آزمایش بر روی مجموعه داده citeulike-A در دو حالت تنک و متراکم را نشان می‌دهد.

با مقایسه نتایج به دست آمده در حالت متراکم و تنک مشخص می‌شود که در حالت داده‌های متراکم استفاده از ارتباطات بین مقالات تنها اندکی سبب بهبود نتایج شده است اما همانطور که مشخص است در حالت داده‌های تنک استفاده از ارتباطات بین گزینه‌ها تاثیر محسوس‌تری را بر روی نتایج نشان می‌دهد. همانطور که گفته شده، با توجه به این که در حالت تنک تنها ۱ گزینه به ازای هر کاربر تست، وجود دارد در نتیجه استفاده از ماتریس امتیازات کمک چندانی در پیدا کردن گزینه‌های مشابه نمی‌کند اما استفاده از ارتباطات همان یک گزینه به سیستم کمک می‌کند تا بتواند گزینه‌های مشابه را با استفاده از ارتباطات بین گزینه‌ها پیدا کند و در نتیجه سبب بهبود عملکرد سیستم می‌شود. اما در حالت متراکم با توجه به وجود امتیازات بیشتر برای هر کاربر سیستم می‌تواند گزینه‌های مشابه را با استفاده از همان ماتریس امتیازات به دست آورد و در نتیجه ارتباطات کمک چندانی در بهبود عملکرد سیستم در این حالت نمی‌کنند. یکی از دلایل دیگری که می‌تواند سبب کم بودن اثر ارتباطات در نتایج شود کم بودن تعداد ارتباطات بین گزینه‌ها است با توجه به این که در مجموعه داده مورد استفاده به ازای هر گزینه به طور میانگین تنها ۳ ارتباط با گزینه‌های دیگر وجود دارد در نتیجه ماتریس ارتباطات بسیار تنک خواهد بود که سبب کم شدن اثر ارتباطات در نتایج می‌گردد.

همانطور که گفته شد مدل ارائه شده یک رویکرد ترکیبی است که از محتوای گزینه‌ها در کنار ماتریس امتیازات جهت ارائه پیشنهاد استفاده می‌کند. در این پژوهش جهت به دست آوردن فضای نهان گزینه‌ها از روی محتوای آن‌ها ابتدا متن توصیف آن‌ها با روش تبدیل پاراگراف به بردار به یک بردار با ابعاد کوچکتر نگاشت می‌گردد سپس با استفاده از شبکه SDAE ویژگی‌های مهم این گزینه‌ها استخراج می‌گردد و میزان تاثیر محتوا در پیش‌بینی امتیازات نیز توسط پارامتر λ کنترل می‌گردد. میزان تاثیر این پارامتر در نمودارهای ستون سمت راست شکل ۶ مشخص شده است. جهت انجام آزمایش همانند بخش‌های قبلی از مجموعه داده‌ی citeulike-A در دو حالت تنک و متراکم استفاده شده است.

همانطور که در نمودارهای این بخش مشخص است استفاده از محتوای گزینه‌ها تاثیر قابل توجهی بر روی نتایج دارد چرا که کاربران عموماً به دنبال گزینه‌های مشابه با گزینه‌هایی که دوست دارند هستند و با استفاده از محتوای گزینه‌ها می‌توان گزینه‌های مشابه با یکدیگر را شناسایی کرد. از طرف دیگر تاثیر دو طرفه ویژگی‌های به دست آمده برای گزینه‌ها از ماتریس امتیازات و ویژگی‌های به دست آمده از محتوای گزینه‌ها بر یکدیگر سبب می‌شود ویژگی‌های مهم گزینه‌ها از متن محتوای آن‌ها استخراج شوند و انتخاب ویژگی‌های مناسب سبب بهبود عملکرد سیستم در حالت کلی می‌گردد.

