

یک مدل یادگیری متضاد برای توصیه های متوالی آگاهانه اجتماعی

محمدامین عنایتی^۱، علی هارون آبادی^۲

^۱موسسه عالی جهاد دانشگاهی استان خوزستان، اهواز Enayati2013@Gmail.com

^۲استادیار دانشگاه آزاد اسلامی واحد علوم تحقیقات، a.harounabadi@gmail.com

چکیده

توصیه متوالی یک وظیفه‌ی مهم در سیستم توصیه‌گر است که تاریخچه‌ی ای از رفتار کاربران را برای یادگیری تغییرات پویا، علائق کاربران و پیش‌بینی رفتار بعدی کاربر مدل می‌کند. رویکردهای کنونی عمدتاً بر روی مدل‌سازی متوالی رفتار قبلی کاربران تمرکز کرده و دارای آگاهی اجتماعی نیستند، بدین معنی که اطلاعات اجتماعی کاربران را نادیده می‌گیرند. در همین حال، به دلیل تصادفی بودن و تنوع بالای رفتار کاربران، بسیاری از رویکردها به راحتی تحت تأثیر نویز قرار گرفته و ممکن است علائق واقعی کاربران را در نظر نگیرد. برای مقابله با مشکلات فوق، ما مدل جدیدی به نام یادگیری متضاد برای توصیه‌های متوالی آگاهانه اجتماعی (CLSSR) معرفی می‌کنیم که به دو ماژول ۱- ماژول یادگیری متضاد و شبکه پیچشی گراف تقسیم بندی می‌شود. به طور خاص، یک مکانیسم یادگیری خود نظارتی جدید ابداع شده تا با جایگزین نمودن یک مورد با یکی از همسایگان تعاملی در شبکه اجتماعی، بازنمایی کاربر را افزایش دهد. علاوه بر این، از شبکه پیچشی گراف برای جمع‌آوری اطلاعات اجتماعی کاربران در شبکه اجتماعی استفاده می‌شود. پس از آزمایش‌های متمرکزی که روی دو مجموعه داده واقعی انجام شد، مدل CLSSR عملکرد بهتری را نسبت به مدل‌های پیشرفته نشان می‌دهد. این تحقیق نقش یادگیری متضاد را در استفاده از اطلاعات شبکه اجتماعی برای بهبود اثر توصیه‌های متوالی نشان می‌دهد.

واژه‌های کلیدی

توصیه متوالی، یادگیری متضاد، یادگیری خود نظارتی، شبکه‌های پیچشی گراف، شبکه اجتماعی

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

۱- مقدمه

از سیستم‌های توصیه‌گر به عنوان یکی از ارکان پایین‌دستی در داده‌کاوی و یادگیری ماشین استفاده شده است. خواه یک پلتفرم تجارت الکترونیک و یا یک پلتفرم موسیقی باشد؛ آنها باید ترجیحات کاربران را با پشتیبانی ضروری سیستم توصیه جمع‌آوری کنند. سیستم توصیه‌گر با توجه به رفتار قبلی کاربران توصیه‌هایی را به آنها ارائه می‌دهد. سیستم‌های توصیه‌گر سنتی در درجه اول، با نادیده گرفتن این مهم که تعامل بین کاربران و اقلام متوالی و پویا است، از داده‌های ثابتی (ایستا) استفاده می‌کردند. به عنوان مثال در پلتفرم تجارت الکترونیک، اگر کاربری یک کت و یک شلوار جین را پشت سر هم خریداری کند، احتمالاً کالای بعدی که کاربر قصد خرید آن را داشته یک جفت چکمه برای تکمیل ست کردن لباسش است. رفتار تعاملی کاربران دارای نظامی منطقی بوده لذا برای حل چنین مسائلی، روش‌های توصیه‌های متوالی ارائه شده که امروزه توجه اغلب محققین را به خود جلب نموده است. توصیه متوالی که به عنوان توصیه بعدی نیز شناخته می‌شود، به پیش‌بینی مواردی اشاره دارد که کاربر ممکن است در مرحله بعدی با آنها تعامل داشته باشد. مشکل کلیدی توصیه‌های متوالی این است که چگونه می‌توان یک توالی از تعامل گذشته کاربر را با کیفیت بالا یاد گرفته تا موارد دقیق و شخصی شده را توصیه نماید. در ابتدا، مدل‌های سنتی بیشتر بر اساس زنجیره مارکوف [۵] (MC)، [۶]، [۷] بودند. در سال‌های اخیر و با توسعه یادگیری عمیق، بسیاری از مدل‌های مبتنی بر شبکه‌های عصبی بازگشتی (RNN) [۸]، [۹]، [۱۰]، شبکه‌های پیچشی عصبی (CNN) [۱۱]، [۱۲]، [۱۳]، شبکه‌های پیچشی گراف [14] (GNN)، [۱۵]، [۱۶] و مکانیسم خود نظارتی [۱۷]، [۱۸]، [۱۹] پیشنهاد شده است. آنها می‌توانند الگوهای تبدیل پیچیده نهفته در توالی‌های گذشته کاربران را ثبت کرده، ترجیحات کاربر را استخراج نموده و به نتایج خوبی دست یابند.

اگرچه پیشرفت‌های زیادی در توصیه‌های متوالی صورت گرفته است، اما هنوز دو مشکل زیر وجود دارد. اول، پژوهش فعلی در مورد توصیه‌های متوالی بر روی استخراج توالی‌های تعامل گذشته کاربر تمرکز دارد؛ این در حالی است که تأثیر شبکه‌های اجتماعی در بین کاربران را نادیده می‌گیرد. در سناریوهای عملی، دوستان اغلب به طور مستقیم یا غیرمستقیم بر انتخاب آیتم‌های کاربران تأثیر می‌گذارند، بنابراین توصیه‌های متوالی آگاهانه اجتماعی در حال تبدیل شدن به یک موضوع چالش برانگیز است. دوم، به دلیل تصادفی بودن و تنوع در رفتارهای کاربران، اغلب داده‌های تداخلی در توالی تعاملی بین کاربران و آیتم‌ها که نمی‌تواند منعکس‌کننده‌ی علائق اساسی کاربران باشد، وجود دارند. بنابراین، تأثیر منفی آنها باید کاهش یابد تا کیفیت ارائه به کاربران بهبود یابد.

به منظور حل مشکلات فوق، یک مکانیسم یادگیری خود نظارتی جدید برای تقویت یادگیری بازنمایی کاربر ابداع شده است. ایده اصلی این بوده که آیتم‌های (موارد) تعاملی همسایگان کاربر در شبکه اجتماعی را برای جایگزینی موارد به ترتیب انتخاب و از یادگیری متضاد برای محاسبه ضرر (تابع loss) استفاده کنید. علاوه بر این، برای در نظر گرفتن تأثیر شبکه‌های اجتماعی بر رفتار کاربر، بازنمایی کاربر با استفاده از GNN قبل از توصیه جمع‌آوری و در بین شبکه اجتماعی منتشر می‌شود. کلیت این مقاله به شرح زیر است.

- ما یک مدل جدید، یعنی یادگیری متضاد برای توصیه‌های متوالی آگاه اجتماعی (CLSSR) پیشنهاد می‌کنیم. تا آنجا که می‌دانیم، این اولین کاری است که هم‌زمان از یادگیری متضاد و اطلاعات شبکه‌های اجتماعی در توصیه‌های متوالی استفاده شود.
- ما یک مکانیسم یادگیری خود نظارت جدید را پیشنهاد کرده تا با جایگزین کردن مورد با یکی از همسایگان تعاملی در شبکه اجتماعی، بازنمایی کاربر را افزایش دهیم.
- آزمایش‌های گسترده‌ای روی دو مجموعه داده دنیای واقعی، یعنی Last-fm و Epinions انجام می‌شود، و نتایج اثربخشی رویکرد پیشنهادی ما را نشان می‌دهد. بقیه مقاله به شرح زیر سازماندهی شده است. در بخش ۲، کارهای مرتبط بررسی شده است. مدل پیشنهادی ما یعنی CLSSR در بخش ۳ آورده شده است. سپس آزمایش‌های گسترده انجام که نتایج در بخش ۴ تجزیه و تحلیل می‌شوند. در نهایت، یافته‌ها تحقیق در بخش ۵ نتیجه‌گیری می‌شوند.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

۲- کارهای مرتبط

۲-۱- توصیه متوالی

کارهای اولیه روی توصیه‌های متوالی معمولاً تعاملات گذشته کاربران را با استفاده از زنجیره مارکوف مدل کرده و از تجزیه ماتریس برای به دست آوردن ترجیحات کاربران استفاده می‌کردند [۵]. بر این اساس، مطالعات اخیر نشان داده که توصیه‌های شخصی شده را می‌توان با روش‌های مبتنی بر شباهت نیز ادغام کرد که عملکرد کلی را بهبود می‌بخشد [۶]، [۷]. علاوه بر این، برخی از مدل‌های توصیه متوالی مبتنی بر رتبه‌بندی شخصی بیزی (BPR) [۲۰] نیز وجود داشته که نتایج خوبی در توصیه‌های مکانی و کالا دارند [۲۱]، [۲۲]. در سال‌های اخیر، با توسعه یادگیری عمیق، RNN و انواع آن، مانند شبکه عصبی با حافظه کوتاه مدت حافظه کوتاه مدت طولانی (LSTM) [۲۳] و شبکه عصبی بازگشتی (گیتی) دروازه‌ای (GRU) [۲۴] پیشنهاد شده و به طور گسترده مورد استفاده قرار گرفته‌اند. از آنجایی که RNN برای مقابله با داده‌های متوالی طراحی شده است، می‌توان آن را مستقیماً در کار توصیه متوالی اعمال کرد. به عنوان مثال، هیداسی و همکاران [۸] رکوردهای قبلی کاربر را در یک برداری رمزگذاری کرده و آن را در یک GRU چند لایه قرار داده و سپس آنها از یک لایه کاملاً متصل استفاده می‌کنند که احتمال تعامل با کاربران مختلف را در مرحله‌ی بعدی وجود دارد. تان و همکاران [۹] همچنین دریافته‌اند که بهبود اثربخشی مدل توصیه متوالی مبتنی بر RNN با در نظر گرفتن تغییر رفتار کاربر یا اتخاذ یک روش مناسب افزایش داده معتبر است.

