



## ارایه یک مدل پیش‌بینی غیرخطی با حداکثر حاشیه با کمک اسناد توصیفی برای بهبود عملکرد سیستم‌های توصیه‌گر

مهدی رواخواه<sup>(۱)</sup> مهرداد جلالی\*<sup>(۲)</sup> یحیی فرقانی<sup>(۳)</sup> رضا شیبانی<sup>(۴)</sup>

(۱) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۲) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران\*

(۳) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۴) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

تاریخ دریافت: ۱۴۰۱/۰۳/۲۶ تاریخ پذیرش: ۱۴۰۱/۰۴/۲۸

### چکیده

بسیاری از مدل‌های پیش‌بینی در سیستم‌های توصیه‌گر، سعی در مدل کردن فاکتورهای پنهان کاربران و آیتم‌ها دارند. این مدل‌ها به کمک ماتریس امتیازات داده شده توسط کاربران به آیتم‌ها آموزش می‌بینند و کم بودن نسبت امتیازات داده شده کاربران به آیتم‌ها نسبت به کل امتیازات ممکن، باعث کاهش دقت این مدل‌ها شده است. لذا برای حل این مشکل، در برخی پژوهش‌ها سعی گردیده است که علاوه بر امتیازات موجود، از اطلاعات کمکی نظیر اسناد توصیفی که در مورد آیتم‌ها وجود دارند استفاده گردد. اما بسیاری از آنها از مدل‌های قدیمی‌تر پرکاربرد در متن کاوی استفاده نموده اند و همچنین عدم لحاظ نمودن حداکثر حاشیه در هنگام محاسبه ویژگی‌های کاربران و آیتم‌ها باعث گردیده است که ویژگی‌های کاربران و آیتم‌ها به شکل موثری استخراج نگردد. در این مقاله و در روش ارایه شده، مدلی غیرخطی ارایه کرده‌ایم که انعطاف بیشتری در مقایسه با مدل‌های خطی رایج دارد و همچنین علاوه بر استفاده مفید از اسناد توصیفی در مورد آیتم‌ها، با لحاظ کردن حداکثر حاشیه در هنگام استخراج ویژگی‌های کاربران باعث بهبود صحت پیش‌بینی در مقایسه با پژوهش‌های قبل گردیده است. با توجه به توانایی شبکه‌های عصبی در کار با دنباله‌ها، برای استخراج ویژگی از اسناد متنی از شبکه عصبی عمیق با حافظه کوتاه مدت در مدل پیشنهادی استفاده می‌نماییم.

واژه‌های کلیدی: فاکتورسازی ماتریس با بیشترین حاشیه، مدل غیرخطی، اسناد توصیفی، یادگیری عمیق.

\*عهده‌دار مکاتبات:

مهرداد جلالی

نشانی: گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

پست الکترونیکی: [mehradad.jalali@kit.edu](mailto:mehradad.jalali@kit.edu)

تلفن:

حجم داده‌های تولید شده توسط ابزارهای الکترونیکی و خودکار، با سرعت قابل توجهی در حال افزایش هستند. اما بهره بردن از این داده‌های حجیم در صورتی امکان‌پذیر است که ابتدا روی آن‌ها پردازش و تحلیل صورت پذیرد و سپس از نتایج و خروجی‌های این پردازش‌ها استفاده گردد. در این راه، سیستم توصیه‌گر به کاربران این امکان را می‌دهد که در بین انبوه آیت‌های موجود، با توجه به پیشنهادهاى ارایه شده توسط این سیستم، به سادگی بهترین انتخاب‌ها را انجام داده و تجربه نمایند. همچنین استفاده از این نوع سیستم‌ها باعث افزایش فروش محصولات و خدمات برای ارایه دهندگان آن‌ها می‌شود که سود هنگفتی را نصیب آنان می‌نماید. به طوری که در حال حاضر حجم قابل توجهی از فروش‌های اینترنتی سایت‌های فروش را محصولات پیشنهاد شده توسط سیستم‌های توصیه‌گر به خود اختصاص می‌دهند. امروزه اکثر فروشگاه‌های اینترنتی، وب سایت‌های ارایه خدمات اینترنتی، شبکه‌های اجتماعی و ... به عنوان جزئی از خود شامل سیستم توصیه‌گر می‌باشند که سعی در پیش‌بینی ترجیحات و سلیق کاربر و بهبود ارایه خدمات دارند. علیرغم اینکه داده‌های زیادی در سیستم‌های فعلی ذخیره می‌گردند اما با توجه به تعداد زیاد کاربران و همچنین تعداد زیاد آیت‌ها عملاً امتیازاتی که کاربران به آیت‌ها می‌دهند درصد بسیار کوچکی از امتیازات ممکن است. می‌توان از اسناد توصیفی مانند نظرات کاربران در مورد آیت‌ها یا خلاصه‌هایی در مورد آیت‌ها برای مقابله با مشکل کمبود اطلاعات در مورد سلیقه کاربران در خصوص آیت‌های مختلف که به آن مشکل خلوت بودن نیز گفته می‌شود، در جهت بهبود کیفیت پیش‌بینی امتیازات کاربران به آیت‌ها بهره برد. این اسناد متنی در بسیاری از سیستم‌ها ذخیره می‌شوند و به راحتی در دسترس قرار دارند، همچنین با اصول مربوط به حفظ محرمانگی کاربران نیز در تضاد قرار ندارند. اگرچه اطلاعات نوشتاری کاربران به صورت غیرساختارمند هستند اما پیشرفت‌هایی که در حوزه مدلسازی معنایی و کاوش متن و یادگیری ماشین رخ داده است امکان تفسیر اسناد متنی و استخراج اطلاعات مفید از آن را فراهم نموده است. از روی اسناد متنی مربوط به آیت‌ها می‌توان اطلاعات مختلفی استخراج نمود که در طراحی سیستم‌های توصیه‌گر بسیار مفید و پرکاربرد می‌باشند. مشخص‌ترین راه برای تحلیل متون مانند [1,2] شناسایی عبارات پرتکرار و استفاده از روش‌های اندازه‌گیری وزنی مانند TF-IDF برای تعیین اهمیت هر عبارت است. برخی از کاربران در نظراتشان موضوعات و جنبه‌هایی را مطرح می‌کنند. به عنوان مثال، در متنی که در مورد یک هتل در TripAdvisor نوشته شده است، موضوعاتی مانند کیفیت اتاق، غذا، وسایل ورزشی، مکان و ... بیان می‌شوند. برای بازنمایی سند با یک توزیع موضوعی K-بعدی و توزیع کلمات هر موضوع در این گونه رهیافت‌ها عموماً از تکنیک‌هایی مانند تخصیص پنهان دیریکله (LDA) [3] استفاده می‌شود و مانند [4,5] موضوعات کشف شده می‌توانند برای بهبود امتیازدهی در رهیافت‌های پالایش مشارکتی مورد استفاده قرار گیرند. همچنین یک راه ساده برای تخمین نظر کلی کاربر، تجمیع احساسات همه کلمات احساسی اوست که در نظرش آمده است [6,7]. به عنوان جایگزین، یک الگوریتم یادگیری ماشین (مانند دسته بند بیزین Naive یا SVM) می‌تواند برای یادگیری عقیده و دسته بندی آن به درون یک رده احساسی مناسب مورد استفاده قرار گیرد [8,9]. مقایسه‌های انجام شده در نظرات کاربران را نیز می‌توان با استفاده از یک سری قوانین زبانی خاص استخراج کرد [10]. حالات روحی کاربر مانند ناراحتی، لذت بردن، پریشانی، شاد بودن و ... را می‌توان با ساخت یک دسته‌بند برای برچسب‌گذاری متون با حالات روحی مختلف استخراج نمود [11]. از تعداد آراء داده شده سایر کاربران به یک نظر می‌توان برای تعیین کیفیت امتیازدهی آن کاربر به آیت‌ها مورد نظر استفاده نمود [12]. اما مهمترین و مفیدترین نوع استفاده از نظرات و اسناد متنی مرتبط با کاربران و آیت‌ها در سیستم‌های توصیه‌گر مدل کردن فاکتورهای پنهان موجود در آن‌ها می‌باشد. با استفاده از این فاکتورها می‌توان ارتباط بین ذائقه کاربران و ویژگی‌های آیت‌ها را بدست آورده و از آن در ارائه پیشنهادها استفاده نمود. با پیشرفت غیرمنتظره کاربرد تکنولوژی یادگیری

عمیق در زمینه پردازش زبان طبیعی و تصویر و ویدیو، بکاربردن این تکنولوژی برای ساختن یا بهبود سیستم‌های توصیه‌گر تبدیل به یک موضوع داغ شده است. با این وجود مسائل باز بسیاری در این مسیر وجود دارد، مانند اینکه شبکه عصبی را چگونه بسازیم تا برای اطلاعات متنی کاربرد داشته باشد یا اینکه چگونه ماژول شبکه عصبی را با فاکتورسازی ماتریس که جزء مهمترین روش‌های کشف فاکتورهای پنهان کاربران و آیتم‌ها است ترکیب کنیم تا مدلی مناسب برای پیش‌بینی نظر یک کاربر در مورد یک آیتم طراحی کنیم. در این مقاله یک مدل غیرخطی ارائه نموده‌ایم که از اسناد متنی که در مورد آیتم‌ها است برای استخراج بهتر ویژگی‌های آیتم‌ها استفاده می‌نماید. همچنین با در نظر گرفتن حداکثر حاشیه در استخراج ویژگی‌های کاربران و آیتم‌ها کارایی مدل در پیش‌بینی امتیاز برای آیتم‌هایی که توسط کاربران امتیازدهی نشده‌اند را حاصل می‌کند و باعث بهبود صحت می‌گردد. در ادامه و در بخش ۲، پژوهش‌های مرتبط با سیستم‌های توصیه‌گری که از اسناد متنی استفاده می‌نمایند بررسی گردیده‌اند. بخش ۳، مقدماتی را بیان می‌کند که برای ارائه روش پیشنهادی مورد نیاز است. در بخش ۴ روش پیشنهادی جدید را ارائه نموده‌ایم. بخش ۵ شامل نتایج عملی و بخش ۶ نتیجه‌گیری و کارهای آینده می‌باشد.