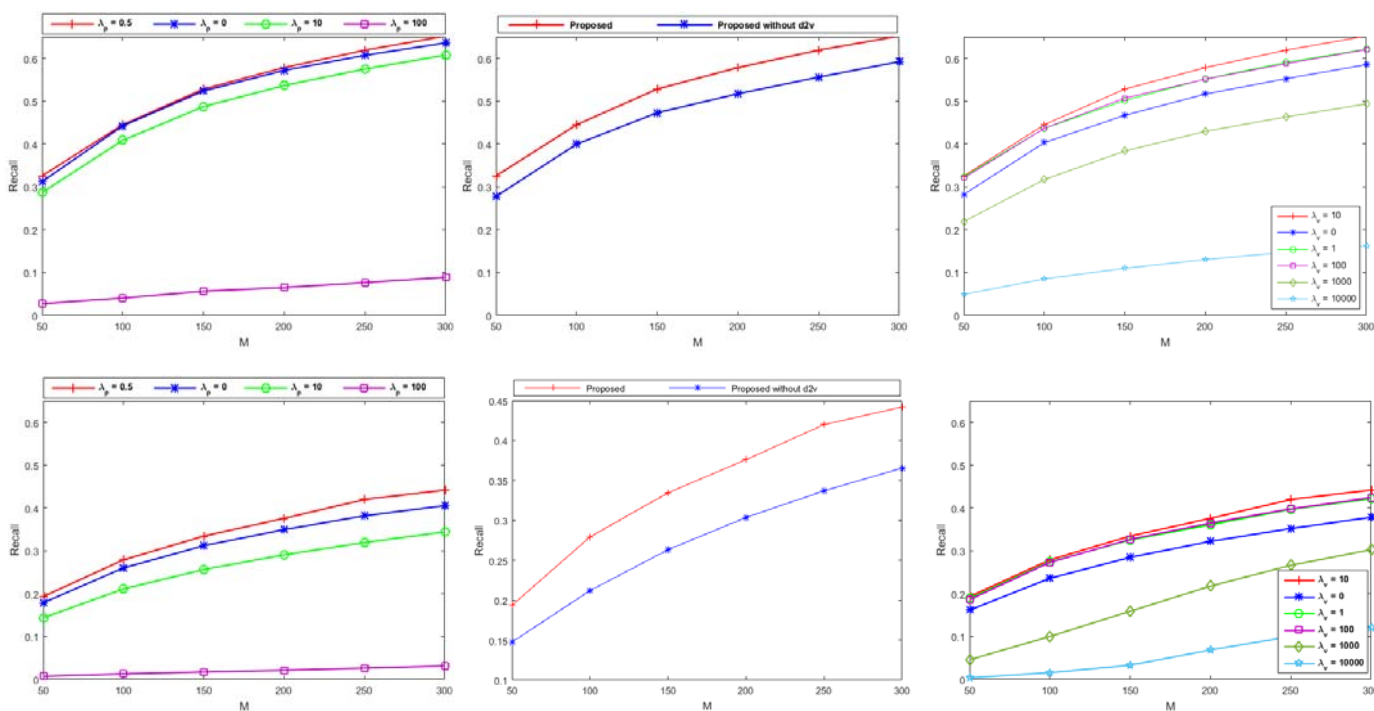
اما روش تجزیه ماتریسی غیرمغرم سادگی خود در حالت‌هایی که جدول امتیازات تنک نباشد بسیار خوب عمل می‌کند و همانطور که در نمودارهای مربوط به مجموعه داده movielens مشخص است این روش توانسته است به نتایجی نزدیک به روش CDL و روش پیشنهادی که مدل‌هایی پیچیده هستند دست یابد. اما عملکرد آن در مجموعه داده‌های تنک همانند citeulike-T به شدت افت می‌کند. یکی دیگر از دلایل نزدیک شدن نتایج مدل تجزیه ماتریسی به روش CDL و روش پیشنهادی می‌تواند به دلیل کم ارزش بودن اطلاعات متنی اضافی درباره فیلم‌ها نسبت به متن مقالات باشد در نتیجه این اطلاعات نمی‌توانند به خوبی فیلم مورد نظر را توصیف کنند که سبب کاهش کارایی مدل می‌شود. هر دو روش CDL و روش پیشنهادی از اطلاعات اضافی موجود درباره گزینه‌ها استفاده می‌کنند و از شبکه عمیق جهت استخراج ویژگی‌های نهان گزینه‌ها بهره می‌برند، اما نتایج ارائه شده نشان‌دهنده این مطلب است که روش پیشنهادی توانایی بهتری در به دست آوردن ویژگی‌های نهان گزینه‌ها دارد. یکی از مهمترین دلایل برتری روش ارائه شده نسبت به روش CDL استفاده از روش تبدیل پاراگراف به بردار جهت نمایش گزینه‌ها است. چرا که با این روش، ورودی با ابعاد بسیار کوچکتر و با حفظ ویژگی‌های اصلی گزینه‌ها را خواهیم داشت که هم سبب افزایش سرعت رسیدن به حالت پایدار می‌گردد و هم دقت مدل را در حالت کلی به دلیل کم کردن پارامترهای آزاد و جلوگیری از بیش‌برازش افزایش می‌دهد. یکی دیگر از دلایل برتری روش ارائه شده بر مدل CDL استفاده از اطلاعات ارتباطات بین گزینه‌ها است که سبب پیدا کردن گزینه‌های شبیه به هم در حالت شروع سرد برای گزینه‌ها می‌گردد.