یو و همکاران [۲۵] مدل DREAM را پیشنهاد می‌کنند، که می‌تواند ویژگی‌های پویای کاربر و نیز الگوهای جهانی را در دنباله ای ثبت کنند. در همین حال، با توسعه RNN، مدل‌های پیشنهادی متوالی زیادی بر اساس تغییرات RNN وجود دارد که شامل یکپارچه‌سازی اطلاعات بصری [۲۶]، [۲۷]، اعمال رمزگذاری خودکار متغیر (VAE) به شبکه [۲۸] و افزودن مکانیسم توجه می‌شود. [۲۹]، [۳۰]، [۳۱]، [۳۲].

همچنین برخی از مدل‌های توصیه متوالی بر اساس CNN وجود دارند. آنها معمولاً تعامل توالی را در ماتریسی که به عنوان تصویر در نظر گرفته می‌شود برای استخراج ویژگی‌ها جاسازی می‌کنند. به عنوان مثال تانگ و همکاران [۱۱]، سعی کرده اند تا از فیلترهای پیچیدگی گوناگون در سطوح مختلف استفاده و الگوهای متوالی را به طور همزمان در سه سطح مختلف استخراج کنند. آنها همچنین ترجیحات عمومی کاربران را در نظر می‌گیرند و مدلی به نام Caser را پیشنهاد می‌کنند. به منظور حل مشکل دور انداختن که Caser هنگام پردازش دنباله‌های طولانی با آن مواجه می‌شود، یوان و همکاران [۱۲] فیلتر عریض را با لایه کانولوشن انباشته شده‌ی یک‌بعدی جایگزین کرده و از روش یادگیری باقیمانده استفاده کردند. مدل NextItNet پیشنهادی آنها می‌تواند نتایج خوبی در پردازش داده‌های متوالی در مقیاس بزرگ به دست آورد. یوان و همکاران [۱۳] از ساختار رمزگذاری تجارب بیشتری گرفته و توصیه‌گری مبتنی بر پرکننده‌ی شکاف (GRec) را پیشنهاد می‌کنند که می‌تواند از عملکرد کلی کاربر آگاه باشد.

با پیشنهاد مکانیسم خود نگرشی [۳۳]، مدل توصیه متوالی دور جدیدی از پیشرفت‌ها را آغاز کرده است. مکانیسم توجه به خود می‌تواند جذب نیات و ترجیحات کاربران را بهبود بخشد. به عنوان مثال، کانگ و همکاران [۱۷] مدلی به نام SASRec را برای توصیه متوالی طراحی کرده که بر اساس ساختار رمزگذاری ترانسفورماتور [۳۳] است و نسبت به مدل‌های قبلی پیشرفت قابل توجهی دارد. سان و همکاران [۱۸] از مدل BERT [۳۴] در پردازش زبان طبیعی (NLP) درس گرفته و مدل BERT4Rec را پیشنهاد می‌کنند. مکانیزم خود نگرشی دو طرفه، برای رمزگذاری توالی از گذشته کاربر اتخاذ شده است. Wu و همکاران [۳۵] یادگیری شخصی سازی شده را بر اساس SASRec اضافه و یک تکنیک منظم سازی جدید، یعنی جاسازی‌های مشترک تصادفی (SSE) را برای بهبود اثر مدل ارائه می‌دهد. Xu و همکاران [۳۶] یک شبکه جدید خود نگرش را پیشنهاد کرده که می‌تواند نیازهای کوتاه مدت و علائق بلند مدت کاربر را ترکیب و چارچوب جدیدی به نام LSSA ایجاد کند.

۲-۲- گراف شبکه‌های عصبی

GNN نوعی مدل شبکه عصبی است که برای داده‌هایی با ساختار گراف مناسب است. از زمان ارائه این مدل، کاربردهای زیادی در شبکه‌های اجتماعی، گراف‌های دانش و سیستم‌های توصیه‌گر داشته است. مدل‌های GNN عمدتاً به سه سری تقسیم می‌شوند که به ترتیب با GCN [۳۷]، GAT [۳۸] و GraphSAGE [۳۹] نشان داده می‌شوند. به طور خاص، GCN اولین مدلی است که ویژگی‌های ساختاری

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

در گراف را با استفاده از پیچیدگی ترکیب می‌کند، اما دو مشکل دارد. یکی اینکه وزن لبه‌ها را نمی‌توان به صورت پویا در فرآیند ادغام تنظیم کرد و دیگری اینکه به دلیل استفاده از پیچیدگی کامل گراف، سرعت بروز رسانی در هنگام برخورد با گراف‌های با مقیاس بزرگ کند است.

برای پرداختن به مشکل اول، GAT مکانیسم توجه را به شبکه عصبی گراف اعمال می‌کند که مدل را تطبیق‌پذیرتر می‌کند. برای حل مشکل دوم، گراف SAGE از نمونه‌گیری تصادفی زیرگراف برای دستیابی به کارایی بالا در پردازش گراف‌های مقیاس بزرگ استفاده می‌کند.

در زمینه توصیه می‌توان کاربردهای شبکه‌های عصبی گراف را به دو دسته تقسیم کرد. یک رویکرد از رابطه و تعامل بین کاربران و آیتم‌ها برای ایجاد یک GNN، اطلاعات همسایگی‌ها را جمع‌آوری می‌کند [۴۰]، [۴۱]، [۴۲]. به عنوان مثال، فن و همکاران [۴۰] گراف کاربر-کاربر را با گراف کاربر مورد ادغام کرده و مدل GraphRec را پیشنهاد می‌کنند. Yu و همکاران [۴۱] رمزگذار خودکار مبتنی بر GCN را پیشنهاد کرده و یادگیری خصمانه در این مدل برای بهبود (ارتقای) کیفیت توصیه را پذیرفتند. این نوع روش در حوزه پژوهشی، توصیه اجتماعی است.

رویکرد دیگر اغلب در توصیه‌های مبتنی بر جلسه استفاده می‌شود. این مدل دنباله تعامل کاربر را به ترتیب زمانی به چند دنباله کوتاه تقسیم می‌کند و هر دنباله را به عنوان یک نشست در نظر می‌گیرد. GNN برای تجمیع اطلاعات همسایگی با ساختن یک شبکه (لایه) نشست [۱۴]، [۱۵]، [۱۶] استفاده می‌شود. علاوه بر این، وانگ و همکاران [۴۳] سعی کرده سطح فعلی جاسازی آیتم‌ها را از نمودارهای جلسه یاد بگیرند و سطح سراسری جاسازی‌ها را از گراف‌های سراسری بگیرند. سپس چارچوبی به نام GCE-GNN را پیشنهاد می‌کنند. وانگ و همکاران [۴۴] مزایای شبکه عصبی گراف و شبکه حافظه کلید-مقدار را تجزیه و تحلیل کرده و آنها را برای به دست آوردن اولویت فعلی و جهانی کاربر ترکیب می‌کنند.

اگرچه رویکردهای ذکر شده در بالا شروع به استفاده کردن از پیچیدگی گراف در وظایف پیشنهادی کرده‌اند، مدل‌های کمی از GNN برای جمع‌آوری اطلاعات اجتماعی در وظایف پیشنهادی متوالی استفاده می‌کنند.

۲-۳- یادگیری متضاد

یادگیری متضاد یک کار یادگیری تحت نظارت شخصی به صورت خاص (ویژه) است. این مدل یادگیری، از زمان ارائه آن در زمینه‌های مختلف تحقیقاتی مورد توجه قرار گرفته است. ایده اصلی یادگیری متضاد این است که نمونه‌های مشابه را در فضای تصویر نزدیک و نمونه‌های غیرمشابه را دورتر در فضای تصویر قرار دهیم.

یادگیری متضاد اولین بار در بینایی کامپیوتری (بینایی ماشین) مورد استفاده قرار گرفت. به عنوان مثال، He و همکاران [۴۵] مدل MoCo را با استفاده از یک صف برای ذخیره‌سازی پویای نمونه‌های منفی و تابع loss متضاد برای یادگیری ویژگی‌ها پیشنهاد می‌کند. Chen و همکاران [۴۶] ساختار و عملکرد فعال‌سازی مدل MoCo را دقیق تنظیم کرده و مدل MoCo v2 را پیشنهاد می‌کنند که تأثیر بهتری نسبت به مدل MoCo دارد. Chen و همکاران [۴۷]، [۴۸] جفت‌های مثبت و منفی را با کاوش در روش‌های مختلف افزایش داده، مانند برش و ورق زدن ایجاد می‌کنند. آنها به‌طور متوالی مدل‌های SimCLR و SimCLR v2 را پیشنهاد می‌کنند که عملکرد خوبی برای بازنمایی‌های یادگیری دارند. زمانی که صحبت از وظایف سیستم‌های توصیه‌گر می‌شود، مدل‌هایی وجود دارند که از یادگیری خود نظارتی برای بهبود عملکرد این سیستم‌ها استفاده می‌کنند [۴۹]، [۵۰]، [۵۱]، [۵۲]. چندین مدل یادگیری متضاد به طور آزمایشی برای بهبود اثربخشی توصیه پیشنهاد شده است. به عنوان مثال، Liu و همکاران [۵۳] برای یادگیری نمایش کاربر و آیتم به شیوه‌ای خود نظارت، یک مدل تحت تأثیر واقع نشده متضاد کلی (عمومی) طراحی کردند. بر اساس ایده SimCLR، Xie و همکاران [۵۴] چهار روش افزایش داده را برای توصیه‌های متوالی طراحی کرده و تابع loss را بیشتر محاسبه می‌کند. Qin و همکاران [۵۵] یک فرآیند یادگیری متضاد با هدایت anchor را به منظور حل مشکل حذف نویز در سیستم توصیه‌گر طراحی کردند. از مدل‌های ذکر شده در بخش‌های فوق‌الذکر، تلاش زیادی برای استفاده از یادگیری خود نظارتی برای افزایش بازنمایی کاربر انجام شده است. با این حال، تعداد کمی از رویکردها آیتم‌ها (موارد) تداخلی را به صورت مانوس در نظر می‌گیرند. این مطالعه یک مکانیسم یادگیری متضاد جدید را با جایگزینی آیتم با یکی از همسایگان تعاملی در شبکه اجتماعی پیشنهاد می‌کند. به این ترتیب، می‌توانیم تأثیر منفی موارد تعامل فردی را که توسط دوستان تحت تأثیر قرار می‌گیرند کاهش داده تا علاقه‌ی واقعی کاربران را جلب کنیم.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of the New Technologies in Sustainable Development of Iran