## ۲. پژوهش‌های مرتبط

در این بخش به بررسی سیستم‌های توصیه‌گر مبتنی بر اسناد متنی مرتبط با آیتم‌ها می‌پردازیم. در این روش‌ها، نویسندگان راهکارهایی برای کشف موضوعات آیتم‌ها یا به دست آوردن فاکتورهای پنهان مرتبط با آیتم‌ها و کاربران ارائه نموده‌اند و از آن برای پیش‌بینی امتیاز اعطایی کاربر به آیتم استفاده نموده‌اند. مقاله [13]، یک مدل بیزین سلسله مراتبی است که از SDAE<sup>۱</sup> و PMF<sup>۲</sup> استفاده می‌کند و نوع بهبود یافته [18] CTR محسوب می‌شود. ساختار عصبی عمیق باعث یادگیری ویژگی‌های پنهان قابل تفسیر از روی متون می‌شود. اشکال این روش نیز محدودیت‌های ذاتی روش‌های کیسه کلمات است. روش ارائه شده در [14] به‌عنوان ورودی علاوه بر امتیازات، تمامی نوشته‌های یک کاربر و تمامی نوشته‌های در مورد یک آیتم را دریافت می‌کند. یادگیری ویژگی‌های پنهان کاربران و آیتم‌ها از روی متون به‌وسیله شبکه عصبی کانولوشن و مکانیزم توجه انجام می‌پذیرد. از سوی دیگر یادگیری مبتنی بر برهم‌کنش‌های بین کاربران و آیتم‌ها از طریق ماشین تجزیه صورت می‌گیرد. در نهایت با ترکیب کردن پویای امتیاز پیش‌بینی شده از روی ویژگی‌های بدست آمده متون و امتیاز پیش‌بینی شده از روی ویژگی‌های بدست آمده از ماشین تجزیه، امتیاز نهایی تخمین زده می‌شود. اشکال این روش نیز این است که زمانی مفید است که برای کاربر و آیتم مورد نظر سند متنی وجود داشته باشد. مقاله [15] روشی ارائه کرده است که از LDA و NMF استفاده کرده است اما اشکال مشخص استفاده از نمایش *bow* (کیسه کلمات) برای پردازش متون است که اطلاعات زمینه ای معنایی که در کلمات محلی کد شده‌اند را لحاظ نکرده است. از این رو اطلاعات بهم چسبیده زیادی که به شکل عبارات و جملات هستند در این شیوه پردازش متنی درشت دانه گم می‌شوند. مقاله [16] علاوه بر اینکه اشکالات مقاله قبل را دارد این اشکال را هم دارد که موضوعات پنهان فقط می‌توانند به فاکتورهای پنهان کاربر (یا آیتم) مرتبط باشند در حالیکه در مقاله قبل به‌صورت همزمان به هردو وابسته شده‌اند. مقاله [17] همان اشکالات مقاله [15] را دارد. در این مقاله روشی سه مرحله‌ای ارائه شده است. مرحله اول یادگیری میزان توصیه‌پذیری آیتم‌ها است که در آن به‌صورت تقویتی ویژگی‌هایی که در امتیازات بالاتر کشف شده‌اند قابلیت توصیه بالاتری دارند. در این مرحله نیز از LDA استفاده شده است. در مرحله دوم با کمک موضوعات استخراج

<sup>۱</sup> Stacked Denoising Autoencoder

<sup>۲</sup> Probabilistic Matrix Factorization

شده آیت‌ها در مرحله قبل و همچنین امتیازی که کاربر به آن آیت‌ها داده است میزان علاقمندی کاربر به ویژگی‌های مختلف بدست می‌آید. در مرحله آخر نیز با ارایه رابطه‌ای که مبتنی بر مدل فاکتورهای پنهان است و با استفاده از ویژگی‌های کشف شده کاربران و آیت‌ها در دو مرحله قبل امتیاز نهایی پیش‌بینی می‌شود. برای بدست آوردن فاکتورهای پنهان کاربر و آیت‌ها و بایاس‌ها در این مرحله از نزول گرادیان تصادفی جهت بهینه‌سازی تابع هدف مربوطه استفاده شده است. [18] پالایش مشارکتی سنتی را با مدلسازی موضوعی احتمالاتی ترکیب می‌کند و ساختار پنهان کاربران و آیت‌ها را بدست می‌آورد. اشکال این روش هم مانند برخی دیگر از روش‌ها، استفاده از LDA می‌باشد که از کیسه کلمات استفاده کرده و اطلاعات زمینه‌ای معنایی که در کلمات محلی کد شده‌اند را لحاظ نمی‌کند. در [19] از شبکه عصبی CNN برای استخراج ویژگی‌های پنهان کاربر یا آیت‌ها استفاده کرده که با استفاده از بازنمایی چگال تعبیه کلمات و یک پنجره محلی برای بدست آوردن اطلاعات مفهومی، تکنیک‌های مبتنی بر CNN درک معنایی بهتری از نظرات دارند که منجر به بهبود قابل توجهی در پیش‌بینی امتیازات نسبت به مدل‌های bow می‌شود. با این وجود درک ویژگی‌های استخراج شده توسط شبکه‌های عصبی برای انسان مشکل است و بنابراین قابلیت تفسیر سیستم‌های توصیه‌گر را محدود می‌کند. این مقاله DeepCoNN ارایه شده در [21] را با افزودن یک لایه اضافی (شبکه هدف) برای یادگیری بازنمایی نظر یک کاربر هدف - یک آیت‌ها هدف در زمان آموزش توسعه داده است و سپس از بازنمایی یادگرفته شده برای تنظیم خروجی شبکه منبع استفاده می‌کند. بنابراین شبکه منبع می‌تواند بازنمایی پنهان یک متن هدف را تقلید کند که در زمان تست در دسترس نیست. این روش‌ها بهتر از مدل‌های bow عمل می‌کنند و در حذف مشکلات شروع سرد و تنک بودن داده موثرند اما تنها ویژگی‌های کاربران و آیت‌ها را به صورت استاتیک و جداگانه بدست می‌آورند که از اثرات متقابل گوناگون و پیچیده بین کاربران و آیت‌ها غافل می‌شود. مقاله [20] روشی به نام CONVMF پیشنهاد کرده است که یک مدل شبکه عصبی مبتنی بر CNN ارایه کرده، که از CNN برای فراهم کردن بهتر بازنمایی معنایی پنهان متون به وسیله لحاظ کردن ترتیب کلمات و اطلاعات زمینه‌ای استفاده می‌کند. خروجی شبکه عصبی CNN ضمن ترکیب شدن با تجزیه ماتریس احتمالاتی برای بدست آوردن بردارهای پنهان آیت‌ها مورد استفاده قرار می‌گیرد. مقاله [21]، روشی به نام DeepCoNN ارایه کرده است که از یک مدل CNN موازی برای بدست آوردن جداگانه ویژگی‌های پنهان کاربران و آیت‌ها بر اساس متون‌شان استفاده می‌کند. سپس ویژگی‌های پنهان کاربر و آیت‌ها متناظر را بهم الحاق کرده و به یک ماشین تجزیه (FM) برای پیش‌بینی امتیاز ارسال می‌کند. مقاله [22] برای حل مشکل سه مقاله بالا ابتدا یک مکانیزم توجه را دخیل می‌کند تا یک مدل قابل تفسیرتر برای پیش‌بینی امتیازات تولید کند. این مقاله توجه محلی و سراسری روی متون را ترکیب می‌کند و متون وزندار تولید می‌کند که به یک مدل CNN داده می‌شوند تا بازنمایی بهتری از کاربران و آیت‌ها بدست آید. مقاله [23] از روشی شبیه به روش‌های LDA استفاده کرده اما به جای فاکتورسازی ماتریس از مدل‌های مخلوط گوسی برای مدل کردن امتیازات استفاده کرده است. مقاله [24] از یک مدل مبتنی بر تعبیه برای یکپارچه کردن مدل تعبیه کلمات با یک مدل استاندارد فاکتورسازی ماتریس استفاده می‌کند تا اطلاعات زمینه‌ای کلمات در متون را فراهم کند. در این مقاله از مدل CBOW و skip-gram استفاده شده است. تفاوت این دو مدل این است که CBOW از کلمات زمینه‌ای محلی (کلمات قبل و بعد از یک کلمه) برای پیش‌بینی کلمه جاری استفاده می‌کنند در حالیکه در مدل skip-gram کلمات اطراف یک کلمه بر اساس آن کلمه پیش‌بینی می‌شوند. مقاله [25] روشی با نام R-ConvMF ارایه کرده است که نوع بهبود یافته روش ConvMF است که متعلق به همان نویسندگان است. تفاوت اصلی که روش جدید دارد این است که برای مدل کردن فاکتورهای پنهان آیت‌ها بر اساس تعداد امتیازاتی که به هر آیت‌ها داده شده است، نویز گوسی (خطا) در نظر می‌گیرد. بدین شکل آیت‌هایی که تعداد امتیازات بیشتری به آن‌ها داده شده است در هنگام بدست آوردن فاکتورهای پنهان‌شان دارای نویز گوسی (خطا) کمتری می‌باشند. مقاله [26] یک مدل یادگیری عمیق مبتنی بر توجه برای محاسبه میزان مفید بودن متون برای توصیه پیشنهاد می‌کند. این روش می‌تواند یک توضیح سطح متنی برای

