

یک سامانه توصیه‌گر بر پایه شبکه‌های عصبی گرافی و با استفاده از روش دامنه‌های متقابل برای حل مشکل

آغاز سرد

سحر اختری^۱، نصرتعلی اشرفی پیامن^{۲*}

^۱ دانشجوی کارشناسی ارشد هوش مصنوعی، گروه مهندسی برق و کامپیوتر، دانشگاه خوارزمی، تهران، ایران

^۲ استادیار گروه مهندسی برق و کامپیوتر، دانشگاه خوارزمی، تهران، ایران

چکیده

امروزه میزان و اهمیت داده‌های موجود در اینترنت به‌طور تصاعدی در حال افزایش است که انتخاب یک گزینه مطلوب از بین گزینه‌های بسیار زیاد می‌تواند خسته‌کننده و وقت‌گیر باشد. هدف سامانه‌های توصیه‌گر، این است که این فرآیند را با یافتن اقلام مناسبی که بیشتر موردعلاقه کاربران هستند، تسهیل کنند. تکنیک‌های پیشنهادی سامانه‌های توصیه‌گر موجود از مشکلات رایجی مانند پراکندگی داده، آغاز سرد و مشکلات کاربران جدید رنج می‌برند. در این مقاله تمرکز اصلی بر استفاده از اطلاعات دامنه‌های دیگر برای ایجاد سامانه‌های توصیه‌گر دامنه متقابل است. سامانه‌های توصیه‌گر دامنه متقابل می‌توانند موقعیت‌های آغاز سرد و کاربران جدید را به‌خوبی مدیریت کنند، در این مقاله روش GCDRS پیشنهاد شده است که در آن ابتدا مدلی بر پایه شبکه‌های عصبی گرافی، الگوی تعاملات کاربران و کالاها را در هر دامنه به‌صورت مستقل کشف می‌کند و در گام بعد یک شبکه عصبی، بازنمایی به‌دست‌آمده برای کاربران آغاز سرد را از دامنه مبدأ به دامنه هدف منتقل می‌کند. نتایج نشان می‌دهد مدل پیشنهادی در مقایسه با سایر مدل‌ها عملکرد بهتری برای رتبه‌بندی کالاها دارد.

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۳/۰۳/۱۰

تاریخ پذیرش:

۱۴۰۳/۰۵/۳۱

کلیدواژه‌ها:

سامانه‌های توصیه‌گر، سامانه‌های

توصیه‌گر دامنه متقابل، شبکه

عصبی گرافی، آغاز سرد

نویسنده مسئول:

ashrafi@khu.ac.ir

doi : 10.22034/abmir.2024.21697.1055

E-ISSN: [2821-2037](https://doi.org/10.22034/abmir.2024.21697.1055) /© 2023. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).



۱- مقدمه

آغاز سرد است که در آن کاربر در سامانه جدید است، یا سابقه رتبه‌بندی قبلی ندارد.

کاربران انواع مختلفی از اطلاعات را در دامنه‌های مختلف به اشتراک می‌گذارند. پراکندگی داده‌ها^۲ را می‌توان با اشتراک‌گذاری دانش از یک دامنه به دامنه دیگر یا با ادغام ویژگی‌های مختلف از دامنه‌های مختلف کاهش داد. اگر کاربر تازه‌وارد یک دامنه شده باشد، یک سامانه توصیه‌گر دامنه متقابل^۴ می‌تواند از سایر اطلاعات مشترک قبلی مرتبط با این کاربر یا موضوع برای ایجاد یک توصیه دقیق برای آن کاربر خاص در دامنه جدید استفاده کند.

این پژوهش بر توسعه یک سامانه توصیه‌گر دامنه متقابل بانام GCDRS^۵ برای مقابله با مشکل آغاز سرد، مشکل کاربر جدید و همچنین افزایش دقت موارد توصیه‌شده نهایی تمرکز دارد. برای بررسی اثربخشی این ایده، شبکه عصبی گرافی^۶ مورد استفاده قرار گرفته است. علاوه بر این، عملکرد سامانه‌های توصیه‌گر دامنه متقابل ارائه‌شده در این مقاله با استفاده از مجموعه داده‌های واقعی آمازون مورد ارزیابی قرار گرفته است.

در ادامه مقاله، در بخش ۲ مروری بر پژوهش‌های گذشته مرتبط با روش خود خواهیم داشت. پس از بررسی پژوهش‌ها در بخش ۲، در بخش ۳ روش پیشنهادی خود را تشریح خواهیم کرد. در بخش ۴ روش پیشنهادی خود را مورد ارزیابی قرار خواهیم داد و در بخش ۵ به نتیجه‌گیری از پژوهش انجام‌شده و چالش‌های موجود در این زمینه خواهیم پرداخت.