senaconf.ir

۳- مدل پیشنهادی

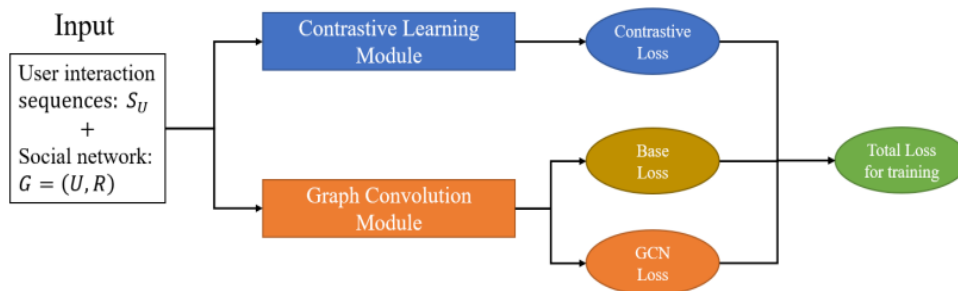
۳-۱- فرمول سازی مساله

بباید $U = \{u_1, u_2, u_3, \dots, u_{|U|}\}$ و $V = \{v_1, v_2, v_3, \dots, v_{|V|}\}$ که مجموعه‌ای از کاربران و مجموعه آیت‌ها را نشان می‌دهند در نظر بگیریم که در آن‌ها $|U|$ و $|V|$ به ترتیب تعداد کل کاربران و آیت‌ها هستند. باید $G = (U, R)$ که نشان دهنده شبکه اجتماعی در بین کاربران است، به طوری که R نشان دهنده مجموعه روابط در شبکه اجتماعی است و $|S^u|$ که مجموعه توالی‌های تعامل کاربران را نشان می‌دهد، در نظر بگیریم. دنباله تعامل کاربر u با $[v_1^u, v_2^u, v_3^u, \dots, v_i^u, \dots, v_{|S^u|}^u]$ نشان دهنده تاریخچه طول تعاملات برای کاربر u و v_i^u نشان دهنده آیتی است که کاربر u با آن در مرحله زمانی i تعامل دارد. در مورد هدف توصیه متوالی، هدف آن محاسبه بیشترین آیت ممکن است $v_{|S^u|+1}^u$ که کاربر u در مرحله زمانی با آن تعامل خواهد داشت و $|S^u| + 1$. با فرمول ریاضی به صورت زیر قابل بیان است.

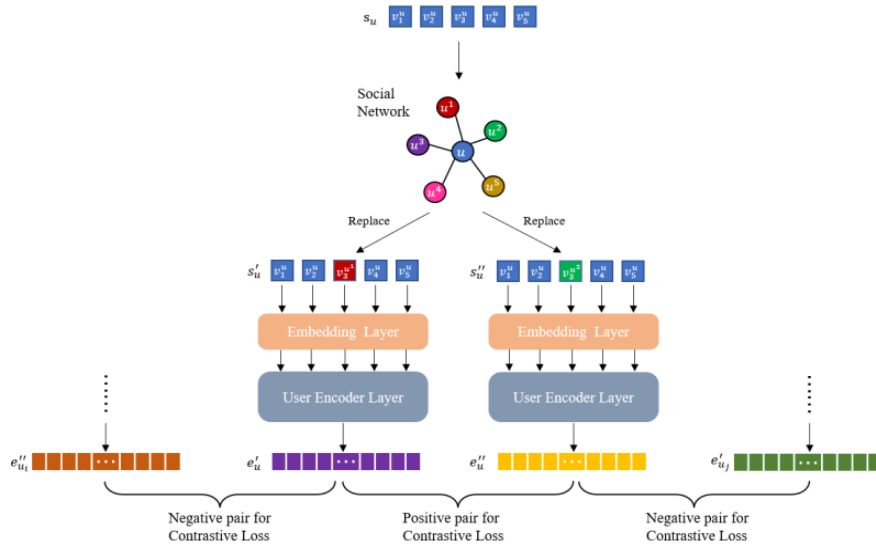
$$\arg \max_{v_i \in V} P(v_{|S^u|+1}^u = v_i | S^u). \quad (1)$$

۳-۲- مدل CLSSR

همانطور که در شکل ۱ نشان داده شده است، مدل CLSSR پیشنهاد شده در این مقاله به دو ماژول تقسیم می‌شود: ماژول یادگیری متضاد و ماژول گراف پیچیدگی. علاوه بر این، ساختارهای ماژول یادگیری متضاد و ماژول گراف پیچیدگی به ترتیب در شکل ۲ و ۳ نشان داده شده است. برای راحتی، طول دنباله بر روی ۵ تنظیم شده است، همان اثر مشابه. لایه جاسازی و لایه رمزگذار (انکودر) کاربر در این مدل، پارامترهای یکسانی دارند.



شکل ۱. چارچوب اصلی مدل CLSSR.

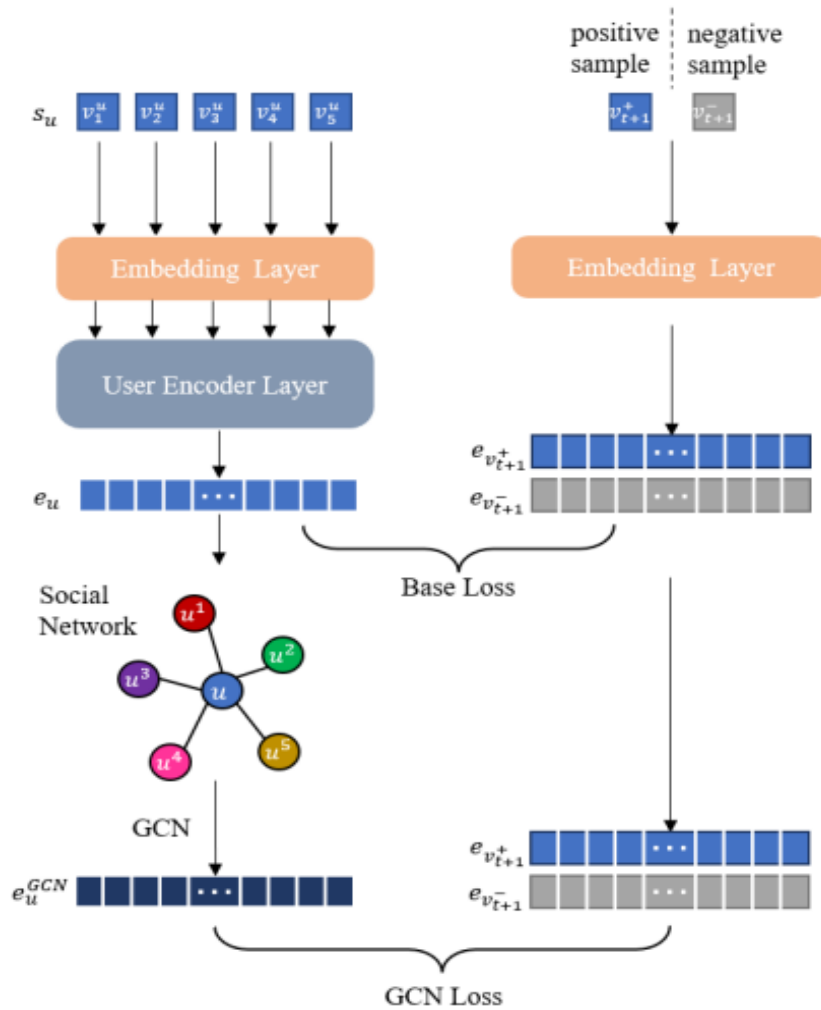


شکل ۲. ساختار ماژول یادگیری متضاد.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir



شکل ۳. ساختار مازول گراف پیچیدگی.

۳-۲-۱- مازول یادگیری متضاد

همانطور که در شکل ۲ نشان داده شده است، برای هر دنباله تعامل کاربر s_u در مجموعه داده، آیمتی را انتخاب می‌کنیم که همسایه‌ی کاربر، در شبکه اجتماعی با آن تعامل داشته باشد تا جایگزین آیمتی شود که در موقعیت ثابت دنباله تعامل s_u کاربر u قرار دارد. این عملیات دو مرتبه برای هر کاربر تکرار می‌شود و به ترتیب دو توالی تعاملی با جایگزینی متفاوت s_u ، برای کاربر u به دست می‌آید. توالی‌های تعاملی جایگزین شده مجموعه‌ای از توالی‌های تعاملی را تشکیل می‌دهند. اگر هر دو دنباله تعاملی جایگزین شده در مجموعه از یک کاربر تبدیل شوند، این جفت به عنوان یک مثال مثبت در نظر گرفته می‌شوند. در مقابل، ما دو دنباله تبدیل شده از کاربران مختلف را به عنوان یک جفت منفی در نظر می‌گیریم. تابع loss برای مازول یادگیری متضاد به منظور اندازه‌گیری میزان سازگاری منابع دو جاسازی استفاده می‌شود. به طور خاص، هدف تابع loss به حداکثر رساندن شباهت داده‌های جاسازی شده به دست آمده از جفت مثبت و به حداقل رساندن شباهت داده‌های جاسازی شده حاصل از جفت منفی است.