پیش‌بینی امتیازات فراهم کند. مقاله [27] از یک شبکه GRU مبتنی بر توجه برای تفسیر مفاهیم معنایی مرتبط با هر ویژگی پنهان بدست آمده به‌وسیله مدل فاکتورسازی ماتریس استفاده می‌کند. در [28] از دو شبکه عصبی جداگانه برای کاربران و آیتم‌ها استفاده شده است و مدل سلسله مراتبی ارائه شده است که از GRU دو طرفه و مکانیزم توجه سطح کلمه و سطح جمله برای استخراج اطلاعات کاربران و آیتم‌ها استفاده می‌کند. از SkipGram برای بازنمایی کلمات استفاده شده است. بعد از بازنمایی کلمات، از GRU دو طرفه به همراه مکانیزم توجه در سطح کلمات برای بازنمایی جملات استفاده شده است و پس از آن نیز از یک GRU دو طرفه به همراه مکانیزم توجه در سطح جملات استفاده شده است که بازنمایی سند را حاصل می‌کند. خروجی بازنمایی سند مرتبط با کاربر و آیتم به لایه FC وارد می‌شوند که خروجی این لایه بردار معنایی مبتنی بر توجه کاربر و بردار معنایی مبتنی بر توجه آیتم را حاصل می‌کند. سپس از ضرب داخلی این بردارها برای تخمین امتیاز داده شده کاربر به آیتم استفاده می‌شود. از RMSE به‌عنوان تابع هزینه برای کمینه کردن تفاوت میزان امتیاز واقعی داده شده با امتیاز تخمین زده شده در زمان آموزش استفاده می‌شود. اشکال این روش این است که زمانی مفید است که برای کاربر و آیتم مورد نظر سند متنی وجود داشته باشد ضمن اینکه زمان مورد نیاز برای آموزش وزن‌های شبکه GRU دو طرفه زیاد است. مقاله [29] از ترکیب کردن RNN‌های سلسله مراتبی و PMF برای استفاده از محتواهای متنی و اطلاعات امتیازات جهت طراحی یک سیستم جدید استفاده می‌کند. RNN‌های سلسله مراتبی در دو سطح طراحی شده‌اند. در سطح اول با دریافت کلمات یک جمله، مفاهیم جمله را بدست می‌آورند و در سطح دوم با ترکیب کردن مفاهیم بدست آمده از سطح قبل، مفاهیم مرتبط با کل سند را بدست می‌آورند. در نهایت برای ترکیب کردن HRN و PMF جهت استفاده از این مفاهیم بدست آمده و امتیازات داده شده توسط کاربران، از تخمین حداکثر احتمال پسین استفاده شده است. مقاله [30] از سه نوع اطلاعات شامل اطلاعات متنی، اطلاعات جغرافیایی و اطلاعات اجتماعی کاربر برای ساخت مدلی جهت ارائه پیشنهادها نقاط جذاب برای کاربران استفاده می‌کند. برای استخراج ویژگی از اطلاعات متنی از شبکه عصبی کانولوشن استفاده شده است. از نزول گرادین برای بدست آوردن پارامترها و کمینه کردن تابع هدف بیان شده، استفاده می‌شود. در مقاله [31] از دو شبکه عصبی جداگانه برای کاربران و آیتم‌ها استفاده شده است. ساختار شبکه‌های عصبی شامل لایه بازنمایی کلمات، لایه‌های CNN، لایه‌های GRU رو به جلو و رو به عقب، و لایه خروجی می‌باشد. سپس با ترکیب این شبکه با تجزیه ماتریس احتمالاتی (PMF) و ارائه یک تابع هدف، مقادیر بردارهای کاربران و آیتم‌ها و پارامترهای شبکه با کمک دیتاست آموزشی محاسبه می‌شوند. در نهایت با کمک ویژگی‌های کاربران و آیتم‌ها می‌توان مقادیر امتیازات را پیش‌بینی کرد. اشکال این روش نیز این است که زمانی مفید است که برای کاربر و آیتم مورد نظر سند متنی وجود داشته باشد. تعداد زیاد پارامترهای شبکه نیز زمان آموزش را بالا خواهد برد. مقاله [32] از RNN‌های سلسله مراتبی و متقارن برای کشف مفاهیم معنایی و تغییرات در سلاقی کاربران یا ویژگی‌های آیتم‌ها استفاده می‌کند. روش ارائه شده در این مقاله به‌عنوان ورودی توالی‌های محتوایی مربوط به کاربران و آیتم‌ها را به‌صورت جداگانه دریافت می‌کند و با کمک شبکه‌های عصبی RNN که در دو سطح قرار گرفته‌اند و با بهره‌گیری از واحدهای LSTM اقدام به استخراج مفاهیم معنایی از روی محتواهای متنی می‌نماید و از آن‌ها برای پیش‌بینی امتیازات مشخص نشده استفاده می‌کند. در [37] نویسندگان از اطلاعات امتیازات قبلی داده شده، دموگرافی کاربران، اسناد متنی، زمان مشاهده ویدیوها و ... استفاده می‌کنند و با بکاربردن شبکه عصبی سعی در بدست آوردن ویژگی‌های کاربران و آیتم‌ها و در نتیجه بهبود پیش‌بینی نظر کاربران در مورد آیتم‌ها دارند. اما این روش نیز در زمان بدست آوردن ویژگی‌های کاربران و آیتم‌ها حداکثر حاشیه را در نظر نمی‌گیرند. به‌طور خلاصه می‌توان گفت کارهای انجام شده قبل، شامل ایرادات مختلفی هستند مانند: محدودیت‌های روش‌های مبتنی بر کیسه کلمات، عدم لحاظ کردن حداکثر حاشیه در هنگام بدست آوردن ویژگی‌های پنهان، داشتن یک مدل پیشگوی خطی، زمان‌بر بودن زمان آموزش، نیاز به وجود اسناد متنی هم در مورد کاربران و هم در مورد آیتم‌ها و ... و در پژوهش فعلی سعی گردیده است این اشکالات تا حد امکان

مرتفع گردد. لذا در ادامه مدلی غیرخطی ارائه می‌کنیم که انعطاف بیشتری در مقایسه با مدل‌های خطی رایج دارد و در آن بدست آوردن ویژگی‌های پنهان به صورت موثرتری انجام می‌پذیرد.

### ۳. مقدمات

از آنجاکه روش ارائه شده از فاکتورسازی ماتریس با بیشترین حاشیه (Maximum Margin Matrix Factorization) استفاده می‌نماید، لذا به صورت مختصر این تکنیک را نیز بررسی می‌نماییم. فرض کنید عناصر ماتریس امتیازدهی  $Y$  دو سطح  $+1$  (برای بیان علاقه داشتن کاربر به آیت) و  $-1$  (برای بیان علاقه نداشتن کاربر به آیت) را شامل شوند و صفر به معنای مشخص نبودن این مقدار باشد. هدف یافتن ماتریس‌های  $U$  و  $V$  با کمترین میزان نرْم اثر  $X = UV^T$  است که  $Y$  را با توجه به مجموعه عناصر  $\Omega$  (عناصری از ماتریس  $Y$  که مقدار آن‌ها مشخص است) تقریب بزند. زمانی که  $Y \in \{\pm 1\}$  است، در نظر گرفتن حاشیه سخت  $1$ ، معادل این است که برای همه  $(i, j) \in \Omega$  داریم  $y_{ij}x_{ij} \geq 1$ . با معرفی متغیرهای شل‌کننده  $\xi_{ij}$ ، محدودیت سخت می‌تواند به صورت  $y_{ij}x_{ij} \geq 1 - \xi_{ij}$  درآید. کمینه کردن متغیرهای شل‌کننده معادل کمینه کردن تابع خطای محوری (hinge-loss) یعنی  $h(z) = (1 - z)_+ = \max(0, 1 - z)$  است. خطای محوری  $h(z)$  در  $z=1$  مشتق پذیر نیست و نسبت به داده‌های پرت بسیار حساس است و بنابراین به عنوان جایگزین، خطای محوری نرْم (smooth hinge-loss) در [33] پیشنهاد شد که به صورت زیر تعریف می‌شود:

$$h(z) = \begin{cases} 0 & \text{if } z \geq 1 \\ \frac{1}{2}(1 - z)^2 & \text{if } 0 < z < 1 \\ \frac{1}{2} - z & \text{otherwise} \end{cases} \quad (1)$$

بنابراین می‌توان مسئله فاکتورسازی ماتریس با بیشترین حاشیه را برای ماتریس‌های امتیازدهی دو سطحی به مسئله بهینه‌سازی زیر تبدیل کرد:

$$\min_{U, V} J(U, V) = \sum_{(i, j) \in \Omega} h(y_{ij}(U_i V_j^T)) + \frac{\lambda}{2} (\|U\|_F^2 + \|V\|_F^2) \quad (2)$$

که در آن  $h(\cdot)$  تابع خطای محوری نرْم می‌باشد.