۲- پژوهش‌های گذشته

در سناریوی انجام‌شده در این مقاله، تعاملات برخی از کاربران در هر دو دامنه وجود دارند درحالی‌که تعاملات برخی از کاربران دیگر فقط در یک دامنه ثبت شده‌اند. کالاهای ارائه‌شده در دو دامنه نیز هم‌پوشانی ندارند. لذا در مرور ادبیات سامانه‌های توصیه‌گر، پژوهش‌های صورت گرفته در این سناریو (هم‌پوشانی جزئی کاربران و عدم هم‌پوشانی کالاها) بررسی خواهند شد. این

با گسترش دسترسی به اینترنت در سال‌های گذشته، میزان خدمات آنلاین و وب‌سایت‌های رسانه‌های اجتماعی و همچنین تعداد کاربران فعال آن‌ها به‌طور تصاعدی افزایش یافته است و کاربران محتوای زیادی را ایجاد و به اشتراک می‌گذارند. بهره‌برداری از داده‌های متنوع و کشف بینش‌های مفید به یک مهارت ضروری برای کسب‌وکارها تبدیل شده است تا بتوانند خود را در این بازار مدرن، سریع و رقابتی حفظ کنند.

یافتن محصول یا خدمات مناسب در بین اقلام متعددی که برای یک کاربر خاص در دسترس است فرآیندی بسیار وقت‌گیر است. هدف سامانه‌های توصیه‌گر پیش‌بینی اقلامی است که به احتمال زیاد، مناسب و مطلوب یک کاربر خاص می‌باشند. امروزه مردم از منابع متنوع موجود در شبکه جهانی وب برای فعالیت‌های شخصی خود استفاده می‌کنند، مانند یافتن فیلمی برای تماشا، جستجوی کتاب‌های موردعلاقه، یافتن موسیقی موردنظر، دنبال کردن اخبار، یافتن مکانی برای صرف غذا، گسترش فعالیت‌های اجتماعی خود از قبیل پیدا کردن دوستان جدید و یا شریک زندگی خود. ارائه‌دهندگان خدمات آنلاین سعی می‌کنند در چنین مواردی در راستای مشتری مداری با استفاده از سامانه‌های توصیه‌گر به کاربر کمک کنند که با صرف وقت به‌مراتب کمتری و بدون سردرگمی اقلام موردنظر خود را پیدا کند.

به‌طورکلی سامانه‌های توصیه‌گر بر استفاده از داده‌هایی که کاربران در گذشته به اشتراک گذاشته‌اند متکی هستند. با این حال، اکثر تکنیک‌های پیشنهاددهنده موجود با مشکلات مهمی روبرو هستند. اولین مشکل، ماهیت پراکنده داده‌های موجود در اینترنت یا حتی یک دامنه^۱ خاص است. مشکل دیگر زمانی است که سامانه توصیه‌گر اطلاعات کافی در مورد یک کاربر برای درک ترجیحات صریح و روابط پنهان ندارد. در این صورت، سامانه توصیه‌گر نمی‌تواند توصیه‌های مفید و دقیقی ارائه دهد که به آن مشکل آغاز سرد^۲ می‌گویند [۱]. مشکل کاربر جدید یک حالت خاص از مشکل

^۴ cross domain recommender system

^۵ Graph Cross Domain Recommender System

^۶ graph neural network

^۱ domain

^۲ cold start

^۳ data sparsity

نشانش و نگاشت یک روش توصیه‌گر دامنه متقابل است که در آن یک دامنه به‌عنوان دامنه مبدأ و دیگری به‌عنوان دامنه هدف در نظر گرفته می‌شود. رویکرد نشانش و نگاشت برای توصیه‌گرهای دامنه متقابل اولین بار توسط من و همکاران [۴] ارائه شد که مسئله توصیه‌گر دامنه متقابل را هدف قرار داد. هدف، تبدیل عامل پنهان^۷ کاربران مشترک در دامنه مبدأ، به عوامل پنهان مربوط به آن‌ها در دامنه هدف است. برای مدل‌سازی عامل پنهان، وانگ و همکاران [۵] یک مدل نگاشت ویژگی پنهان دامنه متقابل^۸ را پیشنهاد کردند. ابتدا سه معیار شباهت بر روی رفتارهای رتبه‌بندی کاربران تعریف شد. در طول مدل‌سازی عامل پنهان، مقادیر شباهت به‌عنوان محدودیت در فرآیند تجزیه ماتریس نشانش شد.

زو و همکاران [۶] بیان کردند که روابط پیچیده بین ترجیحات کاربر دامنه مبدأ و هدف از کاربر به‌کاربری دیگر متفاوت است که به‌سختی می‌توان با یک تابع نگاشت منفرد آن‌ها را کشف کرد. چارچوب پیشنهادی آن‌ها به نام انتقال شخصی ترجیحات کاربر برای توصیه‌گر دامنه متقابل^۹ [۷] یک شبکه نگاشت نشانش را برای شخصی کردن تابع نگاشت برای هر کاربر می‌آموزد.

کانگ و همکاران [۸] پیشنهاد کردند که در رویکردهای مبتنی بر نشانش و نگاشت موجود، برای آموزش توابع نگاشت فقط از کاربران مشترک استفاده می‌شود، بنابراین عملکرد این سامانه‌های توصیه‌گر به تعداد کاربران مشترک حساس است. پس از تجزیه و تحلیل مجموعه داده‌های آمازون، آن‌ها ذکر کردند که در مجموعه داده‌های دنیای واقعی، تعداد کاربران مشترک همیشه کم است، که عملکرد رویکردهای موجود را محدود می‌کند. بنابراین، آن‌ها یک چارچوب نیمه نظارتی را برای پیشنهاد دامنه متقابل^{۱۰} (SSCDR) پیشنهاد کردند تا هم از کاربران مشترک و هم کالاهای دامنه منبع برای آموزش تابع نگاشت استفاده کند.