فرض کنید یک دسته کوچک شامل N کاربران است و $UN = \{u_1, u_2, \dots, u_N\}$ مجموعه دنباله‌های جایگزین شده باشند. پس از لایه‌های embedding و user encoder، مجموعه جاسازی‌ها پیرو تحقیقات (مقالات) قبلی [۴۷]، [۴۹]، [۵۴]، برای هر کاربر u ، (e_u) (به عنوان جفت مثبت تلقی می‌شود و مجموعه‌ی E_u^- شامل جاسازی‌های به دست آمده از سایر کاربران $N-1$ در مینی‌بچ مشابه

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

است. به منظور اندازه گیری شباهت بین جاسازیها، کسینوس مشابه (همگون) $\cos(\cdot)$ انتخاب شده است. علاوه بر این، برای کاربر u تابع loss متضاد L_{cl} را می توان همانطور که در رابطه (۲) نشان داده شده است، تعریف کرد.

$$L_{cl}(u \in U_N) = -\log \frac{\exp(\cos(e'_u e''_u))}{\exp(\cos(e'_u e''_u)) + \sum_{u \in E_u} \exp(\cos(e'_u e''_u))} \quad (2)$$

۳-۲-۲-۲- مازول گراف پیچیدگی

همانطور که در شکل ۳ نشان داده شده است، برای دنباله تعامل کاربر s در مرحله زمانی t ، پس از لایه های جاسازی و رمزگذار کاربر، جاسازی e_u برای کاربر u در گام زمانی t به دست می آید. در طول آموزش (train) کردن دادهها، آیتمی که کاربر در مرحله زمانی $t + 1$ با آن تعامل دارد، به عنوان نمونه مثبت v^{+}_{t+1} و یک آیتمی منفی v^{-}_{t+1} به صورت تصادفی نمونه برداری می شود. آنها را در لایه های embedding قرار دهید، و ما embedding مثبت $evt+1$ و embedding منفی $evt+1$ را دریافت می کنیم. سپس آنتروپی متقاطع باینری به عنوان تابع هدف برای تابع loss پایه اتخاذ می شود. بعداً، جاسازی اصلی به عنوان ویژگی برای کاربر در شبکه اجتماعی قرار می گیرد و GCN برای جمع آوری و انتشار جاسازی کاربر در بین شبکه اعمال می شود. پس از آن، تعبیه جدید e_u^{GCN} را برای کاربر u به دست می آوریم. در مورد GCN loss، تابع loss آنتروپی متقاطع باینری نیز به عنوان تابع هدف انتخاب می شود. فرمول های محاسبه تابع loss پایه L_{bl} و تابع L_{gl} برای GCN L_{gl} برای کاربر u به صورت زیر نشان داده شده است.

$$L_{bl}(u \in U_N) = -[\log \sigma(e_u \cdot e_{v^{+}_{t+1}}) + \log(1 - \sigma(e_u \cdot e_{v^{-}_{t+1}}))] \quad (3)$$

$$L_{gl}(u \in U_N) = -[\log \sigma(e_u^{GCN} \cdot e_{v^{+}_{t+1}}) + \log(1 - \sigma(e_u^{GCN} \cdot e_{v^{-}_{t+1}}))] \quad (4)$$

۳-۲-۳- لایه جاسازی و لایه رمزگذار کاربر

برای لایه جاسازی و لایه رمزگذار کاربر، رمزگذار Transformer برای مدل سازی توالی های تعامل کاربر به صورت پشته (Stack) قرار می گیرد. برای این بخش، از ساختار SASRec [۱۷] بهره گرفته شده است که عمدتاً شامل لایه جاسازی شده با موقعیت، لایه خود نگرشی و شبکه عصبی پیش خور (feed-forward network) نقطه ای است. از آنجایی که هدف مدل، داده های متوالی است، از رمزگذاری موقعیتی نیز استفاده می شود. با توجه به دنباله تعامل کاربر $S_u = [v_1^u, v_2^u, \dots, v_n^u]$ می توان آن را همانطور که در رابطه (۵) نشان داده نمایش داد.

$$e_u^0 = \begin{bmatrix} e_{v_1} + p_1 \\ e_{v_2} + p_2 \\ \dots \\ e_{v_n} + p_n \end{bmatrix} \quad (5)$$

به طوری که $[e_{v_1}, e_{v_2}, \dots, e_{v_n}]$ و $[p_1, p_2, \dots, p_n]$ به ترتیب، آیتمیها و موقعیت های جاسازی را نشان می دهند. در مرحله بعدی، جاسازی e_u^0 در لایه های خود نگرش قرار می گیرد. به طور خاص، بیان ریاضی بلوک خود نگرش را می توان به صورت زیر نمایش داد.

$$Attention(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d}} \right) V \quad (6)$$

که در آن Q, K و V به ترتیب کوثریها، کلیدها و مقادیر را نشان می دهند. در مورد پارامتر d ، بُعد جاسازی نشان داده می شود.

$$a_u = SA(e_u^0) = Attention(e_u^0 W^Q, e_u^0 W^K, e_u^0 W^V) \quad (7)$$

که در آن W^Q, W^K, W^V همگی ماتریس های نمایش $d \times d$ هستند.

اگرچه جاسازی مواردی که کاربر با آنها در تعامل است را می توان از طریق لایه های خود نگرش جمع آوری کرد، اما هنوز یک عملگر خطی است. بنابراین، یک شبکه عصبی پیش خور نقطه ای برای اضافه کردن غیرخطی بودن به مدل، اختیار می شود. همچنین می توان آن را به عنوان تعاملی مابین ابعاد مختلف به طور ضمنی در نظر گرفت. فرمول محاسباتی به صورت زیر نشان داده شده است.

$$e_u = FFN(a_u) = ReLU(a_u W^{(1)} + b^{(1)}) W^{(2)} + b^{(2)} \quad (8)$$

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

که در آن $W^{(1)} \in \mathbb{R}^{d \times d}$ ، $W^{(2)} \in \mathbb{R}^{d \times d}$ ماتریس‌های وزن قابل آموزش و $b^{(1)} \in \mathbb{R}^d$ ، $b^{(2)} \in \mathbb{R}^d$ بردارهای بایاس قابل آموزش هستند. در مرحله‌ی بعد، برای یادگیری بازنمایی پیچیده‌تر و دقیق‌تر، ماژول‌های خود نگرش به صورت پشته قرار می‌گیرند و می‌توان آن‌ها را به صورت زیر نشان داد.

$$a_u^{(b)} = SA(e_u^{(b-1)}) \quad (9)$$

$$e_u^{(b)} = FFN(a_u^{(b)}) \quad (10)$$

که در آن b تعداد ماژول‌های خود نگرش پشته را نشان می‌دهد. علاوه بر این، برای حل مسئله overfitting، روش‌های اتصال باقیمانده، نرمال‌سازی لایه و ماژول حذف در هر لایه، اختیار شده است. محاسبات را می‌توان به صورت زیر تعریف کرد.

$$g'(x) = x + Dropout(g(LayerNorm(x))) \quad (11)$$

که در آن $g(x)$ می‌تواند نشان دهنده‌ی لایه خود نگرش $SA(x)$ یا شبکه عصبی پیش‌خور $FFN(x)$ باشد.

۳-۲-۴- تابع loss

همانطور که در شکل ۱ نشان داده شده است، تابع loss مدل CLSSR به سه بخش تقسیم می‌شود: تابع loss بر مبنای L_{bl} ، تابع loss L_{gl} GCN و تابع loss متضاد L_{cl} . نسبت سه نوع تابع loss توسط پارامترهای α و β کنترل می‌شود. محاسبه تابع loss به صورت زیر نشان داده شده است.

$$L = L_{bl} + \alpha L_{gl} + \beta L_{cl} \quad (12)$$

۳-۲-۵- آزمایش

در حقیقت در حین آزمایش، هدف مدل این است که با توجه به ترتیب تاریخچه $[v_1^u, v_2^u, v_3^u, \dots, v_i^u, \dots, v_{|S_u|}^u]$ و کاربر u در مرحله زمانی بعدی یعنی v_{t+1}^u ، ارائه لیست مرتب از مواردی که کاربر می‌خواهد در مرحله بعد با آنها تعامل داشته باشد انجام شود. به طور خاص، ما e_u را پس از لایه‌های embedding و user encoder بدست می‌آوریم و از عملیات GCN برای به‌روزرسانی نمایش کاربر استفاده می‌کنیم. سپس از محصول نقطه‌ای بین e_u^{GCN} و جاسازی سایر موارد برای بدست آوردن لیست توصیه‌نهایی استفاده می‌شود.

۴- آزمایش و تجزیه و تحلیل نتایج

۴-۱- تنظیمات آزمایش

۴-۱-۱- مجموعه داده‌ها

در مرحله‌ی آزمایش، دو مجموعه داده توصیه متوالی عمومی، یعنی Last-fm و Epinions را انتخاب می‌کنیم که در برگزیده‌ی شبکه اجتماعی، به ویژه، Last-fm است. بزرگترین پلتفرم موسیقی اجتماعی در سطح جهان، که بر اساس آن کاربران می‌توانند موسیقی مورد علاقه خود را کشف کنند و موسیقی را با دیگران به اشتراک بگذارند. دوم، Epinions وب‌سایتی است که در آن کاربران می‌توانند محصولات را مرور کنند و نظر بدهند و همچنین روابط اجتماعی بین کاربران وجود دارد.