این مسئله بهینه‌سازی می‌تواند توسط حل‌کننده‌های نیمه معین حل گردد. اما حل‌کننده‌های فعلی فقط می‌توانند ابعاد تا چند صدتایی را مدیریت کنند. بنابراین بهینه‌سازی مستقیماً مبتنی بر گرادیان در [34] مورد استفاده قرار گرفت.

الگوریتم نزول گرادیان و انواع آن مانند نزول گرادیان مزدوج و نزول گرادیان تصادفی با مقادیر تصادفی  $U$  و  $V$  آغاز می‌گردد و به طور پی در پی  $U$  و  $V$  به صورت زیر بروزرسانی می‌شوند.

فرآیند تکمیل ماتریس از روی ماتریس‌های فاکتور  $U$  و  $V$  به وسیله قاعده زیر انجام می‌پذیرد.

$$\hat{y}_{ij} = \begin{cases} -1 & \text{if } (i, j) \notin \Omega \wedge U_i V_j^T \leq 0 \\ +1 & \text{if } (i, j) \notin \Omega \wedge U_i V_j^T \geq 0 \\ y_{ij} & \text{if } (i, j) \in \Omega \end{cases} \quad (3)$$

روش MMMF (فاکتورسازی ماتریس با بیشترین حاشیه) در [35] و پس از آن Fast MMMF (فاکتورسازی ماتریس با بیشترین حاشیه سریع) در [34] از ابتدا برای پالایش مشارکتی با ماتریس‌های امتیازدهی ترتیبی طراحی گردیدند که در آن علاقه‌مندی‌های کاربران به شکل اعداد گسسته بود، نه به صورت دوست داشتن یا نداشتن. ایده اصلی آن‌ها توسعه تابع خطای محوری به تنظیمات ترتیبی است. جهت مرتبط کردن مقدار پیش‌بینی شده  $x_{ij} = U_i V_j^T$  با مقدار گسسته  $y_{ij}$  با  $R$  برچسب، عدد به‌عنوان آستانه استفاده می‌گردد که به آن‌ها  $\{\theta_1, \dots, \theta_{R-1}\}$  می‌گویند. برای حالت‌های با حاشیه نرم، زمانی که متغیر شل‌کننده افزوده می‌گردد، تابع خطای تغییر یافته نه تنها تخطی از دو محدودیت ضروری  $x_{ij} \leq y_{ij} - 1 + \theta_{y_{ij}-1}$  و  $x_{ij} \geq \theta_r + 1$  را اندازه می‌گیرد، بلکه تخطی از همه محدودیت‌های آستانه  $x_{ij} \geq \theta_r + 1$  برای  $r < y_{ij}$  و  $x_{ij} \leq \theta_r - 1$  برای  $r \geq y_{ij}$  نیز اندازه‌گیری می‌شود. این تغییر سعی می‌کند نقاط امتیازدهی را با حداکثر حاشیه جدا نماید. هدف از روش Fast MMMF کمینه کردن تابع هدف زیر است:

$$J(U, V, \theta) = \sum_{(i,j) \in \Omega} \sum_{r=1}^{R-1} h(T_{ij}^r(\theta_{ir} - U_i V_j^T)) + \frac{\lambda}{2} (\|U\|_F^2 + \|V\|_F^2) \quad (4)$$

که در آن  $\|\cdot\|_F$  نرم فروبنیوس، و  $\lambda$  پارامتر تنظیم، و  $\Omega$  مجموعه عناصر مشاهده شده و  $h(z)$  تابع خطای محوری است که قبلاً آن را تعریف کردیم، و  $\theta_{ir}$  آستانه برای امتیاز  $r$  کاربر  $i$  ام، و  $T$  به صورت زیر تعریف می‌گردد:

$$T_{ij}^r = \begin{cases} +1, & \text{if } r \geq y_{ij} \\ -1, & \text{if } r < y_{ij} \end{cases} \quad (5)$$

گرایان متغیرهایی که باید بهینه گردند به صورت زیر تعیین می‌گردند.

$$\frac{\partial J}{\partial U_{ip}} = \lambda U_{ip} - \sum_{r=1}^{R-1} \sum_{j|(i,j) \in \Omega} T_{ij}^r \cdot h'(T_{ij}^r(\theta_{ir} - U_i V_j^T)) \cdot V_{jp} \quad (6)$$

$$\frac{\partial J}{\partial V_{jq}} = \lambda V_{jq} - \sum_{r=1}^{R-1} \sum_{i|(i,j) \in \Omega} T_{ij}^r \cdot h'(T_{ij}^r(\theta_{ir} - U_i V_j^T)) \cdot U_{iq} \quad (7)$$

$$\frac{\partial J}{\partial \theta_{ir}} = \lambda V_{jq} - \sum_{j|(i,j) \in \Omega} T_{ij}^r \cdot h'(T_{ij}^r(\theta_{ir} - U_i V_j^T)) \quad (8)$$

در Fast MMMF هر  $V_i$  یک نقطه و هر جفت  $(U_j, \theta_{jr})$  یک ابرصفحه جداکننده نقاط با امتیاز  $r$  مربوط به کاربر  $j$  ام می‌باشد. مثلاً برای  $R=5$ ، تعداد ۴ ابرصفحه موازی داریم که کل فضا را به ۵ ناحیه (مطابق با ۵ امتیاز) تقسیم می‌نمایند. هدف MMMF یادگیری ویژگی‌های آیتم‌ها به‌عنوان نقاط، کاربران به‌عنوان ابرصفحه‌ها و امتیازات به‌عنوان حد آستانه‌هاست به طوری که نقاط تا حد امکان به صورت صحیحی در نواحی امتیازدهی که توسط ابرصفحه‌های  $(U_j, \theta_{jr})$  تعریف شده است قرار گیرند. از آن‌جا که تابع خطای محوری توسعه یافته استفاده شده است، انتظار می‌رود ابرصفحه‌های جداکننده، حاشیه‌ها را بیشینه کنند. اگرچه Fast MMMF می‌تواند تا میلیون‌ها کاربر و آیتم مقیاس پذیر باشد اما هنوز مشکلاتی دارد. این روش نیاز به تعداد زیاد فاکتور پنهان ( $k$ ) دارد که به طور غیرمستقیم منجر به سربار حافظه و زمان اجرا می‌شود. برای هر کاربر، نواحی  $R$  امتیاز به وسیله یک مجموعه از ابرصفحه‌های موازی جداسازی می‌شود. موازی قرار دادن ابرصفحه‌های تصمیم ساز

ممکن است منجر به خطای تعمیم بالاتری شود. ابرصفحه‌ها کلاس‌ها را با حاشیه‌های نامساوی به همراه بایاسی برای کلاس‌های با نمونه‌های کم جدا می‌کنند. در HMF در [36] برای نشان دادن بایاس MMMF چند سطحی به سمت نمونه‌های با تعداد امتیازات کمتر، آزمایشی انجام شده است. در این آزمایش یک ماتریس با ابعاد  $1000 \times 5$  که ۲۰ درصد آن پر است و  $k=2$  (تعداد ویژگی‌ها) در نظر گرفته شد. توزیع امتیازات نامتوازن انجام گرفت به طوری که امتیازات ۱ و ۵ بیشترین تعداد نمونه را داشتند و تعداد نمونه‌های مربوط به امتیاز ۲ و ۴ نیز از تعداد نمونه‌های مربوط به امتیاز ۳ بیشتر در نظر گرفته شد. مشاهده گردید که خطوط موازی جداکننده که بوسیله  $U_i$  و آستانه  $\theta$  برای امتیازات مختلف تعریف شده‌اند نتوانسته‌اند حاشیه بین این کلاس‌ها را حداکثر کنند. برای حل این مشکل، روشی با نام HMF ارایه گردید.