رویکردها را می‌توان در پنج کلاس به‌صورت زیر طبقه‌بندی کرد: (۱) تجزیه ماتریس جمعی^۱، (۲) ترکیب نمایشی از کاربران مشترک، (۳) نشانش^۲ و نگاشت^۳، (۴) رویکردهای مبتنی بر شبکه عصبی گرافی (۵) کشف همبستگی‌های جنبه^۴.

تجزیه ماتریس جمعی بسط مستقیم روش معمول تجزیه ماتریسی^۵ برای مسئله توصیه‌گر دامنه متقابل است. تجزیه ماتریسی یک روش نشانش است که با گرفتن یک ماتریس، دو ماتریس عامل آن را به‌گونه‌ای محاسبه می‌کند که حاصل ضرب آن‌ها تقریب خوبی از ماتریس اصلی باشد. تفاوت تجزیه ماتریس جمعی با روش تجزیه ماتریس عمومی این است که از دانش دامنه متقابل برای محدود کردن فرآیند تجزیه ماتریس در هر دامنه استفاده می‌شود. جیانگ و همکاران [۲] یک رویکرد یادگیری انتقالی نیمه نظارت شده به نام XPTRANS را پیشنهاد کردند. در این روش آن‌ها استدلال کردند که شباهت‌های بین کاربران مشترک در دامنه‌های مختلف سازگار است. آن‌ها ابتدا تجزیه ماتریس غیرمنفی را که همان روش تجزیه ماتریسی است با این محدودیت که تمام عناصر ماتریس‌های عامل غیر منفی باشد، در دو دامنه انجام دادند. سپس شباهت‌های مبتنی بر کاربر به‌عنوان محدودیت‌هایی به فرآیند تجزیه ماتریس در هنگام یادگیری نمایش‌های کاربران و کالاها اضافه شد.

در روش ترکیب نمایش کاربران مشترک معمولاً سه لایه وجود دارد. لایه اول نشانش‌هایی را برای کاربران و کالاهایی از هر دامنه ایجاد می‌کند. در لایه ترکیب، نشانش‌های کاربران مشترک دو دامنه باهم ترکیب می‌شوند تا نشانش‌های یکپارچه برای کاربران مشترک ایجاد کنند. در نهایت، لایه پیش‌بینی، هم نشانش‌های کاربران متمایز و هم کاربرانی که مشترک هستند را برای آموزش مدل توصیه‌گر در هر دامنه به‌طور جداگانه دریافت می‌کند. زو و همکاران [۳] این مدل را برای توصیه‌گر دامنه متقابل باهدف دوگانه^۶ پیشنهاد کردند که ایده اصلی آن اشتراک‌گذاری دانش کاربران مشترک در دامنه‌ها بود.

⁷ latent factor

⁸ Cross-Domain Latent Feature Mapping (CDLFM)

⁹ Personalized Transfer of User Preferences for Cross-domain Recommendation (PTUPCDR)

¹⁰ Semi-Supervised framework for Cross-Domain Recommendation

¹ collective matrix factorization

² embedding

³ mapping

⁴ capturing aspect correlations

⁵ general matrix factorization

⁶ Dual-Target Cross-Domain Recommendation (DTCDR)



کانولوشنی شامل عملگرهای کانولوشنی طیفی^۴ و فضایی^۵ هستند که در ادامه به صورت خلاصه معرفی می‌شوند.

رویکردهای طیفی با نمایش طیفی گراف‌ها کار می‌کنند. این روش‌ها از نظر تئوری مبتنی بر پردازش سیگنال گراف هستند [۱۰] و عملگر پیچش را در حوزه طیفی تعریف می‌کنند. در روش‌های طیفی، یک سیگنال گراف مانند x ابتدا توسط تبدیل فوریه گراف F به دامنه طیفی تبدیل می‌شود، سپس عملیات پیچش انجام می‌شود. پس از پیچش، سیگنال حاصل با استفاده از تبدیل فوریه معکوس گراف به سیگنال اصلی تبدیل می‌شود.

رویکردهای فضایی عملیات پیچش را بر اساس همبندی گراف به‌طور مستقیم بر روی گراف تعریف می‌کنند. چالش اصلی رویکردهای فضایی، تعریف عملیات کانولوشن با همسایگی‌هایی با اندازه‌های متفاوت و حفظ تغییرناپذیری محلی شبکه عصبی کانولوشنی است. نمونه‌ای از این رویکردها شبکه عصبی گرافی GraphSAGE [۱۱] است.

روش‌های مبتنی بر شبکه عصبی گرافی در سامانه‌های توصیه‌گر، اطلاعات هر دو دامنه را با ساخت یک گراف مشترک و انتشار دانش دامنه متقابل از طریق فناوری‌های یادگیری گراف ترکیب می‌کنند، که در بسیاری از موارد به عملکرد بهینه دست می‌یابد. وانگ و همکاران [۱۲] ابتدا شبکه‌های عصبی گرافی را به توصیه‌گر اجتماعی دامنه متقابل اعمال کردند و یک رویکرد رتبه‌بندی مشارکتی اجتماعی عصبی^۶ را پیشنهاد کردند. دانش دامنه متقابل توسط یک شبکه کانولوشن گرافی چندلایه که بازنمایی کاربران مشترک را به کاربران غیرمشترک منتشر می‌کند، منتقل می‌شود. کوی و همکاران [۱۳] ذکر کردند که در کارهای قبلی، رفتارهای کاربر در هر دامنه پردازش می‌شود که راهی غیرمستقیم برای ترکیب اطلاعات دامنه متقابل است. آن‌ها یک چارچوب گراف نا همگن پیشنهاد کردند که رفتارهای کاربر را از همه دامنه‌ها جمع‌آوری می‌کند تا یک گراف مشترک برای مدل‌سازی مستقیم رفتارهای دامنه متقابل کاربران ایجاد کند. به‌طور مشابه خو و همکاران [۱۴]