۵-۵- بررسی میزان تاثیر بخش‌های مختلف مدل پیشنهادی

مدل ارائه شده از ۴ بخش کلی، شبکه تبدیل پاراگراف به بردار، شبکه SDAE، تجزیه ماتریس ارتباطات و تجزیه ماتریس امتیازات، تشکیل شده است و تمام این بخش‌ها در کنار یکدیگر به طور همزمان آموزش می‌بینند و میزان تاثیر آن‌ها بر مدل نهایی به کمک پارامترهایی که از بیرون تنظیم می‌گردد مشخص می‌شوند. در این بخش میزان تاثیر هر کدام از بخش‌ها بر روی نتایج کلی مدل مورد بررسی قرار گرفته است. میزان تاثیر تمام بخش در شکل ۶ آورده شده است (نتایج گزارش شده از اجرای آزمایش بر روی مجموعه داده citeulike-A به دست آمده‌اند).

همانطور که از نتایج گزارش شده در نمودارهای ستون وسط شکل ۶ مشخص است استفاده از روش تبدیل پاراگراف به بردار تاثیر قابل توجهی بر روی نتایج به دست آمده دارد و این تاثیر در حالت تنک نمایان‌تر است. بخش تبدیل پاراگراف به بردار از دو جهت تاثیر به‌سزایی بر عملکرد کلی سامانه می‌گذارد. اول این که با استفاده از این بخش تعداد ابعاد ورودی بسیار کاهش می‌یابد و ورودی از یک حالت تنک با بعد بالا به یک ورودی با ابعاد بسیار کمتر و به مقادیر حقیقی بین ۱- تا ۱ تبدیل می‌شود. در مثال مجموعه داده‌های citeulike-A که نتایج در آن بررسی شده است ورودی در حالت TF-IDF یک بردار ۵,۰۰۰ بعدی است که به طور میانگین تنها ۶۷ عنصر آن غیرصفر هستند ولی در صورت استفاده از روش تبدیل پاراگراف به بردار به ورودی ۳۰۰ بعدی که تمام عناصر آن بین ۱- تا ۱ هستند می‌رسیم. کم شدن تعداد ابعاد ورودی سبب می‌شود پارامترهای آزاد شبکه کمتر شوند و در نتیجه از بیش‌برازش جلوگیری شده و همچنین شبکه در مدت زمان کمتری به حالت پایدار با دقت بالاتری برسد.

در مدل پیشنهادی از ارتباطات بین گزینه‌ها نیز جهت ارائه پیشنهاد استفاده شده است. استفاده از ارتباطات بین گزینه‌ها سبب می‌شود گزینه‌های مشابه به یکدیگر را علاوه بر محتوا و شباهت بین آرای دریافتی از کاربران، از روی ارتباطات آن‌ها نیز بتوان پیدا کرد و همچنین با استفاده از این روش می‌توان گزینه‌های