HMF شامل  $R-1$  گام می‌باشد. برای هر  $q \in \{1, 2, \dots, R-1\}$  این روش یک ماتریس امتیازدهی مبتنی بر حد آستانه به صورت زیر می‌سازد:

$$Y_{ij}^q = \begin{cases} -1 & Y_{ij} = q, \\ +1 & Y_{ij} > q, \end{cases} \quad (9)$$

که برای یادگیری فاکتورهای پنهان کاربران و آیتم‌ها یعنی  $U_i^q$  و  $V_j^q$  با استفاده از MMMF دو کلاسه زیر استفاده می‌شود:

$$\min_{U^q, V^q} J(U^q, V^q) = \sum_{Y_{ij} \geq q} h(Y_{ij}^q(U_i^q V_j^{qT})) + \frac{\lambda}{2} (\|U^q\|_F^2 + \|V^q\|_F^2). \quad (10)$$

کل فرآیند HMF را می‌توان به شکل درختی با عمق  $R-1$  تصویر کرد. هر گره از این درخت با استفاده از یک MMMF دو کلاسه برای  $Y^q$  ساخته می‌شود. در مرحله تست نیز این MMMF‌های دو کلاسه موجود در درخت مورد استفاده قرار می‌گیرند به این شکل که از ریشه به سمت برگ حرکت انجام می‌شود تا بتوان امتیاز تخمینی کاربر  $i$  به آیتم  $j$  مشخص کرد. در سطح  $q$  درخت اگر  $U_i^q V_j^{qT} \leq 0$  امتیاز تخمینی کاربر  $i$  به آیتم  $j$  برابر  $q$  تخمین زده می‌شود در غیر اینصورت باید به سطح بعدی درخت رفت. شکل ۱ فرآیند کلی روش HMF را توصیف می‌کند.



شکل ۱: فرآیند کلی روش HMF.

#### ۴. روش پیشنهادی

در بخش مرور ادبیات به بررسی برخی از روش‌های ارایه شده در حوزه سیستم‌های توصیه‌گر پرداختیم و گفته شد تنگ بودن ماتریس کاربر-آیتم، صحت روش‌های پالایش مشارکتی را به شدت تحت تاثیر قرار می‌دهد و لذا برخی از روش‌ها سعی در



استفاده از اطلاعات متنی در مورد آیتم‌ها دارند تا بدین وسیله بتوانند با ترکیب این اطلاعات اضافی با روش‌های سنتی مانند پالایش مشارکتی اقدام به پیش‌بینی نظر کاربر در مورد آیتم نمایند. اما اشکال برخی از این مقالات، استفاده از LDA یا روش‌های دیگری است که از کیسه کلمات برای پردازش متون استفاده می‌نمایند که اطلاعات زمینه‌ای معنایی مانند ترتیب کلمات را لحاظ نمی‌کنند. همچنین مدل پیش‌بینی امتیاز کاربر به آیتم که در برخی از مقالات مانند روش‌های مبتنی بر فاکتورسازی ماتریس ارائه شده اند نسبت به فاکتورهای پنهان کاربر یا آیتم خطی هستند که صحت این روش‌ها را محدود می‌کند. ضمناً روش‌های مبتنی بر فاکتورسازی ماتریس با مرتبه پایین در هنگام استخراج ویژگی کاربران حداکثر حاشیه را لحاظ نمی‌نمایند. هدف از ارائه این روش بهبود صحت پیش‌بینی امتیاز کاربر به آیتم از طریق ارائه یک مدل غیرخطی و در نظر گرفتن حداکثر حاشیه در استخراج ویژگی‌های کاربران است. غیرخطی کردن مدل باعث انعطاف پذیری بالاتر مدل و بهبود صحت آن خواهد شد. همچنین لحاظ نمودن حداکثر حاشیه در استخراج ویژگی‌های کاربران، منجر به بهبود کارایی مدل در مواجهه با آیتم‌هایی است که توسط کاربر امتیاز داده نشده اند.

همانطور که در شکل ۱ مشاهده می‌شود، درخت حاصل روش HMF یک درخت دودویی کاملاً نامتوازن است. لذا زمان مورد نیاز برای آموزش، تست و همچنین دقت چنین درختی کارایی لازم را ندارد. لذا در این مقاله روشی ارائه می‌کنیم که ساختاری متوازن دارد و علاوه بر رفع مشکل روش HMF، از داده‌های متنی نوشته شده توسط کاربران جهت بهبود دقت پیش‌بینی امتیازات بهره می‌برد.

درک مفهوم یک متن و استخراج ویژگی از آن نیازمند خواندن پیوسته کلمات و حفظ و نگهداری مفاهیم کلمات قبل است. شبکه‌های عصبی متداول چندان در این مورد موفق نبودند زیرا امکان نگهداری مفاهیم کلمات قبل را نداشتند. به‌عنوان نمونه شبکه‌های عصبی کانولوشنی از پنجره کلمات برای استخراج ویژگی استفاده می‌نمایند که با توجه به محدود بودن تعداد کلمات داخل پنجره امکان نگهداری مفاهیم از کلمات تاثیرگذار قبلی وجود ندارد. شبکه‌های عصبی بازگشتی با توجه به نوع طراحی‌شان این مشکل را برطرف کرده‌اند. این شبکه‌ها در داخل خود به‌صورت زنجیره‌ای و بازگشتی عمل می‌کنند و لذا بسیار مناسب برای کار کردن با داده‌های دنباله‌ای و لیستی می‌باشند. عملکرد شبکه‌های عصبی بازگشتی به گونه‌ای است که باعث می‌شود اطلاعاتی که از کلمات موجود در متن استخراج شده‌اند از بین نرفته و در شبکه باقی بمانند. شبکه عصبی LSTM عملکرد بسیار مناسبی در حوزه کار با دنباله‌ها از خود به نمایش گذاشته است. با توجه به توانایی شبکه‌های LSTM در کار با دنباله‌ها و اینکه متن نوعی دنباله شامل کلمات به هم مرتبط می‌باشد برای استخراج ویژگی از متون نوشته شده توسط کاربران و استفاده از آن‌ها در بهبود تخمین امتیاز کاربران به آیتم‌ها، از این نوع شبکه در طراحی مدل پیشنهادی استفاده نمودیم.

الگوریتم مربوط به مرحله آموزشی روش ارائه شده یک ساختار درختی متوازن ایجاد می‌کند که به‌طور مثال برای سیستمی با امتیازات یک تا پنج، با  $low=1$  و  $high=5$  و  $Y$  به‌عنوان ماتریس امتیازات آغاز به کار می‌نماید. این الگوریتم یک الگوریتم بازگشتی است که در هر گره درخت برای ایجاد گره فرزند خود را فراخوانی می‌کند. در هر گام،  $low$  و  $high$  به ترتیب کمترین و بیشترین امتیاز باقیمانده برای گره فعلی می‌باشند. در هر تکرار اگر  $low < high$  باشد آنگاه  $mid = \frac{low+high}{2}$  و با توجه به مقدار  $mid$  و با استفاده از رابطه زیر عناصر ماتریس  $Y_{ij}^{mid}$  بدست می‌آیند.

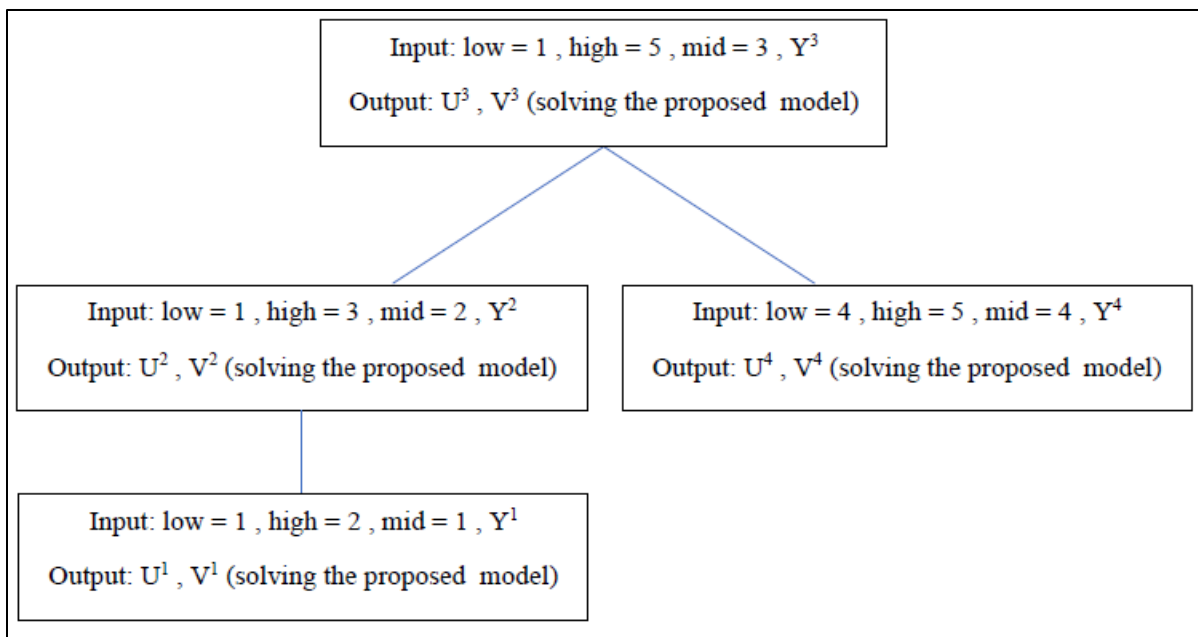
$$Y_{ij}^{mid} = \begin{cases} -1 & low \leq Y_{ij} \leq mid, \\ +1 & mid + 1 \leq Y_{ij} \leq high. \end{cases} \quad (11)$$

سپس با کمینه کردن تابع هزینه مدل پیشنهادی که در زیر آمده است، مقادیر ویژگی‌های پنهان کاربران یعنی  $U^{mid}$  و آیت‌های متناسب با آن مرحله یعنی  $V^{mid}$  بدست می‌آید.

$$\begin{aligned} \min_{U^{mid}, V^{mid}} J(U^{mid}, V^{mid}) &= \|V_j^{mid} - LSTM(X_j)\|^2 + \sum_{low \leq Y_{ij} \leq high} h\left(Y_{ij}^{mid} \left(U_i^{mid} V_j^{mid T}\right)\right) \\ &+ \frac{\lambda}{2} \left(\|U^{mid}\|_F^2 + \|V^{mid}\|_F^2\right) \end{aligned} \quad (12)$$

مقادیر  $U^{mid}$  و  $V^{mid}$  بدست آمده، برای استفاده در مرحله تست روش پیشنهادی ذخیره می‌گردند.