گراف‌ها نوعی ساختار داده‌ای هستند که مجموعه‌ای از اشیا (گره‌ها) و روابط آن‌ها (لبه‌ها) را مدل می‌کنند. به‌عنوان یک ساختار داده غیراقلیدسی منحصر به فرد برای یادگیری ماشین، تجزیه و تحلیل گراف بر وظایفی مانند طبقه‌بندی گره، پیش‌بینی لبه، خوشه‌بندی و تشخیص ناهنجاری [۹] تمرکز دارد.

شبکه‌های عصبی گرافی روش‌های مبتنی بر یادگیری عمیق هستند که در حوزه گراف عمل می‌کنند. مشخصه کلیدی یک شبکه عصبی گرافی، ارسال پیام بین زوج گره‌های مجاور است و به این ترتیب نمایش هر گره با تبادل اطلاعات با گره‌های همسایه به‌روز می‌شود. شبکه‌های عصبی گرافی دارای ماژول‌های محاسباتی مختلفی هستند که در ادامه به تشریح آن می‌پردازیم.

▪ ماژول انتشار

ماژول انتشار برای انتشار اطلاعات بین گره‌ها استفاده می‌شود تا اطلاعات جمع‌آوری شده بتواند هم اطلاعات ویژگی و هم اطلاعات همبندی را کشف کند. در ماژول‌های انتشار، عملگر کانولوشنی و عملگر بازگشتی^۱ به‌طور معمول برای جمع‌آوری اطلاعات از همسایگان استفاده می‌شود درحالی‌که در عملیات اتصال پرش^۲ برای جمع‌آوری اطلاعات از بازنمایی‌های گذشته گره‌ها و حل مشکل هموارسازی بیش‌ازحد^۳ استفاده می‌شود.

▪ ماژول نمونه برداری

برای انجام عمل انتشار در گراف‌های بزرگ، نیاز به ماژول‌های نمونه برداری داریم. به‌طور معمول ماژول نمونه برداری با ماژول انتشار ترکیب می‌شود.

▪ ماژول ادغام

هنگامی که به بازنمایی زیرگراف‌ها یا گراف‌های سطح بالا نیاز داریم، ماژول‌های ادغام برای استخراج اطلاعات از گره‌ها مورد نیاز هستند.

یک لایه شبکه عصبی گرافی معمولاً با ترکیب این اجزا ساخته می‌شود. برای به دست آوردن بازنمایی بهتر از گراف معمولاً تعدادی از این لایه‌ها روی هم چیده می‌شوند. عملگرهای

⁴ spectral

⁵ spatial

⁶ Neural Social Collaborative Ranking(NSCR)

¹ recurrent

² skip connection

³ over-smoothing

می‌یابد. دوم اینکه با ترکیب اطلاعات هر دو دامنه در یک گراف، مفاهیم خاص هر دامنه بر روی یکدیگر تأثیر گذاشته و ممکن است باعث ورود اطلاعات غیرمفید به شبکه عصبی گرافی برای یادگیری روابط بین کاربران و کالاها در دامنه دیگر شود. با استقلال گراف‌های دو دامنه از یکدیگر این اثر مخرب از بین رفته و مدل در سناریوی تک دامنه‌ای می‌تواند به‌طور مؤثرتری روابط کاربر-کالا را فراگرفته و دقیق‌تر عمل کند که خود منجر به بهبود عملکرد در سناریوی دامنه متقابل می‌شود.

در این بخش به تفکیک مراحل و اجزاء مدل پیشنهادی شامل سامانه توصیه‌گر تک دامنه‌ای، نشانش و همچنین انتقال نشانش بین دامنه‌ها تشریح می‌شود.

مرحله اول؛ توصیه‌گر تک دامنه‌ای: در این مرحله گام‌های زیر انجام می‌شود.

▪ کدگذاری ۳ و نشانش

ابتدا شناسه کاربران و کالاها از نوع رشته به اعداد صحیح متوالی تبدیل می‌شود که به آن کدگذاری می‌گویند. سپس برای تبدیل شناسه به دست‌آمده برای کاربران و کالاها به ورودی مناسب برای شبکه، از لایه نشانش استفاده شده است. برای نشانش هر موجودیت (کالا و کاربر) از یک فضای مستقل d_e بعدی استفاده شده است.

▪ ساخت گراف تعاملات

برای ساخت گراف تعاملات در داده‌ها، کاربران و کالاها، گره‌های گراف و تعاملات بین آن‌ها به‌عنوان لبه‌های گراف در نظر گرفته می‌شود. گراف حاصل در این مرحله یک گراف دوبخشی^۳ جهت‌دار خواهد بود. سپس در مرحله بعد برای کشف تعاملات کالا-کاربر گراف تعاملات به یک گراف بدون جهت تبدیل می‌شود.