شکل ۶- میزان تاثیر بخش‌های مختلف مدل. در این نمودارها محور افقی نشان‌دهنده تعداد گزینه‌هایی است که برای کاربر بازگردانده می‌شود. سطر اول مربوط به مجموعه داده‌های مترکم است که در آن‌ها $Q=10$ است و سطر دوم مربوط به مجموعه داده‌های تنک است که در آن‌ها $Q=1$ قرار داده شده است. ستون سمت چپ مربوط به میزان تاثیر بخش ارتباطات بین گزینه‌ها، ستون میانی میزان تاثیر بخش تبدیل پاراگراف به بردار و ستون سمت راست میزان تاثیر اطلاعات محتوای گزینه‌ها را نمایش می‌دهند. در تمام نمودارها از مجموعه داده‌های citeulike-A استفاده شده است

مراجع

- [1] D. Almazro, G. Shahatah, L. Albdulkarim, M. Kherees, R. Martinez, and W. Nzoukou, "A Survey Paper on Recommender Systems," *CoRR*, 2010.
- [2] J. Tang, X. Hu, and H. Liu, "Social recommendation: a review," *Social Network Analysis and Mining*, pp. 1113-1133, 2013.
- [3] Y. Koren, R. Bell, and C. Volinsky, "Matrix Factorization Techniques for Recommender Systems," *Computer*, pp. 30-37, August 2009.
- [4] J. Schmidhuber, "Deep Learning in Neural Networks: An Overview," *Neural Networks*, pp. 85-117, 2015.
- [5] N. Wang, and D.-Y. Yeung, "Learning a Deep Compact Image Representation for Visual Tracking," *Advances in Advances in Neural Information Processing Systems 26*, pp. 809-817, 2013.
- [6] K. Nal, G. Edward, and B. Phil, "A Convolutional Neural Network for Modelling Sentences," *CoRR*, 2014.
- [7] H. Wang, N. Wang, and D.-Y. Yeung, "Collaborative Deep Learning for Recommender Systems," *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1235-1244, 2015.

۶- نتیجه‌گیری و کارهای آتی

در این مقاله یک روش ترکیبی ارائه شد که از منابع اطلاعاتی مختلف جهت ارائه پیشنهاد به کاربر بهره می‌گیرد. مدل پیشنهادی با استفاده از اطلاعات اضافه موجود درباره گزینه‌ها و ارتباطات بین آن‌ها مشکل شروع سرد را برطرف کرده است و با ایجاد یک ارتباط محکم بین اجزای مدل توانسته نتایج بهتری نسبت به برترین روش موجود در سامانه‌های توصیه‌گر بر روی ۳ مجموعه داده دنیای واقعی کسب کند.

از جمله مواردی که به کمک آن‌ها می‌توان روش پیشنهادی را توسعه داد، استفاده از اطلاعات اضافه‌ای همچون ارتباطات بین کاربران با یکدیگر و اطلاعات موجود در نمایه کاربران است. در ادامه می‌توان از اطلاعات نمایه کاربران نیز استفاده کرد. در نتیجه می‌توان به کاربرانی که تازه وارد سیستم شده‌اند نیز گزینه‌هایی را با استفاده از ارتباطات آن‌ها و یا اطلاعات نمایه کاربران پیشنهاد کرد و به این ترتیب مشکل شروع سرد برای کاربران نیز تا حد زیادی برطرف شود.

در این مقاله محور اساسی آزمایشات بر روی مجموعه داده‌هایی بود که از بازخوردهای غیرمستقیم کاربر نسبت گزینه‌ها در سیستم به وجود آمده بودند و به همین دلیل برای هر گزینه تنها دو حالت مورد علاقه کاربر و یا عدم علاقه کاربر به آن گزینه وجود داشت اما در مجموعه داده‌هایی که کاربران به گزینه‌ها یک امتیاز (مثلاً بین ۱ تا ۱۰) انتساب می‌دهند سیستم باید بتواند میزان علاقه کاربر به هر گزینه را با یک مقدار عددی مشخص کند. روش پیشنهادی با تغییر اندکی قابلیت به دست آوردن امتیاز را نیز دارد که این موضوع نیز می‌تواند مورد بررسی قرار بگیرد.