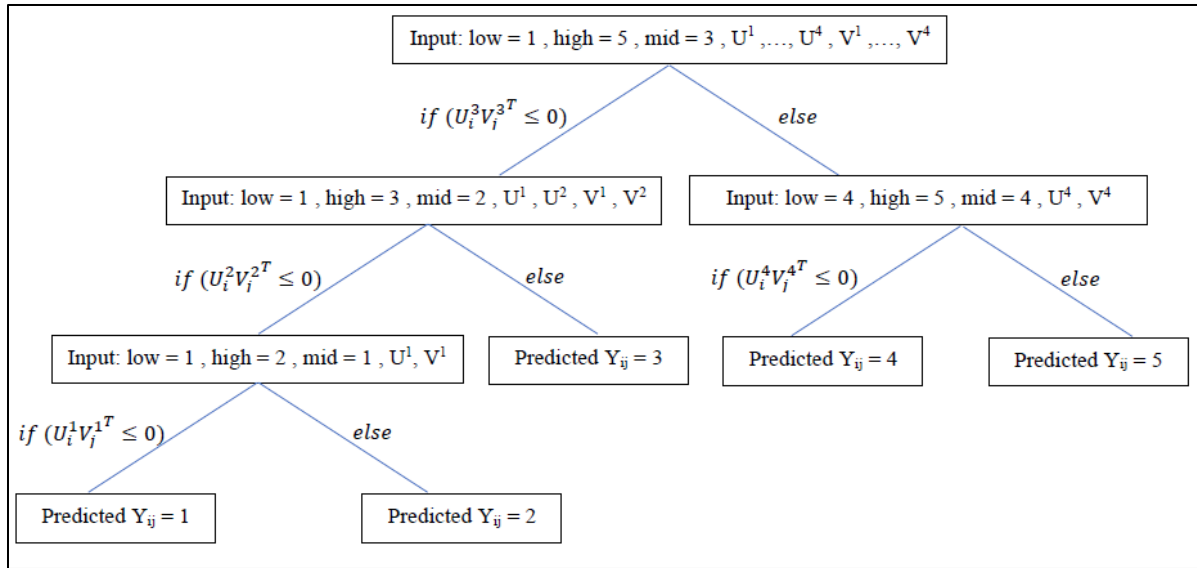
اجرای این مرحله باعث تقسیم مجموعه امتیازات باقیمانده یعنی  $\{low, low + 1, \dots, high\}$  به دو زیرمجموعه تقریباً برابر  $\{low, low + 1, \dots, mid\}$  و  $\{mid + 1, mid + 2, \dots, high\}$  می‌گردد. سپس الگوریتم مجدداً برای هر زیرمجموعه به صورت بازگشتی فراخوانی می‌گردد که نتیجه آن ساختن دو گره فرزند برای گره فعلی است. شکل ۲ مرحله آموزش روش پیشنهادی برای حالتی که امتیازات قابل اختصاص اعداد طبیعی ۱ تا ۵ می‌باشند را نمایش می‌دهد و همان‌طور که در شکل مشخص شده است ویژگی‌های پنهان کاربران و آیت‌ها در مراحل مختلف با حل کردن مدل پیشنهادی محاسبه می‌گردند.



شکل ۲: مرحله آموزش روش پیشنهادی و بدست آوردن ویژگی‌های پنهان کاربران و آیت‌ها در مراحل مختلف.

در مرحله تست برای تخمین امتیاز کاربر  $i$  به آیت  $j$  از ریشه به سمت برگ حرکت می‌کنیم و از مقادیر ویژگی‌های پنهان کاربران و آیت‌ها که در مراحل مختلف آموزش بدست آمدند استفاده می‌نماییم. در هر گره پارامترهای  $low$  و  $high$  وجود دارند که کمترین و بیشترین مقدار امتیاز در آن گره محسوب می‌شوند و لذا برای گره ریشه داریم  $low=1$  و  $high=R$ . در گره برگ داریم  $low=high$ . در هر گره اگر آن گره برگ باشد امتیاز تخمینی برابر با  $low$  است. در غیر این صورت اگر

آنگاه به سمت چپ حرکت می‌کنیم و در غیر این صورت به سمت راست حرکت می‌کنیم که در آن  $U_i^{mid}V_j^{midT} \leq 0$ ، شکل ۳ مرحله تست روش پیشنهادی و پیش‌بینی امتیازات نامعلوم را نمایش می‌دهد.



شکل ۳: مرحله تست روش پیشنهادی و پیش‌بینی امتیازاتی که مقدارشان مشخص نبوده است. شبه‌کدهای زیر الگوریتم‌های آموزش و تست مربوط به روش پیشنهادی را بیان می‌کنند.

### Algorithm 1. Train phase of the proposed method.

Input:

low, high, // minimum and maximum of remaining ratings

Y. // user-item rating matrix

Output:

$(U^1, V^1), (U^2, V^2), \dots, (U^{R-1}, V^{R-1})$ .

// Users and items latent factors for thresholded user-item rating matrices  $Y^q$  ( $q = 1, 2, \dots, R - 1$ ).

Begin

If (high <= low)

return;

//Make the content of current node:

Set  $mid = \lfloor \frac{low+high}{2} \rfloor$ ;

Set  $Y_{ij}^{mid} = \begin{cases} -1 & low \leq Y_{ij} \leq mid, \\ +1 & mid + 1 \leq Y_{ij} \leq high. \end{cases}$

Solve the following model:

$$\begin{aligned} \min_{U^{mid}, V^{mid}} J(U^{mid}, V^{mid}) \\ = \sum_{low \leq Y_{ij} \leq high} h\left(Y_{ij}^{mid} (U_i^{mid} V_j^{mid T})\right) + \frac{\lambda}{2} (\|U^{mid}\|_F^2 + \|V^{mid}\|_F^2) \\ + \|V_j^{mid} - LSTM(X_j)\|^2. \end{aligned}$$

Call Algorithm1(low, mid, Y); //Make left child node  
 Call Algorithm1(mid+1, high, Y); //Make right child node

End

---

### Algorithm 2. Test phase of the proposed method.

Input:

low, high, // Minimum and maximum of remaining ratings  
 // They must be set to 1 and R, respectively, by user.  
 i, //user No.  
 j, //item No.  
 $U^1, \dots, U^{R-1}$ , //Latent feature vectors of users for each of R-1 two-class MMMFs.  
 $V^1, \dots, V^{R-1}$ . //Latent feature vectors of items for each of R-1 two-class MMMFs.

Output:

Estimated rating of i-th user on j-th item.

Begin

If (high<=low)

return low; // It is a leaf node. Return estimated rating of i-th user on j-th item.