▪ کدگذاره

برای کشف روابط بین کاربران و کالاها، با استفاده از لایه‌های شبکه عصبی گرافی، کدگذار ساخته می‌شود. سپس لایه‌های پیچش گرافی، گراف ساخته‌شده را پردازش می‌کنند. در این شبکه برای کشف تعاملات کاربران و کالاها و همچنین روابط غیرمستقیم

توصیه‌گر دامنه متقابل مبتنی بر گسترش رابطه^۱ (ReCDR) را پیشنهاد کردند. تفاوت اصلی این روش با [۸] در نحوه مدل‌سازی گراف مشترک است. آن‌ها ابتدا تعبیه گراف را با روش Node2Vec [۱۵] برای ایجاد نشانش گره‌های از پیش آموزش‌دیده برای همه گره‌ها در هر دو دامنه به دست می‌آورند. سپس گره‌هایی با شباهت‌های بالاتر برای ایجاد گراف مشترک به هم متصل می‌شوند. با این‌حال، به دلیل نیاز زیاد به منابع محاسباتی، مقیاس‌پذیری این رویکردها ممکن است محدود باشد.

رویکرد کشف همبستگی‌های جنبه ترجیحات کاربران را چندوجهی فرض می‌کند و هدف آن مدل‌سازی جنبه‌های معنایی دقیق و کاوش در روابط متقابل آن‌ها در دامنه‌ها است. پیش‌بینی میزان امتیاز را می‌توان با تطبیق ویژگی‌های جنبه یک کاربر در یک دامنه و یک کالا در دامنه دیگر انجام داد.

ژائو و همکاران [۱۶] یک چارچوب توصیه‌گر دامنه متقابل را از طریق چارچوب انتقال جنبه^۲ پیشنهاد کردند تا ترجیحات چندوجهی و دقیق کاربران را به تصویر بکشند. آن‌ها ویژگی‌های جنبه را برای کاربران و کالاها از اسناد آن‌ها ایجاد می‌کنند. ویژگی‌های جنبه کاربران مشترک برای شناسایی همبستگی‌های جنبه دامنه متقابل سراسری مورداستفاده قرار می‌گیرد. در بخش بعدی به تشریح مدل پیشنهادی می‌پردازیم.

۳- مدل پیشنهادی

روش ارائه‌شده در این مقاله ترکیبی از رویکرد شبکه عصبی گرافی و رویکرد نشانش و نگاشت است، با این تفاوت که در این روش اطلاعات هر دامنه به‌طور مستقل توسط یک شبکه عصبی گرافی فراگرفته می‌شود و سپس نگاشت نشانش (تبدیل نشانش از دامنه مبدأ به دامنه هدف) انجام می‌شود. این روش دو مزیت دارد. اول این‌که گراف حاصل در هر یک از دامنه‌ها کوچک‌تر از گراف حاصل از اطلاعات هر دو دامنه است و به این صورت مشکل مقیاس‌پذیری در شبکه‌های عصبی گرافی در این روش کاهش

³ encoding

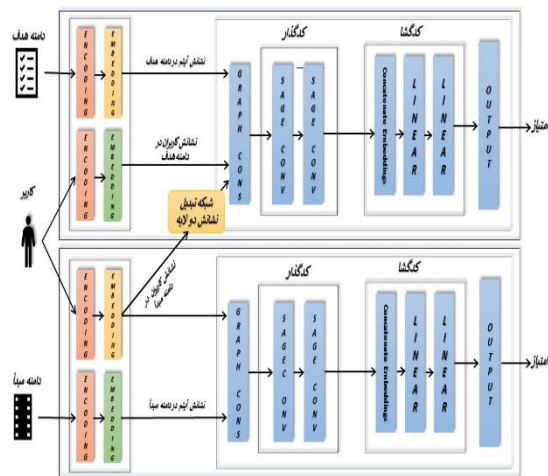
⁴ bipartite

⁵ encoder

¹ Relation Expansion based Cross Domain Recommendation

² Cross-domain recommendation framework via Aspect Transfer Network (CATN)

کاربر در دامنه هدف، کمینه شود. به این نوع آموزش، آموزش وظیفه محور گفته می‌شود. در مقابل آموزش هدف محور یعنی تبدیل نشانش کاربران مشترک از دامنه مبدأ به دامنه هدف به طوری که فاصله بین دو نشانش کمینه شود، آموزش وظیفه محور مزایایی به همراه دارد. اولین مزیت این است که اگر نشانش یک کاربر در دامنه مبدأ به طور مناسبی محاسبه نشده باشد، در این روش اثر مخرب آن بر کارایی نهایی مدل توصیه‌گر دامنه متقابل کمتر از روش هدف محور خواهد بود. دومین مزیت این است که روش یادگیری وظیفه محور نمونه‌های آموزشی بیشتری دارد که می‌تواند از بیش برآزش مدل جلوگیری کند. به عنوان مثال، با تعداد N کاربر مشترک بین دو دامنه که هر کاربر دارای M امتیاز ثبت شده است، روش یادگیری وظیفه محور از $M * N$ رتبه‌بندی کالا-کاربر برای آموزش شبکه تبدیل نشانش استفاده می‌کند که در مقابل، روش آموزش هدف محور تنها از N نمونه آموزشی استفاده خواهد کرد [۷]. پس از آموزش شبکه تبدیل نشانش، می‌توان مدل توسعه یافته را ارزیابی کرد.