برای دو مجموعه داده، پیش‌پردازش زیر انجام می‌شود. اولاً، رفتار گوش دادن یا امتیازدهی به عنوان تعامل بین کاربران و آیتم‌ها مدل‌سازی می‌شود و ترتیب تعامل برای هر کاربر را به ترتیب زمانی مرتب می‌کند. برای اطمینان از اینکه مواردی که هر کاربر با آنها در تعامل بوده کافی است، تحقیقات Rendle و همکاران [۵] و Zhou و همکاران [۵۰]، دنباله تعامل کاربرانی که در داخل شبکه‌های اجتماعی نیستند را حذف می‌کنیم. اندازه مجموعه داده‌های پردازش شده‌ی نهایی در جدول ۱ نشان داده شده است.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

جدول ۱- شرح مجموعه داده ها

The description of datasets.

| Dataset | Last-fm | Epinions |
|--|---------|----------|
| Number of users | 1,164 | 21,764 |
| Number of items | 12,105 | 113,383 |
| Number of interactions | 67,038 | 524,914 |
| Average length of interaction sequence | 55.59 | 22.12 |
| Number of social links in the network | 10,984 | 287,600 |

۴-۱-۲- روش های مقایسه

- برای اثبات اثربخشی مدل پیشنهادی CLSSR، عملکرد آن را با روش های رایج زیر در توصیه های متوالی مقایسه می کنیم.
- (۱) BPR [۲۰]: این یک مدل توصیه سنتی است، نه به طور خاص برای توصیه متوالی. از تجزیه ماتریس برای مدل سازی توالی و محاسبه ضرر رتبه بندی شخصی بیزی استفاده می کند.
- (۲) FPMC [۵]: یک مدل سنتی برای توصیه های متوالی، تجزیه ماتریس را با زنجیره مارکوف ترکیب می کند تا ترجیحات کاربر و اطلاعات زمانی را به طور همزمان ضبط کند.
- (۳) GRU4Rec [۸]: مدلی مبتنی بر RNN از واحدهای بازگشتی دارای گیت پیوسته که برای مدل سازی توالی های کاربر استفاده می کند.
- (۴) Caser [۱۱]: مدلی مبتنی بر CNN از فیلترهای افقی و عمودی برای مدل سازی ترجیحات عمومی و الگوهای توالی کاربران استفاده می کند.
- (۵) SASRec [۱۷]: مدلی مبتنی بر Transformer که از مکانیسم خود نگرش برای مدل سازی توالی های کاربر و جلب علائق پویای کاربران استفاده می کند.
- (۶) GC-SAN [۱۴]: این مدل GNN را با مکانیسم خود نگرش ترکیب می کند و می تواند اطلاعات تبدیل محلی و از راه دور دنباله را ضبط کند.
- (۷) S3-RecMIP [۵۰]: این مدل چهار نوع کار تحت نظارت خود را برای پیش آموزش طراحی می کند تا عملکرد توصیه های متوالی را بهبود بخشد. به منظور عدالت در اجرای آزمایشات تجربی، از پیش بینی آیت ماسک (MIP) در مدل استفاده شده است.

۴-۱-۳- تنظیمات تقسیم بندی و پارامترهای مجموعه داده ها

برای تقسیم مجموعه داده ها، به دنبال کارهای قبلی Kang و همکاران [۱۷]، Sun و همکاران [۱۸] و Zhou و همکاران [۵۰]، آخرین مورد از توالی کاربر، مورد ماقبل آخر دنباله کاربر و بقیه به ترتیب به عنوان مجموعه تست، اعتبار سنجی و آموزش استفاده می شوند. بعد جاسازی بردار ۵۰ و حداکثر طول برای هر دنباله کاربر نیز ۵۰ است. برای BPR، FPMC، GRU4Rec، Caser و GC-SAN، ما آن را بر روی چارچوب RecBole [۵۶] و برای SASRec و S3-RecMIP، آن را روی کد منبع مربوطه اجرا می کنیم.

۴-۱-۴- معیارهای ارزیابی

در آزمایش تجربی، دو معیار ارزیابی که معمولاً در کارهای توصیه ای استفاده می شوند، انتخاب می شوند، یعنی نسبت ضربه (HR) و سود تجمعی تنزیل شده عادی (NDCG).

$HR@k$ به صورت زیر محاسبه می شود.

$$HR@k = 1 / N \sum_{i=1}^N hits(i) \quad (13)$$

که در آن، k نشان دهنده اندازه لیست توصیه ها و N نشان دهنده تعداد کاربران است.

$NDCG@k$ به صورت زیر محاسبه می شود:

$$NDCG@k = 1 / N \sum_{i=1}^N \frac{1}{\log_2(p_i + 1)} \quad (14)$$

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

که در آن k و N به ترتیب نشان دهنده اندازه لیست توصیه و تعداد کاربران هستند. pi ، موقعیت آیتمی را که کاربر i با آن در لیست توصیه‌ها تعامل خواهد داشت را نشان می‌دهد. اگر این آیتم در لیست توصیه وجود نداشته باشد، $pi \rightarrow \infty$ را تنظیم می‌کنیم. این معیار بر ترتیب توصیه تاکید می‌کند، یعنی اینکه آیا آیتمی که کاربر می‌خواهد با آن تعامل داشته باشد در موقعیتی برجسته توصیه می‌شود یا خیر. به طور خاص، اندازه لیست توصیه انتخاب شده در این آزمایش برابر با ۱۰ است، یعنی HR@10 و NDCG@10.

۲-۴- نتایج تجربی

در این بخش، عملکرد مدل پیشنهادی ما (CLSSR) با هفت روش پایه در دو مجموعه داده مقایسه شده است. نتایج تجربی در جدول ۲ نشان داده شده است.

به طور کلی، مدل پیشنهادی ما CLSSR بهترین نتایج را در مجموعه داده‌ها به دست می‌آورد. در Last-fm، در مقایسه با دومین SASRec، مدل CLSSR ما به ترتیب برابر با ۲۲/۸٪ و ۲۰/۳٪ است که بهبودهایی در HR@10 و NDCG@10 به دست می‌آورد. در مورد Epinions، معیارهای ارزیابی HR@10 و NDCG@10 برای CLSSR به ترتیب ۲۳/۷٪ و ۶۱/۸٪ هستند که بالاتر از دومین GC-SAN است. از مزایای قابل توجه این معیار، استفاده از اطلاعات اجتماعی و یادگیری متضاد در توصیه‌های متوالی موثر است. دوماً، در میان تمام خطوط مبنای، مشهود است که مدل غیر ترتیبی BPR تقریباً به رتبه‌های پایینی نسبت به همه شاخص‌ها دست پیدا می‌کند که نشان می‌دهد در نظر گرفتن اطلاعات متوالی در سیستم‌های توصیه‌گر دنیای واقعی ضروری هستند. شایان ذکر است که عملکرد S3-RecMIP در Epinions ضعیف است که ممکن است به دلیل تعداد زیادی توالی کوتاه در مجموعه داده Epinions باشد. سوماً، در مجموعه داده Last-fm، S3-RecMIP با مدل CLSSR ما عملکرد بهتری دارد که نشان دهنده اثربخشی وظیفه خود نظارت شده‌ی جایگزینی آیتم‌ها از همسایگان است.

مشاهده شده است که GRU4Rec و GC-SAN بهتر از خطوط پایه دیگر عمل می‌کنند که نشان می‌دهد این مدل برای برخورد با دنباله‌های کوتاه مناسب‌تر است. در مورد مدل پیشنهادی ما CLSSR، نتایج نشان می‌دهند که توالی‌های بلند و کوتاه را به خوبی اداره می‌شوند.

جدول ۲. اجرای روش‌های مختلف در Last-fm و Epinions.

| | Last-fm | | Epinions | |
|------------------------|---------|---------|----------|---------|
| | HR@10 | NDCG@10 | HR@10 | NDCG@10 |
| BPR | 2.66% | 1.28% | 4.50% | 1.45% |
| FPMC | 3.09% | 1.70% | 4.72% | 2.77% |
| GRU4Rec | 3.09% | 1.52% | 5.60% | 3.33% |
| Caser | 3.18% | 1.70% | 3.94% | 2.16% |
| SASRec | 3.85% | 2.07% | 5.14% | 2.93% |
| GC-SAN | 2.92% | 1.49% | 6.29% | 3.67% |
| S ³ -RecMIP | 3.01% | 1.32% | 1.70% | 1.00% |
| CLSSR | 4.73% | 2.49% | 7.78% | 5.94% |

بهترین عملکرد در هر ستون به صورت پررنگ است و روش دوم بهترین در هر ستون است که زیر آن خط کشیده شده است.

۳-۴- مطالعات انجام شده

به منظور بررسی بیشتر اعتبار ماژول یادگیری متضاد و ماژول گراف پیچیدگی در مدل پیشنهادی ما CLSSR، آزمایش‌های متعددی بر روی مجموعه داده‌های Last-fm و Epinions انجام شده است. نتایج آزمایش در جدول ۳ نشان داده شده است، به طوری که CLSSRGCN و CLSSRCL نشان می‌دهند که ماژول یادگیری متضاد و ماژول گراف پیچیدگی در CLSSR به ترتیب حذف شده اند. با مقایسه نتایج CLSSRCL و CLSSR، می‌توان دریافت که استفاده از اطلاعات اجتماعی کاربر می‌تواند عملکرد توصیه را بهبود

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

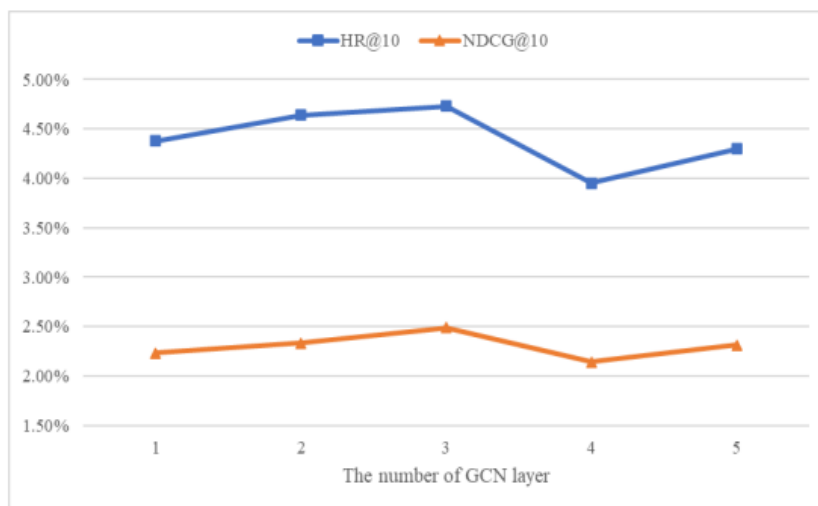
دهد. سپس، در مقایسه با CLSSRGCN، عملکرد CLSSR بهتر است که تأیید می‌کند متد یادگیری متضاد پیشنهادی می‌تواند نمایش دقیق تری از کاربران را به دست آورد و اثر را بهبود بخشد. در همین حال، CLSSRCL و CLSSRGCN بهتر از خطوط پایه در جدول ۲ عمل می‌کنند و این امر نشان دهنده‌ی این است که هر ماژول می‌تواند عملکرد را بهبود بخشد.