Set  $mid = \lfloor \frac{low+high}{2} \rfloor$ ;

If ( $U_i^{mid} V_j^{mid T} \leq 0$ )

return Algorithm2(low, mid, i, j,  $U^1, \dots, U^{R-1}$ ,  $V^1, \dots, V^{R-1}$ ); //Go to left node

else

return Algorithm2(mid+1, high, i, j,  $U^1, \dots, U^{R-1}$ ,  $V^1, \dots, V^{R-1}$ ); //Go to right node

node


End

۵. نتایج عملی

پیاده‌سازی با استفاده از زبان پایتون ۳.۶ و کتابخانه کراس انجام پذیرفت. ساختارهای مختلفی برای شبکه عصبی طراحی شده مورد بررسی قرار گرفت که توصیف نمونه‌نهایی آن بدین صورت است که برای بازنمایی کلمات از روش بردار تعبیه کلمات استفاده شد. برای این منظور بردارهای پنهان کلمات با اندازه ۲۰۰ در نظر گرفته شدند و با استفاده از لایه Embedding در کراس وارد شبکه می‌شوند. سه لایه LSTM با اندازه‌های ۱۲۸ و ۶۴ و ۳۲ ایجاد گردیدند. همچنین بین لایه‌های LSTM نیز لایه‌های Dropout با نرخ‌های ۰.۳ و ۰.۱ و ۰.۱ قرار داده شدند. آخرین لایه نیز Dense است که اندازه آن برابر با تعداد فاکتورهای پنهان آیت‌ها (به‌عنوان مثال ۲۰) می‌باشد. برای ارزیابی روش پیشنهادی از مجموعه داده‌های Amazon و MovieLens استفاده گردید که در مقاله [25] نیز استفاده شده‌اند. این مجموعه داده‌ها شامل امتیازاتی در بازه 1-5 هستند که کاربران به آیت‌های مختلف اختصاص داده‌اند. از آنجا که مجموعه داده MovieLens شامل اطلاعات متنی (مانند خلاصه فیلم) در مورد آیت‌ها نیست لذا نویسندگان مقاله [25] اطلاعات متنی آیت‌های مرتبط را از IMDB فراهم نموده‌اند و برای مجموعه داده Amazon نیز اطلاعات متنی همان نظرات کاربران در مورد آیت‌هاست. همچنین نویسندگان مقاله [25] گام‌های مختلف پیش پردازش متنی را روی متون اجرا نمودند که به تفصیل بیان نموده‌اند و در اختیار سایر محققین قرار گرفته است<sup>۳</sup>. لذا ما نیز برای ارزیابی کارایی روش پیشنهادی از همان مجموعه داده‌ها استفاده نمودیم. میانگین خطای مطلق یا MAE<sup>۴</sup> یکی از پرکاربردترین معیارها در ارزیابی سیستم‌های توصیه‌گر است. این معیار میانگین خطای مدل را به صورت زیر محاسبه می‌نماید:

$$MAE = \frac{\sum_{(i,j) \in \Omega} |Y_{ij} - Predict_{ij}|}{|\Omega|} \quad (13)$$

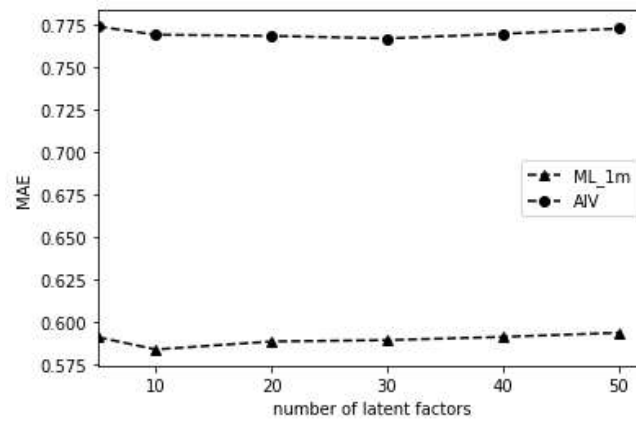
مقدار بهینه پارامتر تنظیمی  $\lambda$  و تعداد فاکتورهای پنهان  $k$  به ترتیب از مجموعه‌های  $\{10, 20, 30, 40, 50, 60, 70, 80, 90, 100\}$  و  $\{5, 10, 20, 30, 40, 50\}$  انتخاب گردیدند. شکل ۴ برای تعداد فاکتورهای پنهان  $k=20$  تغییرات MAE روش پیشنهادی به واسطه تغییر پارامتر تنظیمی  $\lambda$  را بیان می‌نماید. همچنین شکل ۵ تغییرات MAE بعد از تنظیم پارامتر  $\lambda$  را به ازای تعداد فاکتورهای پنهان مختلف نمایش می‌دهد. همان طور که در شکل نیز مشخص است استفاده از تعداد فاکتورهای پنهان بیشتر از ۵۰ تاثیر چندانی روی دقت روش پیشنهادی ندارد.



شکل ۴: تاثیر تغییر پارامتر تنظیمی  $\lambda$  روی MAE روش پیشنهادی برای  $k=20$ .

<sup>۳</sup> <http://dm.postech.ac.kr/~cartopy/ConvMF>

<sup>۴</sup> Mean Absolute Error



شکل ۵: تاثیر تغییر تعداد فاکتورهای پنهان روی MAE روش پیشنهادی برای  $k=20$ .

برای ارزیابی کارایی روش پیشنهادی، آنرا با روش ارایه شده در مقاله [25] که آنرا R-ConvMF نامیدند و روش HMF مقایسه کرده ایم. جدول ۱ نتیجه مقایسه روش پیشنهادی با روش های بیان شده را برحسب MAE نشان می دهد. همان طور که دیده می شود میزان خطای روش HMF از روش پیشنهادی بیشتر است زیرا HMF برای مرحله آموزش، تعدادی دسته بند دو کلاسه با حداکثر حاشیه می سازد که منجر به ایجاد یک درخت نامتوازن یک طرفه می گردد که در شکل ۱ نمایش داده شده بود. اما روش پیشنهادی به شیوه ای طراحی گردیده است که منجر به آموزش تعدادی دسته بند دو کلاسه می گردد که درختی متوازن را نتیجه می دهد. لذا به دلیل متوازن بودن این درخت، دقت دسته بندهای دو کلاسه طراحی شده بیشتر از روش HMF است. مزیت دیگری که باعث بهبود عملکرد روش پیشنهادی نسبت به روش HMF شده است استفاده از داده های متنی است که منجر به استفاده بهتر از دانش موجود در سیستم گردیده است. همچنین همانطور که در جدول ۱ آمده است دقت روش پیشنهادی از روش ارایه شده در R-ConvMF نیز بیشتر است. دلیل بهبود کارایی این است که روش پیشنهادی علاوه بر استفاده از اطلاعات متنی در مورد آیتم ها که در R-ConvMF نیز از آنها استفاده گردیده است، یک مدل پیشگوی غیر خطی ارایه کرده است که در هنگام بدست آوردن فاکتورهای پنهان کاربران و آیتم ها حداکثر حاشیه را نیز لحاظ نموده است.

جدول ۱: خطای تخمینی برحسب MAE.

Method	MovieLens-1M	AIV
HMF [36]	$0.6598 \pm 0.0055$	$0.8723 \pm 0.0056$
R-ConvMF [25]	$0.6058 \pm 0.0028$	$0.8088 \pm 0.0037$
Proposed Method	<b><math>0.5825 \pm 0.0044</math></b>	<b><math>0.7868 \pm 0.0046</math></b>

## ۶. نتیجه گیری و کارهای آینده

همانطور که گفته شد داده های متنی و اسناد توصیفی موجود در سیستم های اطلاعاتی می توانند در بهبود عملکرد سیستم های توصیه گر مورد استفاده قرار بگیرند. پژوهش های مختلف در این حوزه مورد بررسی قرار گرفتند. برخی از روش ها اطلاعات زمینه ای معنایی مانند ترتیب کلمات موجود در اسناد توصیفی را در نظر نمی گیرند که این کار باعث کاهش کیفیت استخراج ویژگی از متن می گردد. همچنین طبق بررسی انجام شده، برخی از روش ها برای طراحی مدلی که بتواند امتیاز یک کاربر به

یک آیتم را تشخیص دهد از روش‌های مبتنی بر فاکتورسازی ماتریس (با مرتبه پایین یا نرم پایین) استفاده می‌نمایند که این روش‌ها نسبت به فاکتورهای پنهان کاربر یا آیتم خطی هستند و لذا توانایی پیش‌بینی رفتارهای پیچیده کاربران را ندارند. علاوه بر این روش‌های مبتنی بر فاکتورسازی ماتریس با مرتبه پایین در هنگام استخراج ویژگی‌های کاربران و آیتم‌ها حداکثر حاشیه را در نظر نمی‌گیرند که این موضوع نیز باعث کاهش دقت مدل پیش‌بینی می‌گردد. لذا در روش پیشنهادی از شبکه‌های بازگشتی LSTM استفاده گردید که نسبت به مدل‌های مبتنی بر کیسه کلمات عملکرد بهتری دارند و ضمن لحاظ کردن ترتیب کلمات توانایی حفظ اطلاعات مفید دنباله‌های طولانی‌تر و بازنمایی معنایی پنهان بهتر متون را نیز دارند. با استفاده از استخراج ویژگی با کمک شبکه‌های بازگشتی LSTM از روی اسناد توصیفی در مورد آیتم‌ها، و لحاظ نمودن حداکثر حاشیه در هنگام استخراج ویژگی‌های کاربران و آیتم‌ها یک مدل پیش‌بینی جدید و غیرخطی طراحی گردید. مدل طراحی شده در آزمایش‌ها انجام گرفته در مقایسه با روش R-ConvMF به‌عنوان روشی موثر برای استفاده از متون توصیفی در پیش‌بینی امتیازات عملکرد بهتری را نمایش داد که علت آن لحاظ نمودن حداکثر حاشیه در استخراج ویژگی‌های کاربران و آیتم‌هاست. همچنین مدل پیشنهادی در مقایسه با HMF به‌عنوان روشی موثر که از فاکتورسازی ماتریس با حداکثر حاشیه بهره می‌برند نیز دقت بالاتری را نشان داد که علت آن استفاده از متون توصیفی موجود در سیستم و همچنین ساخت دسته‌بندهای دوکلاسه از داده‌هایی که متوازن می‌باشند. می‌توان در آینده برای بهبود عملکرد HMF متوازن پیشنهادی روشی ارایه کرد که ساختار درختی متفاوتی را ایجاد نماید. به‌عنوان مثال با لحاظ نمودن تعداد موجود از هر امتیاز ممکن است بتوان ایده مطرح شده در HMF متوازن را با الگوریتم‌هایی مانند AVL ترکیب کرد تا به ساختار درختی جدیدی دست یافت و مجموعه آموزشی متوازن‌تری داشت. تغییر دادن تابع هزینه مدل پیشنهادی که از اسناد متنی استفاده می‌نمود و همچنین بکاربردن تکنیک‌های دیگر شبکه‌های عصبی عمیق مانند مکانیزم توجه نیز به‌عنوان کارهای آینده پیشنهاد می‌گردد.