شکل (۱): سامانه توصیه‌گر دامنه متقابل

۴- ارزیابی مدل

پس از تشریح اجزاء مدل توصیه‌گر بین دامنه‌ای در بخش قبل، در این بخش مدل پیشنهاد شده ارزیابی شده و عملکرد آن با سایر مدل‌های ارائه شده مقایسه می‌شود.

کاربران و کالاها با یکدیگر از دولایه شبکه عصبی گرافی از نوع SAGE هر یک با ابعاد d_g استفاده شده است. تابع فعال‌سازی^۱ ReLU روی خروجی هر یک از این لایه‌ها اعمال می‌شود. همچنین از تابع میانگین به عنوان تابع تجمیع اطلاعات همسایگان در گره‌ها استفاده شده است.

▪ کدگشا

پس از تبادل اطلاعات بین گره‌های گراف، اطلاعات تجمیع شده توسط کاربران و کالاها با یکدیگر مستقیم با یکدیگر تعامل داشته‌اند به یکدیگر الحاق شده و سپس دولایه FC با تابع فعال‌سازی ReLU روی ویژگی‌های کشف شده توسط لایه‌های شبکه عصبی گرافی اعمال می‌شود. تعداد نورون‌ها استفاده شده در هر لایه d_{fc} در نظر گرفته شده است.

▪ لایه خروجی

لایه خروجی در این شبکه با توجه به داشتن تنها یک خروجی در مجموعه داده (امتیاز)، یک لایه کاملاً متصل با تنها یک نورون است و با توجه به نوع خروجی، این نورون تابع فعال‌سازی نیز ندارد. مدل پیشنهادی شامل اجزاء تشریح شده، برای کشف تعاملات در دامنه‌های مبدأ و هدف به صورت مستقل استفاده شده است و تعاملات موجود در هر دامنه بین کاربران و کالاها توسط یک شبکه جدا کشف شده است.

مرحله دوم؛ تبدیل نشانش از دامنه مبدأ به دامنه هدف: پس از تنظیم نشانش کاربران و کالاها در دامنه‌های مبدأ و هدف، از کاربران مشترک در دو دامنه برای آموزش شبکه تبدیل نشانش، برای تبدیل نشانش کاربران از دامنه مبدأ به دامنه هدف استفاده می‌شود. این شبکه دارای دولایه کاملاً متصل با تابع فعال‌سازی ReLU است. تعداد نورون‌ها در لایه‌های این شبکه به ترتیب برابر ۵۱۲ و ۱۲۸ نورون است.

شمای کلی مدل توصیه‌گر دامنه متقابل پیشنهاد شده همانند شکل ۱ است. پس از آموزش شبکه‌ها در دامنه مبدأ و هدف، هر دو شبکه از حالت قابل آموزش به حالت غیرقابل آموزش تبدیل می‌شوند. سپس نشانش کاربر در دامنه مبدأ توسط شبکه تبدیل نشانش به گونه‌ای محاسبه می‌شود که محاسبه مقدار امتیاز ثبت شده توسط

² decoder

¹ activation function

به‌عنوان مجموعه داده ارزیابی کنار گذاشته شده است. نتایج حاصل از انجام آزمایش‌ها در جدول ۳ ارائه شده است.

جدول (۳): نتایج حاصل از توصیه‌گر تک دامنه‌ای

دامنه	معیارهای ارزیابی	آموزش	ارزیابی
کتاب	MAE	۰,۵۸	۰,۶۳
	RMSE	۰,۸۸	۰,۹۴
فیلم	MAE	۰,۶۰	۰,۷۰
	RMSE	۰,۹۵	۱,۰۴
موسیقی	MAE	۰,۵۳	۰,۶۳
	RMSE	۰,۸۸	۰,۹۷

۴-۱ مقایسه با سایر مدل‌ها

عملکرد مدل پیشنهادی در مقایسه با مدل‌های مورد مقایسه در دامنه‌های مختلف در جدول ۴ آورده شده است. روش CDLFM [۵] یک رویکرد مبتنی بر نشان و نگاشت است که در آن مقادیر شباهت کاربران به‌عنوان محدودیت در فرآیند تجزیه ماتریس استفاده شده است. روش PTUPCDR [۷] نیز یک رویکرد مبتنی بر نشان و نگاشت است که اهمیت کالاهای مختلف را در انتقال نشان کاربر از دامنه مبدأ به دامنه هدف در نظر می‌گیرد.

همان‌طور که در جدول ۴ مشخص است برای سامانه دامنه متقابل که در آن دامنه مبدأ فیلم و دامنه هدف کتاب است روش پیشنهادی برحسب معیار MAE دارای مقدار خطای کمتری و برحسب معیار دوم، یعنی RMSE دارای مقدار خطایی نزدیک به روش مورد مقایسه یعنی CDLFM است. برای سامانه دامنه متقابل که در آن دامنه مبدأ فیلم و دامنه هدف موسیقی است روش پیشنهادی برای هر دو معیار MAE و RMSE دارای مقادیر خطای کمتری نسبت به روش مورد مقایسه یعنی PTUPCDR است که به‌منزله عملکرد بهتر روش پیشنهادی است. بنابراین نتایج به‌دست‌آمده نشان می‌دهند که مدل پیشنهادی (GCDRS) دارای عملکرد بهتری نسبت به روش‌های مورد مقایسه است.