جدول ۳. اجرای آزمایشات قطعی

| | Last-fm | | Epinions | |
|----------------------|---------|---------|----------|---------|
| | HR@10 | NDCG@10 | HR@10 | NDCG@10 |
| CLSSR | 4.73% | 2.49% | 7.78% | 5.94% |
| CLSSR _{GCN} | 4.38% | 2.31% | 7.53% | 5.89% |
| CLSSR _{CL} | 4.30% | 2.14% | 7.31% | 5.33% |

۴-۴- تجزیه و تحلیل بر روی تعداد لایه های GCN

گراف پیچیدگی می‌تواند اطلاعات اجتماعی کاربران را جمع‌آوری کرده تا تعداد مناسبی از لایه‌ها اثر مدل را به طور موثر بهبود بخشند. به منظور بحث بیشتر در مورد تأثیر تعداد لایه‌های GCN در مدل، روی مجموعه داده Last-fm آزمایشاتی را انجام که نتایج تجربی در شکل ۴ نشان داده شده است. از شکل ۴، می‌توان دریافت که با افزایش در تعداد لایه‌های GCN، عملکرد مدل ابتدا افزایش و سپس اندکی کاهش می‌یابد، و زمانی که تعداد لایه‌های GCN 3 باشد، به بالاترین حد خود می‌رسد. این افزایش به این دلیل است که عملکرد GCN ویژگی‌های همسایگی‌ها را در شبکه اجتماعی جمع می‌کند. حتی زمانی که تعداد لایه‌ها کم باشد، می‌تواند تأثیر اجتماعی کاربران را به‌طور مؤثری ثبت کند و نمایش دقیق‌تری از کاربر را بیاموزد. با این حال، اگر لایه‌های زیادی به صورت پشت‌پشته قرار گیرند، ویژگی‌های میان‌گره‌ها در شبکه بیش از حد صاف خواهند بود که اثر مدل را کاهش می‌دهد.



شکل ۴. عملکرد CLSSR با تعداد لایه های مختلف GCN در Last-fm

۴-۵- تجزیه و تحلیل شاخص آیتم جایگزین شده

در ماژول یادگیری متضاد، تأثیر شاخص جایگزین شده را بیشتر بررسی می‌کنیم. از آنجایی که حداقل طول توالی کاربر در مجموعه داده ۵ است و مجموعه‌های اعتبارسنجی و آزمایش از آخرین و دومین نمونه از آخر استفاده می‌کنند، حداقل طول توالی کاربر در مجموعه آموزشی برابر با ۳ است. بنابراین شاخص آیتم جایگزین شده در محدوده {۱-، ۲-، ۳-} تنظیم شده است، جایی که مقدار منفی نشان می‌دهد که شاخص از عقب به جلو است. ما روی مجموعه داده Last-fm آزمایش می‌کنیم، و نتایج در جدول ۴ نشان داده شده است. از جدول ۴، می‌توان دریافت که برای HR@10، زمانی که شاخص برابر با ۲- باشد، بهترین اثر را دارد. علاوه بر این، در مورد NDCG@10،

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

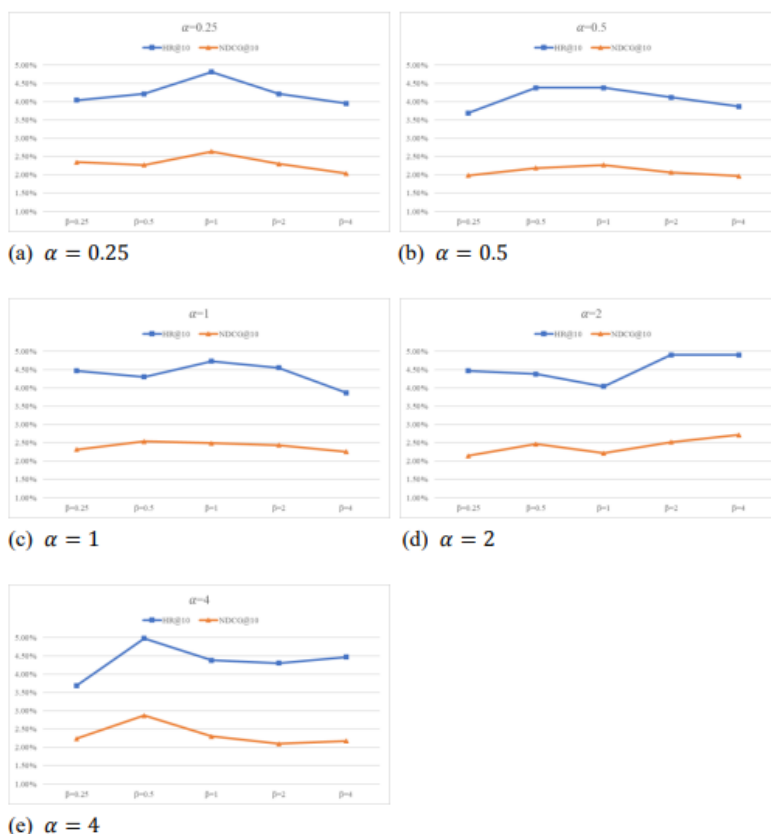
عملکرد، زمانی در بهترین حالت است که شاخص برابر با ۱- باشد. نتایج تجربی نشان می‌دهند که کاهش تأثیر اختلالات اخیر از طریق یادگیری متضاد، می‌تواند بازنمایی کاربر را بهبود داده و علائق واقعی کاربران را به طور بهتری منعکس کند.

جدول ۴. عملکرد مدل CLSSR با شاخص های مختلف آیتم جایگزین شده در Last-fm.

| | HR@10 | NDCG@10 |
|--------------------|-------|---------|
| CLSSR (index = -1) | 4.64% | 2.71% |
| CLSSR (index = -2) | 4.73% | 2.49% |
| CLSSR (index = -3) | 4.47% | 2.43% |

۴-۶ اثر نسبت تابع loss متضاد و تابع loss برای GCN

مدل پیشنهادی ما CLSSR دارای سه بخش در تابع loss است: تابع loss بنیادی، تابع loss متضاد، و تابع loss برای GCN. دو پارامتر α و β برای تنظیم نسبت افت تضاد و تابع loss برای GCN در تابع loss استفاده می‌شوند. برای بررسی نحوه تعامل توابع loss مختلف با یکدیگر، α و β در محدوده $\{0.25, 0.5, 1, 2, 4\}$ تنظیم شده‌اند. ما روی مجموعه داده Last-fm آزمایش می‌کنیم و نتایج در شکل ۵ نشان داده شده است. نتایج در شکل ۵ نشان می‌دهند که مدل، زمانی بهترین عملکرد را دارد که $\alpha = 4$ و $\beta = 0.5$ باشد. مقادیر مربوطه HR@10 و NDCG@10 به ترتیب ۴/۹۸٪ و ۲/۸۷٪ هستند. همچنین مشخص شده است که وقتی مقدار α ثابت است، در بیشتر آیت‌ها، عملکرد کلی CLSSR ابتدا افزایش و سپس با افزایش مقدار β کاهش پیدا می‌کند. در همین حال، عملکرد CLSSR تقریباً در تمامی آیت‌ها با α و β مناسب، به طور مداوم بهتر از خطوط پایه جدول ۲ است. از یک طرف، نتایج تجربی کارایی ماژول یادگیری متضاد و ماژول گراف پیچیدگی را بیشتر تایید می‌کنند و از سوی دیگر، نتایج نشان می‌دهند که نسبت تابع loss متضاد و تابع loss برای GCN بر عملکرد کلی اثر می‌گذارد.



شکل ۵. مقایسه عملکرد بین وزن های مختلف تابع loss متضاد و تابع loss برای GCN در Last-fm

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

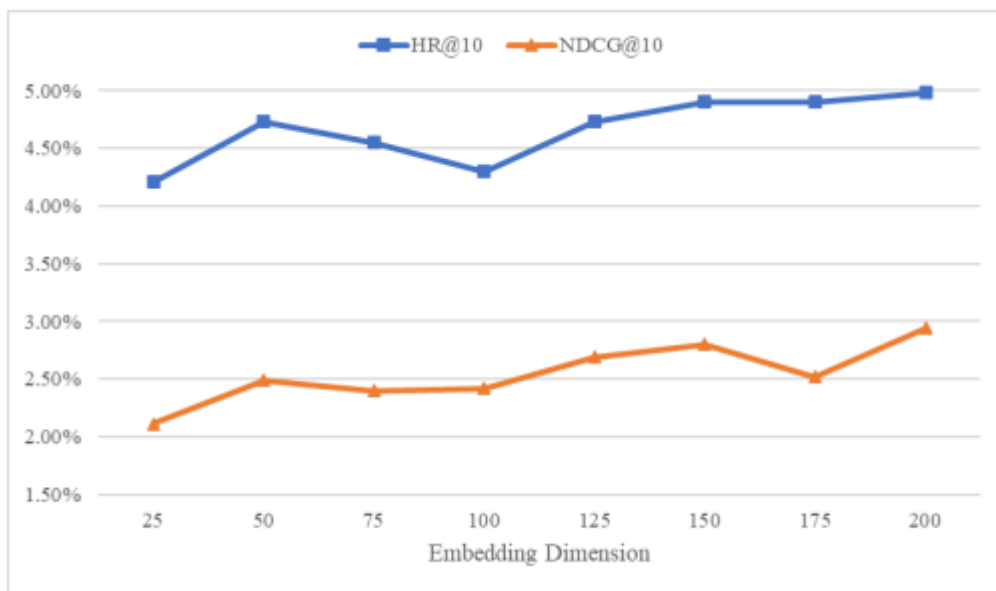
senacnf.ir

۷-۴- تجزیه و تحلیل حساسیت پارامتر

وقتی نوبت به حساسیت پارامتر می‌رسد، در مورد تأثیر پارامترهای معماری شبکه عصبی بحث می‌کنیم. به طور ویژه، آزمایش‌های فشرده‌ای را بر روی مجموعه داده Lastfm برای شش پارامتر زیر انجام می‌دهیم: ابعاد جاسازی، اندازه دسته‌بندی ها، تعداد headها، تعداد بلوک‌ها، نرخ انصراف و حداکثر طول.