آدرس پست‌الکترونیکی ایشان عبارت است از:

kiboabbasi@ce.sharif.edu

مهديه سلیمانی باغشاه دوره کارشناسی، کارشناسی‌ارشد و دکتری خود را به ترتیب در سال‌های ۸۲، ۸۴ و ۸۹ در دانشکده مهندسی کامپیوتر دانشگاه صنعتی شریف به اتمام رسانده است. همچنین وی از سال ۹۱ تاکنون به عنوان استادیار دانشکده مهندسی کامپیوتر این دانشگاه به آموزش و پژوهش پرداخته است. زمینه‌های تحقیقاتی مورد علاقه ایشان یادگیری ماشین، مدل‌سازی احتمالاتی، بازیابی اطلاعات و سیستم‌های



هوشمند است.

آدرس پست‌الکترونیکی ایشان عبارت است از:

soleymani@sharif.edu

اطلاعات بررسی مقاله:

تاریخ ارسال: ۱۳۹۶/۰۴/۱۸

تاریخ اصلاح: ۱۳۹۶/۰۶/۰۶

تاریخ قبول شدن: ۱۳۹۷/۰۱/۲۲

نویسنده مرتبط: دکتر مهديه سلیمانی، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شریف، تهران، ایران.

¹<https://www.amazon.com>

²<https://news.google.com>

³<https://www.netflix.com>

⁴Supervised

⁵Cold Start

⁶Tightly Coupled

⁷Loosely Coupled

⁸Collaborative Topic Regression

⁹Latent Dirichlet Allocation

¹⁰Collaborative Deep Learning

¹¹Auto-Encoder

¹²Stacked Denoising Auto-Encoder

¹³Sequence

¹⁴Binary

¹⁵<http://www.citeulike.org/faq/data.adp>

¹⁶<http://ir.ii.uam.es/hetrec2011>

¹⁷Recall

¹⁸Precision

[8] Q. V. Le, and T. Mikolov, "Distributed Representations of Sentences and Documents," *International Conference on Machine Learning*, pp. 1188-1196, 2014.

[9] T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient Estimation of Word Representations in Vector Space," *CoRR*, 2013.

[10] P. Lops, M. De Gemmis, and G. Semeraro, "Content-based recommender systems: State of the art and trends," in *Recommender systems handbook*, Springer, 2011, pp. 73-105.

[11] D. M. Blei, "Probabilistic topic models," *Communications of the ACM*, pp. 77-84, 2012.

[12] C. Wang, and D. M. Blei, "Collaborative topic modeling for recommending scientific articles," *Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 448-456, 2011.

[13] D. M. Blei, A. Y. Ng, and M. I. Jordan, "Latent dirichlet allocation," *Journal of Machine Learning Research*, pp. 993-1022, 2003.

[14] R. Salakhutdinov, and A. Mnih, "Probabilistic matrix factorization," *Neural Information Processing Systems*, pp. 1-8, 2011.

[15] S. Li, J. Kawale, and Y. Fu, "Deep collaborative filtering via marginalized denoising auto-encoder," *Proceedings of the 24th ACM International on Conference on Information and Knowledge Management*, pp. 811-820, 2015.

[16] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion," *Journal of Machine Learning Research*, pp. 3371-3408, 2010.

[17] Z. S. Harris, "Distributional structure," *Word*, pp. 146-162, 1954.

[18] T. Mikolov, I. Sutskever, K. Chen, G. S. Corrado, and J. Dean, "Distributed representations of words and phrases and their compositionality," *Advances in Neural Information Processing Systems*, pp. 3111-3119, 2013.

[19] M. A. Abbasi, J. Tang, and H. Liu, "Trust-aware recommender systems," *Machine Learning book on computational trust*, Chapman & Hall/CRC Press, 2014.

امید عباسی دوره کارشناسی خود را در رشته مهندسی کامپیوتر گرایش نرم‌افزار و در سال ۹۳ از دانشگاه شیراز و کارشناسی‌ارشد خود را در رشته مهندسی کامپیوتر گرایش هوش مصنوعی و در سال ۹۵ از دانشگاه صنعتی شریف اخذ نموده است. زمینه‌های مورد علاقه ایشان یادگیری عمیق، سامانه‌های توصیه‌گر و بازیابی اطلاعات است.



سامانه‌های توصیه‌گر و بازیابی اطلاعات است.