با توجه به پژوهش‌های موجود [۵] و [۷]، در این مقاله نیز از مجموعه داده Amazon-5scores [۱۷] که یک مجموعه داده عمومی در دنیای واقعی است برای ارزیابی مدل پیشنهادی در این مقاله استفاده می‌شود. در مجموعه داده Amazon-5scores هر کاربر یا کالا حداقل دارای پنج رتبه‌بندی است. در جدول ۱ اطلاعات آماری دامنه‌های کتاب، فیلم و موسیقی ذکر شده است. تعداد کاربران مشترک در دو دامنه کتاب و فیلم برابر ۳۷۳۸۸ کاربر و در دو دامنه فیلم و موسیقی برابر ۱۸۰۳۱ کاربر است.

در این مقاله برای ارزیابی مدل پیشنهادی از معیار میانگین خطای مطلق^۱ (MAE) و ریشه میانگین مربعات خطا^۲ (RMSE) استفاده شده است که طبق روابط زیر محاسبه می‌شوند.

$$MAE = \frac{\sum_{n=1}^N |y_i - \bar{y}_i|}{N} \quad (1)$$

$$RSME = \sqrt{\frac{\sum_{n=1}^N |y_i - \bar{y}_i|^2}{N}} \quad (2)$$

در روابط ۱ و ۲، N تعداد نمونه‌ها، y_i مقدار امتیاز ثبت شده توسط کاربر برای کالا \bar{y}_i خروجی تخمین زده شده توسط شبکه برای امتیاز کاربر به کالا است.

برای تعیین مقدار پارامترها مقادیر مختلفی برای بهترین عملکرد شبکه آزمایش شده است که مقدار آن‌ها مطابق جدول ۲ است.

جدول (۱): اطلاعات آماری مجموعه داده‌های مبدأ و هدف

دامنه	تعداد کاربران	تعداد کالاها	تعداد تعاملات
کتاب	۶۰۳۶۶۸	۳۶۷۹۸۲	۸۸۴۸۰۴۱
فیلم	۱۲۳۹۶۰	۵۰۰۵۲	۱۶۹۷۵۳۳
موسیقی	۷۵۲۵۸	۶۴۴۴۳	۱۰۹۷۵۹۲

جدول (۲): مقادیر پارامترهای شبکه

پارامتر	مقدار
d_e	۱۲۸
d_g	۶۴
d_{FC}	۱۲۸

مدل‌ها در دامنه مبدأ و هدف با استفاده از بهینه‌ساز Adam با نرخ یادگیری ۰,۰۰۵ آموزش دیده‌اند. در هر دامنه ۵ درصد از تعاملات

² Root Mean Squard Error(RMSE)

¹ Mean Absolute Error(MAE)



- AAAI 2016, pp. 13–19, 2016, doi: 10.1609/AAAI.V30I1.10001.
- [3] F. Zhu, C. Chen, Y. Wang, G. Liu, and X. Zheng, “DTCDR: A framework for dual-target cross-domain recommendation,” International Conference on Information and Knowledge Management, Proceedings, pp. 1533–1542, Nov. 2019, doi: 10.1145/3357384.3357992.
- [4] T. Man, H. Shen, X. Jin, and X. Cheng, “Cross-domain recommendation: An embedding and mapping approach,” IJCAI International Joint Conference on Artificial Intelligence, vol. 0, pp. 2464–2470, 2017, doi: 10.24963/IJCAI.2017/343.
- [5] X. Wang, Z. Peng, S. Wang, P. S. Yu, W. Fu, and X. Hong, “Cross-Domain Recommendation for Cold-Start Users via Neighborhood Based Feature Mapping,” Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), vol. 10827 LNCS, pp. 158–165, Mar. 2018, doi: 10.1007/978-3-319-91452-7_11.
- [6] Y. Zhu et al., “Transfer-Meta Framework for Cross-domain Recommendation to Cold-Start Users,” SIGIR 2021 - Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, pp. 1813–1817, May 2021, doi: 10.1145/3404835.3463010.
- [7] Y. Zhu et al., “Personalized Transfer of User Preferences for Cross-domain Recommendation,” WSDM 2022 - Proceedings of the 15th ACM International Conference on Web Search and Data Mining, pp. 1507–1515, Oct. 2021, doi: 10.1145/3488560.3498392.
- [8] Kang S, Hwang J, Lee D, Yu H. Semi-supervised learning for cross-domain recommendation to cold-start users. In Proceedings of the 28th ACM international conference on information and knowledge management 2019 Nov 3 (pp. 1563-1572).
- [9] Khazaei M, Ashrafi-Payaman N. An Unsupervised Anomaly Detection Model for Weighted Heterogeneous Graph. Journal of AI and Data Mining. 2023 Apr 1;11(2):237-45.
- [10] Shuman DI, Narang SK, Frossard P, Ortega A, Vandergheynst P. The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains. IEEE signal processing magazine. 2013 Apr 5;30(3):83-98.
- [11] Hamilton W, Ying Z, Leskovec J. Inductive representation learning on large graphs. Advances