## مراجع

- [1] Esparza, S. G., O'Mahony, M. P., & Smyth, B. (2010, December). Effective product recommendation using the real-time web. In International Conference on Innovative Techniques and Applications of Artificial Intelligence (pp. 5-18). Springer, London.
- [2] Garcia Esparza, S., O'Mahony, M. P., & Smyth, B. (2011, October). A multi-criteria evaluation of a user generated content based recommender system. In Presented at the 3rd Workshop on Recommender Systems and the Social Web (RSWEB-11), 5th ACM Conference on Recommender Systems, Chicago, IL, USA, 23-27 October 2011.
- [3] Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent dirichlet allocation. Journal of machine Learning research, 3(Jan), 993-1022.
- [4] Seroussi, Y., Bohnert, F., & Zukerman, I. (2011, June). Personalised rating prediction for new users using latent factor models. In Proceedings of the 22nd ACM conference on Hypertext and hypermedia (pp. 47-56). ACM.
- [5] McAuley, J., & Leskovec, J. (2013, October). Hidden factors and hidden topics: understanding rating dimensions with review text. In Proceedings of the 7th ACM conference on Recommender systems (pp. 165-172). ACM.
- [6] Leung, C. W., Chan, S. C., & Chung, F. L. (2006, August). Integrating collaborative filtering and sentiment analysis: A rating inference approach. In Proceedings of the ECAI 2006 workshop on recommender systems (pp. 62-66).

- [7] Zhang, W., Ding, G., Chen, L., Li, C., & Zhang, C. (2013). Generating virtual ratings from chinese reviews to augment online recommendations. *ACM Transactions on intelligent systems and technology (TIST)*, 4(1), 9.
- [8] Poirier, D., Tellier, I., Fessant, F., & Schluth, J. (2010, April). Towards text-based recommendations. In *Adaptivity, Personalization and Fusion of Heterogeneous Information* (pp. 136-137). LE CENTRE DE HAUTES ETUDES INTERNATIONALES D'INFORMATIQUE DOCUMENTAIRE.
- [9] Wawre, S. V., & Deshmukh, S. N. (2016). Sentiment classification using machine learning techniques. *International Journal of Science and Research (IJSR)*, 5(4), 819-821.
- [10] Ganapathibhotla, M., & Liu, B. (2008, August). Mining opinions in comparative sentences. In *Proceedings of the 22nd International Conference on Computational Linguistics-Volume 1* (pp. 241-248). Association for Computational Linguistics.
- [11] Shaikh, M. A. M., Prendinger, H., & Ishizuka, M. (2009). A linguistic interpretation of the OCC emotion model for affect sensing from text. In *Affective information processing* (pp. 45-73). Springer, London.
- [12] Raghavan, S., Gunasekar, S., & Ghosh, J. (2012, September). Review quality aware collaborative filtering. In *Proceedings of the sixth ACM conference on Recommender systems* (pp. 123-130). ACM.
- [13] Wang, H., Wang, N., & Yeung, D. Y. (2015, August). Collaborative deep learning for recommender systems. In *Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 1235-1244). ACM.
- [14] Wu, L., Quan, C., Li, C., Wang, Q., Zheng, B., & Luo, X. (2019). A context-aware user-item representation learning for item recommendation. *ACM Transactions on Information Systems (TOIS)*, 37(2), 22.
- [15] Bao, Y., Fang, H., & Zhang, J. (2014, June). Topicmf: Simultaneously exploiting ratings and reviews for recommendation. In *Twenty-Eighth AAAI conference on artificial intelligence*.
- [16] McAuley, J., & Leskovec, J. (2013, October). Hidden factors and hidden topics: understanding rating dimensions with review text. In *Proceedings of the 7th ACM conference on Recommender systems* (pp. 165-172). ACM.
- [17] Tan, Y., Zhang, M., Liu, Y., & Ma, S. (2016, July). Rating-boosted latent topics: Understanding users and items with ratings and reviews. In *IJCAI (Vol. 16, pp. 2640-2646)*.
- [18] Wang, C., & Blei, D. M. (2011, August). Collaborative topic modeling for recommending scientific articles. In *Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 448-456). ACM.
- [19] Catherine, R., & Cohen, W. (2017, August). Transnets: Learning to transform for recommendation. In *Proceedings of the Eleventh ACM Conference on Recommender Systems* (pp. 288-296). ACM.
- [20] Kim, D., Park, C., Oh, J., Lee, S., & Yu, H. (2016, September). Convolutional matrix factorization for document context-aware recommendation. In *Proceedings of the 10th ACM Conference on Recommender Systems* (pp. 233-240). ACM.
- [21] Zheng, L., Noroozi, V., & Yu, P. S. (2017, February). Joint deep modeling of users and items using reviews for recommendation. In *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining* (pp. 425-434). ACM.
- [22] Seo, S., Huang, J., Yang, H., & Liu, Y. (2017, August). Interpretable convolutional neural networks with dual local and global attention for review rating prediction. In *Proceedings of the Eleventh ACM Conference on Recommender Systems* (pp. 297-305). ACM.



- [23] Ling, G., Lyu, M. R., & King, I. (2014, October). Ratings meet reviews, a combined approach to recommend. In Proceedings of the 8th ACM Conference on Recommender systems (pp. 105-112). ACM.
- [24] Zhang, W., Yuan, Q., Han, J., & Wang, J. (2016, July). Collaborative multi-Level embedding learning from reviews for rating prediction. In IJCAI (pp. 2986-2992).
- [25] Kim, D., Park, C., Oh, J., & Yu, H. (2017). Deep hybrid recommender systems via exploiting document context and statistics of items. *Information Sciences*, 417, 72-87.
- [26] Chen, C., Zhang, M., Liu, Y., & Ma, S. (2018, April). Neural attentional rating regression with review-level explanations. In Proceedings of the 2018 World Wide Web Conference (pp. 1583-1592). International World Wide Web Conferences Steering Committee.
- [27] Lu, Y., Dong, R., & Smyth, B. (2018, April). Coevolutionary recommendation model: Mutual learning between ratings and reviews. In Proceedings of the 2018 World Wide Web Conference (pp. 773-782). International World Wide Web Conferences Steering Committee.
- [28] Xing, S., Wang, Q., Zhao, X., & Li, T. (2019). A hierarchical attention model for rating prediction by leveraging user and product reviews. *Neurocomputing*, 332, 417-427.
- [29] Zheng, L., Cao, B., Noroozi, V., Philip, S. Y., & Ma, N. (2017, December). Hierarchical collaborative embedding for context-aware recommendations. In 2017 IEEE International Conference on Big Data (Big Data) (pp. 867-876). IEEE.
- [30] Xing, S., Liu, F., Zhao, X., & Li, T. (2018). Points-of-interest recommendation based on convolution matrix factorization. *Applied intelligence*, 48(8), 2458-2469.
- [31] Wu, H., Zhang, Z., Yue, K., Zhang, B., He, J., & Sun, L. (2018). Dual-regularized matrix factorization with deep neural networks for recommender systems. *Knowledge-Based Systems*, 145, 46-58.
- [32] Zhang, J. D., & Chow, C. Y. (2018). SEMA: Deeply learning semantic meanings and temporal dynamics for recommendations. *IEEE Access*, 6, 54106-54116.
- [33] Rennie, J. D., & Srebro, N. (2005, July). Loss functions for preference levels: Regression with discrete ordered labels. In Proceedings of the IJCAI multidisciplinary workshop on advances in preference handling (pp. 180-186). Kluwer Norwell, MA.
- [34] Rennie, J. D., & Srebro, N. (2005, August). Fast maximum margin matrix factorization for collaborative prediction. In Proceedings of the 22nd international conference on Machine learning (pp. 713-719). ACM.
- [35] Srebro, N., Rennie, J., & Jaakkola, T. S. (2005). Maximum-margin matrix factorization. In *Advances in neural information processing systems* (pp. 1329-1336).
- [36] Kumar, V., Pujari, A. K., Sahu, S. K., Kagita, V. R., & Padmanabhan, V. (2017). Collaborative filtering using multiple binary maximum margin matrix factorizations. *Information Sciences*, 380, 1-11.
- [37] Sharma, S., Rana, V., & Kumar, V. (2021). *Deep learning based semantic personalized recommendation system. International Journal of Information Management Data Insights*, 1(2), 100028.