۷-۴-۱- تأثیر بُعد جاسازی

سایر پارامترها را اصلاح و بُعد جاسازی داده‌ها را در محدوده {۲۵، ۵۰، ۷۵، ۱۰۰، ۱۲۵، ۱۵۰، ۱۷۵، ۲۰۰} تنظیم می‌کنیم. شکل ۶ نتایج HR@10 و NDCG@10 را در Last-fm گزارش می‌کند. مطابق شکل ۶، مدل CLSSR زمانی که بُعد جاسازی روی ۲۰۰ تنظیم شود، بهترین نتایج را دارد. همچنین می‌توانیم به این نتیجه برسیم که با افزایش ابعاد جاسازی، عملکرد به تدریج با نوسانات جزئی افزایش پیدا می‌کند. بعد بالاتر می‌تواند ویژگی‌های بیشتری را به تصویر بکشد. با این حال، هزینه‌ی حافظه و زمان بیشتر و خطر تطبیق بیش از حد را در پی خواهد داشت. بنابراین، نیاز به انتخاب ابعاد مناسبی برای مدل وجود دارد.



شکل ۶. تأثیر بُعد جاسازی شده CLSSR بر Last-fm

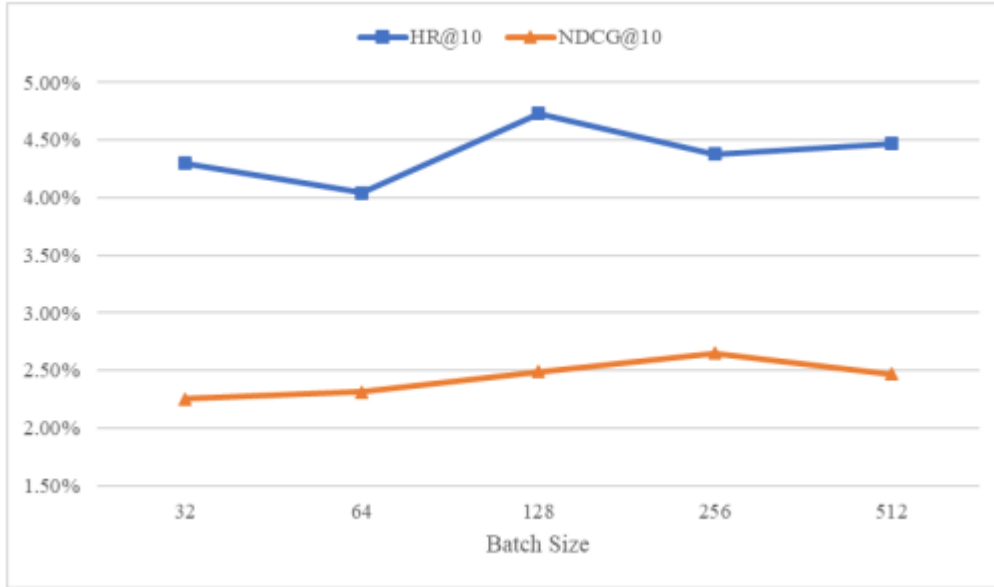
۷-۴-۲- تأثیر اندازه‌ی بچ (دسته یا برنامه‌ها و دستوراتی که برای پردازش آماده شده‌اند)

به منظور تجزیه و تحلیل تأثیر اندازه‌ی بچ، آن را در محدوده {۳۲، ۶۴، ۱۲۸، ۲۵۶، ۵۱۲} تنظیم می‌کنیم. شکل ۷ نتایج HR@10 و NDCG@10 را در Last-fm نشان می‌دهد. مطابق شکل ۷، معیارهای ارزیابی زمانی که اندازه‌ی بچ افزایش می‌یابد کمی تغییر می‌کند. مخصوصاً، مدل در اکثر موارد به نتایج خوبی می‌رسد که نشان می‌دهد مدل CLSSR نسبت به تغییرات اندازه بچ قوی است.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

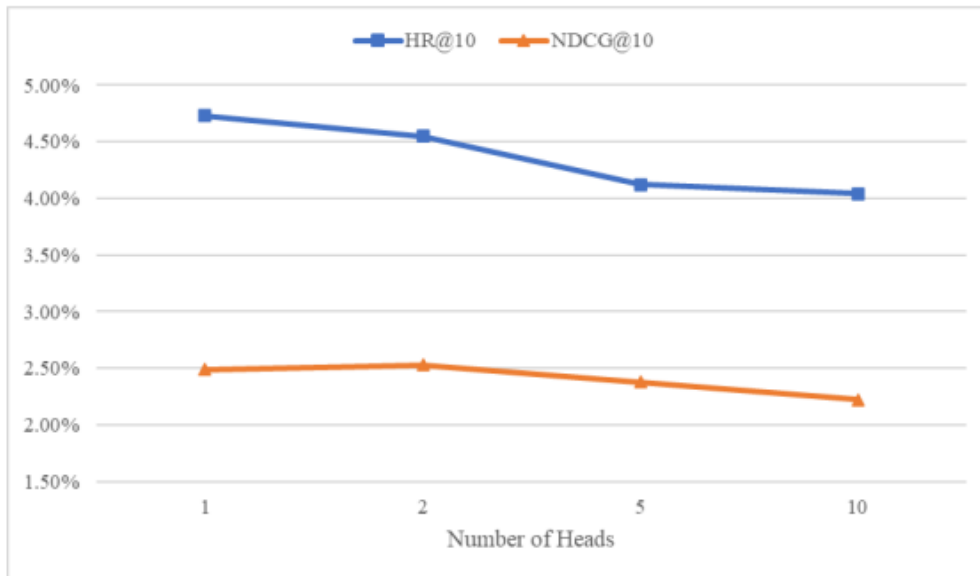
senacnf.ir



شکل ۷. تأثیر اندازه بچ CLSSR در Last-fm

۳-۷-۴- تأثیر تعداد head ها در بلوک خود نگرش

در این قسمت تعداد هدها را در محدوده {۱، ۲، ۵، ۱۰} تنظیم می کنیم. نتایج HR@10 و NDCG@10 در Last-fm در شکل ۸ نشان داده شده اند. مطابق با شکل ۸، مشخص شده است که عملکرد مدل با افزایش تعداد هدها در بلوک خود نگرش، کاهش پیدا می کند و از آنجایی که ابعاد جاسازی ۵۰ است، وقتی Nh روی ۲ یا بیشتر تنظیم شده باشد، جاسازی در هر head آنقدر متراکم خواهد بود که ویژگیها را به خوبی نشان نمی دهد. نتایج تجربی نشان می دهند که تعداد هدها در بلوک خود نگرش باید متناسب با بعد جاسازی شده D باشد.



شکل ۸. تأثیر تعداد head های CLSSR در Last-fm

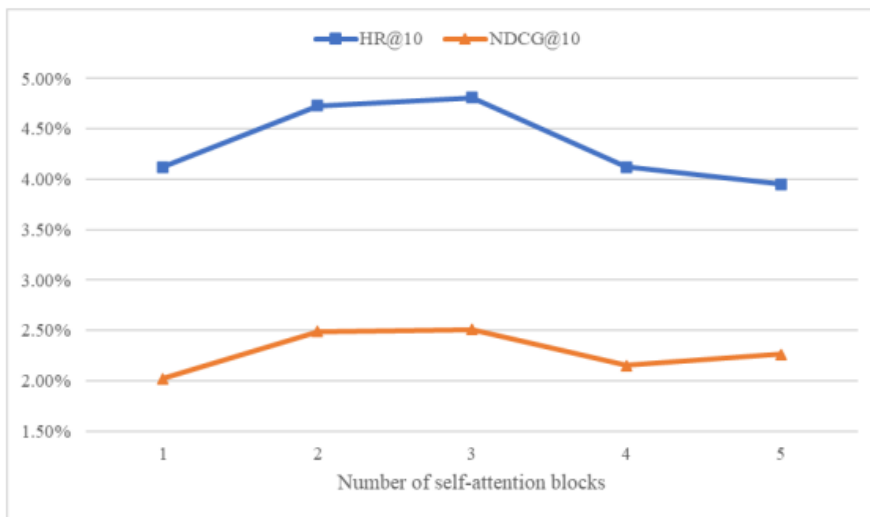
دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

۴-۷-۴- تأثیر تعداد بلوک های خود نگرش با ثابت کردن سایر پارامترها

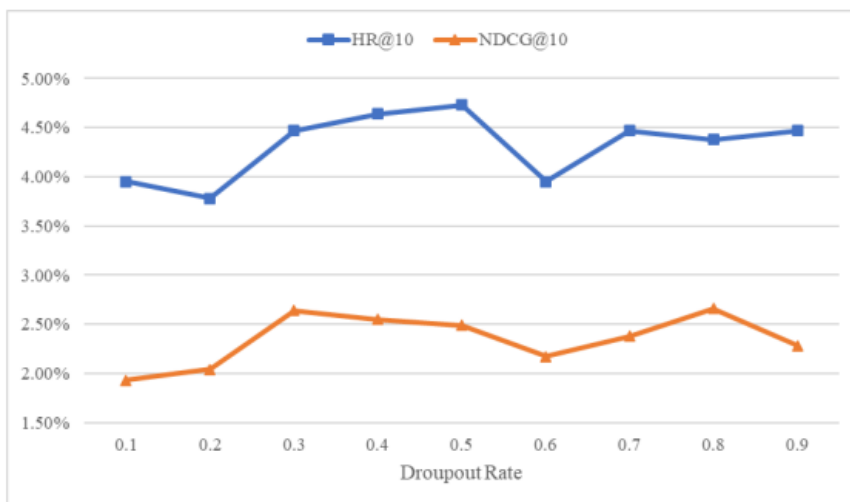
تعداد بلوک های خود نگرش در محدوده ی {۱، ۲، ۳، ۴، ۵} تنظیم می شوند. شکل ۹ نتایج HR@10 و NDCG@10 را در Last-fm گزارش می کند. مطابق با شکل ۹، CLSSR زمانی بهترین عملکرد را به دست می آورد که تعداد بلوک های خود نگرش روی ۳ تنظیم شوند. عملکرد CLSSR دائماً با افزایش تعداد بلوک های خود نگرش افزایش پیدا نمی کند بلکه ابتدا افزایش و سپس کاهش می یابد. نتایج تجربی نشان می دهند که یک Nb مناسب برای مدل ضروری است.