جدول (۴): مقایسه عملکرد مدل پیشنهادی با سایر مدل‌ها

RMSE	MAE	روش	دامنه هدف	دامنه مبدأ
۰٫۹۵>	۰٫۷۵>	CDLFM	کتاب	فیلم
۱٫۰۲	۰٫۷۳	GCDRS		
۱٫۵۱	۱٫۱۵	PTUPCDR	موسیقی	فیلم
۱٫۰۳	۰٫۶۸	GCDRS		

۵- نتیجه و جمع بندی

در این پژوهش مدلی برای غلبه بر چالش کاربران آغاز سرد ارائه شد. با توجه به نقاط قوت شبکه‌های عصبی گرافی در یادگیری ساختار گراف و ماهیت داده‌ها در زمینه سامانه‌های توصیه‌گر، مدل پیشنهادی در این پژوهش مبتنی بر شبکه‌های عصبی گرافی بود. در ادامه نتایج حاصل از آموزش مدل در سناریوهای مختلف، موفقیت این شبکه در یادگیری نمایش مؤثر کاربران و کالاها را نشان داده و مقدار خطای به‌دست‌آمده از این مدل در مقایسه با سایر مدل‌ها کمتر بود که عملکرد بهتر این مدل در مقایسه با سایر مدل‌ها را نشان می‌دهد.

برای بهبود نتایج حاصل از این پژوهش، در کارهای بعدی می‌توان از دیگر اطلاعات موجود در داده‌ها نظیر نظرات ثبت‌شده توسط کاربران برای بهبود نمایش کاربران در دامنه‌های مبدأ و هدف استفاده کرد که خود منجر به کاهش مقدار خطا برای تخمین مقدار امتیاز ثبت‌شده برای کالاها در سناریوی تک دامنه‌ای می‌شود. روش‌های مختلفی برای انتقال نمایش کاربران از دامنه مبدأ به دامنه هدف وجود دارد. برای کمتر کردن میزان خطای توصیه‌گر دامنه متقابل، ضمن بررسی این روش‌ها باید روشی انتخاب کرد که انتقال نوین آن از دامنه مبدأ به دامنه هدف کمینه باشد.

References

- [۱] محمدی، سید علی و عندلیب، اعظم، ۱۳۹۵، سیستم‌های توصیه گر و چالش شروع سرد: بررسی راه‌کارها، اولین کنفرانس ملی مهندسی کامپیوتر، علوم کامپیوتر و فناوری اطلاعات، قم
- [2] M. Jiang, P. Cui, N. J. Yuan, X. Xie, and S. Yang, “Little Is Much: Bridging Cross-Platform Behaviors through Overlapped Crowds,” 30th AAAI Conference on Artificial Intelligence,



- in neural information processing systems. 2017;30.
- [12] X. Wang, X. He, L. Nie, and T.-S. Chua, "Item Silk Road: Recommending Items from Information Domains to Social Users," SIGIR 2017 - Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval, pp. 185–194, Jun. 2017, doi: 10.1145/3077136.3080771.
- [13] Q. Cui, T. Wei, Y. Zhang, and Q. Zhang, "HeroGRAPH: A Heterogeneous Graph Framework for Multi-Target Cross-Domain Recommendation," ORSUM@RecSys, 2020.
- [14] Xu K, Xie Y, Chen L, Zheng Z. Expanding relationship for cross domain recommendation. In Proceedings of the 30th ACM International Conference on Information & Knowledge Management 2021 Oct 26 (pp. 2251-2260).
- [15] Grover A, Leskovec J. node2vec: Scalable feature learning for networks. In Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining 2016 Aug 13 (pp. 855-864).
- [16] C. Zhao, C. Li, R. Xiao, H. Deng, and A. Sun, "CATN: Cross-Domain Recommendation for Cold-Start Users via Aspect Transfer Network," SIGIR 2020 - Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, pp. 229–238, May 2020, doi: 10.1145/3397271.3401169.
- [17] <https://cseweb.ucsd.edu/~jmcauley/datasets/amazon/links.html>

A Recommender System Based On Graph Neural Networks And Using Cross Domain Approach For Solving Cold Start Problem

Sahar Akhzari¹, Nosratali Ashrafi-Payaman^{2*}

MSc. of Artificial Intelligence, Department of Electrical and Computer Engineering, Kharazmi University, Tehran, Iran.

Professor Assistant, Department of Electrical and Computer Engineering, Kharazmi University, Tehran, Iran.

Article Information

Original Research Paper

Received:

2024 May 30

Accepted:

2024 August 21

Keywords:

recommendation systems, cross domain recommender systems, neural network, cold start

Corresponding Author*:

ashrafi@khu.ac.ir

Abstract

Today, the amount and importance of data available on the Internet is increasing exponentially, so choosing a suitable option from among many options can be tiring and time-consuming. The goal of recommendation systems is to facilitate this process by finding the right items that are of most interest to users. Existing recommendation systems suffer from common problems such as data sparsity, cold start, and new user problems. In this article, the main focus is on using information from other domains to create cross-domain recommendation systems. The proposed cross-domain systems can manage cold start situations and new users. In this article, first, a model based on convolutional graph neural networks discovers the interaction pattern of users and items in each domain independently, and in the next step, a neural network is used to transfer representation for cold-start users from the source domain to the target domain. The results show that the proposed model has a better performance compared to other proposed models for estimating the recorded score for the items.



: 10.22034/ABMIR.2024.21697.1055

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2024.21697.1055) 2023. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