شکل ۹. تأثیر تعداد بلوک های خود نگرش CLSSR در Last-fm.

۴-۷-۵- تأثیر نرخ حذف تصادفی

هدف از عملیات، حذف تصادفی پیشگیری از برازش بیش از حد (overfitting) مدل است. برای مدل پیشنهادی ما CLSSR، نرخ حذف تصادفی rd در محدوده {۰.۱، ۰.۲، ۰.۳، ۰.۴، ۰.۵، ۰.۶، ۰.۷، ۰.۸، ۰.۹} تنظیم شده است. نتایج آزمایش بر روی Last-fm در شکل ۱۰ نشان داده شده است. طبق شکل ۱۰، زمانی که نرخ حذف تصادفی روی ۰/۳ تا ۰/۵ تنظیم شده باشد، نتایج نسبتاً خوبی در HR@10 و NDCG@10 به دست می آید. زمانی که rd روی ۰/۱ یا ۰/۹ تنظیم شود، عملکرد مدل کاهش می یابد که نشان می دهد نرخ حذف تصادفی باید مقداری را نسبت به مرکز مابین ۰ و ۱ داشته باشد.



شکل ۱۰. تأثیر نرخ حذف تصادفی CLSSR بر Last-fm

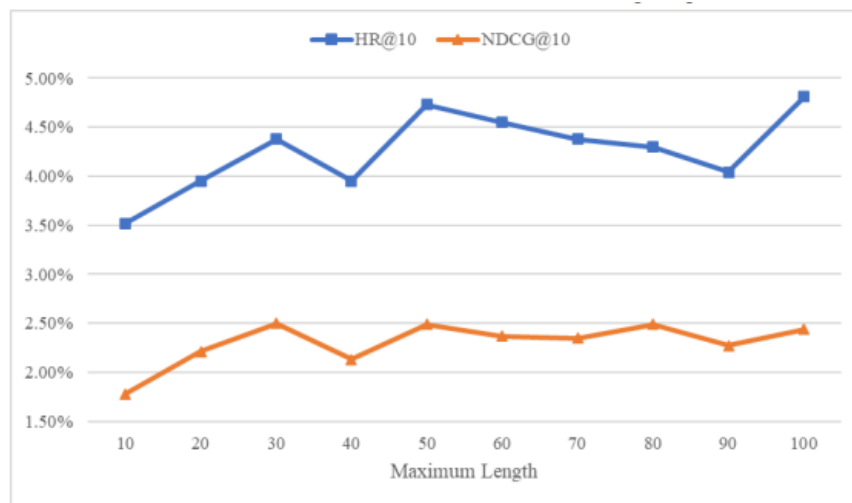
دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

۴-۷-۶- تأثیر حداکثر طول توالی کاربر

به منظور بررسی تأثیر حداکثر طول دنباله‌ی کاربر Lm ، آن را در محدوده‌ی $\{10, 20, 30, 40, 50, 60, 70, 80, 90, 100\}$ تنظیم می‌کنیم. شکل ۱۱ نتایج مدل ما را در Last-fm گزارش می‌کند. در شکل ۱۱، مشخص شده است که نتیجه CLSSR زمانی که Lm از ۵۰ فراتر می‌رود، به خصوص برای $NDCG@10$ و احتمالاً به این دلیل که طول بیشتر دنباله‌های کاربر حدود ۵۰ است پایدار می‌باشد. وقتی Lm روی مقدار کمتر از ۵۰ تنظیم شده است، بسیاری از فعالیت‌ها در مجموعه داده Last-fm پوشش داده نشده‌اند و عملکرد را کاهش می‌دهند.



شکل ۱۱. تأثیر حداکثر طول CLSSR در Last-fm.

۵- نتیجه‌گیری و کار آینده

در این مطالعه، مدلی به نام CLSSR برای وظیفه توصیه‌های متوالی پیشنهاد شده است که از شبکه اجتماعی کاربران به منظور بهبود اثر استفاده می‌کند. دقیقاً، برای به دست آوردن عوامل اجتماعی، از شبکه گراف پیچیدگی برای جمع‌آوری اطلاعات همسایه استفاده می‌شود. در مرحله بعد، یک مکانیسم جدید خود نظارتی طراحی شده است تا تأثیر نویز را کاهش داده و با جایگزینی عملکرد، نمایش کاربران را بهبود بخشد. به این ترتیب، برای تسهیل یادگیری متضاد، جفت‌های مثبت و منفی می‌سازیم. تا جایی که می‌دانیم، این اولین کاری است که همزمان از یادگیری متضاد و اطلاعات شبکه‌های اجتماعی در توصیه‌های متوالی استفاده می‌کند. آزمایش‌های گسترده‌ای بر روی دو مجموعه داده دنیای واقعی انجام می‌شود و نتایج نشان‌دهنده مزایای قابل توجه مدل پیشنهادی ما نسبت به سایر روش‌های نماینده و پیشرفته است.

در آینده، ما قصد داریم راه‌های جامع‌تری برای کشف اطلاعات اجتماعی کاربران در نظر بگیریم. به طور خاص‌تر، شبکه‌های عصبی گراف متفاوتی مانند GAT و GraphSAGE استفاده خواهند شد. علاوه بر این، راه‌های مختلف برای ایجاد جفت‌های مثبت و منفی برای بهبود یادگیری متضاد بیشتر بررسی خواهد شد.

دوازدهمین کنگره ملی سراسری
فناوریهای نوین در حوزه توسعه پایدار ایران
12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

منابع

- [1] H. J. Xue, X. Y. Dai, J. Zhang, S. Huang, J. Chen, Deep matrix factorization models for recommender systems, in: Proceedings of the 26th International Joint Conference on Artificial Intelligence, 2017, pp. 3203-3209.
- [2] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, T. S. Chua, Neural collaborative filtering, in: Proceedings of the 26th International Conference on World Wide Web, 2017, pp. 173-182.
- [3] S. Wang, L. Hu, Y. Wang, L. Cao, Q. Z. Sheng, M. Orgun, Sequential recommender systems: challenges, progress and prospects, in: Proceedings of the 28th International Joint Conference on Artificial Intelligence (IJCAI), 2019, pp. 6332- 6338.
- [4] H. Fang, D. Zhang, Y. Shu, G. Guo, Deep learning for sequential recommendation: Algorithms, influential factors, and evaluations, ACM Transactions on Information Systems 39(1) (2020) 1-42.
- [5] S. Rendle, C. Freudenthaler, L. Schmidt-Thieme, Factorizing personalized markov chains for next-basket recommendation, in: Proceedings of the 19th International Conference on World Wide Web, 2010, pp. 811-820.
- [6] R. He, J. McAuley, Fusing similarity models with markov chains for sparse sequential recommendation, in: Proceedings of the 2016 IEEE 16th International Conference on Data Mining, 2016, pp. 191-200.
- [7] Y. Yang, D. Hooshyar, H. S. Lim, GPS: Factorized group preference-based similarity models for sparse sequential recommendation, Information Sciences 481 (2019) 394-411.
- [8] B. Hidasi, A. Karatzoglou, L. Baltrunas, D. Tikk, Session-based recommendations with recurrent neural networks, in: Proceedings of the 4th International Conference on Learning Representations (ICLR), 2016, pp. 1-10.
- [9] Y. K. Tan, X. Xu, Y. Liu, Improved recurrent neural networks for session-based recommendations, in: Proceedings of the 1st workshop on deep learning for recommender systems, 2016, pp. 17-22
- [10] Y. Ma, M. Gan, DeepAssociate: A deep learning model exploring sequential influence and history-candidate association for sequence recommendation, Expert Systems with Applications 185 (2021) 115587.
- [11] J. Tang, K. Wang, Personalized top-n sequential recommendation via convolutional sequence embedding, in: Proceedings of the 11th ACM International Conference on Web Search and Data Mining, 2018, pp. 565-573.
- [12] F. Yuan, A. Karatzoglou, I. Arapakis, J. M. Jose, X. He, A simple convolutional generative network for next item recommendation, in: Proceedings of the 20th ACM International Conference on Web Search and Data Mining, 2019, pp. 582-590.
- [13] F. Yuan, X. He, H. Jiang, G. Guo, J. Xiong, Z. Xu, Y. Xiong, Future data helps training: Modeling future contexts for session-based recommendation, in: Proceedings of The Web Conference, 2020, pp. 303-313.
- [14] C. Xu, P. Zhao, Y. Liu, V. S. Sheng, J. Xu, F. Zhuang, J. Fang, X. Zhou, Graph contextualized self-attention network for session-based recommendation, in: Proceedings of the 28th International Joint Conference on Artificial Intelligence (IJCAI), 2019, pp. 3940-3946.
- [15] S. Wu, Y. Tang, Y. Zhu, L. Wang, X. Xie, T. Tan, Session-based recommendation with graph neural networks, in: Proceedings of the 33rd AAAI Conference on Artificial Intelligence, 2019, pp. 346-353.
- [16] Y. Tao, C. Wang, L. Yao, W. Li, Y. Yu, Item trend learning for sequential recommendation system using gated graph neural network, Neural Computing and Applications (2021) 1-16.
- [17] W. C. Kang, J. McAuley, Self-attentive sequential recommendation, in: Proceedings of the 2018 IEEE International Conference on Data Mining (ICDM), 2018, pp. 197-206.
- [18] F. Sun, J. Liu, J. Wu, C. Pei, X. Lin, W. Ou, P. Jiang, BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer, in: Proceedings of the 28th ACM International Conference on Information and Knowledge Management, 2019, pp. 1441-1450.
- [19] Z. Yang, S. Dong, J. Hu, GFE: General Knowledge Enhanced Framework for Explainable Sequential Recommendation, Knowledge-Based Systems 230 (2021) 107375.
- [20] S. Rendle, C. Freudenthaler, Z. Gantner, L. Schmidt-Thieme, BPR: Bayesian personalized ranking from implicit feedback, in: Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence, 2009, pp. 452-461.
- [21] R. Gao, J. Li, X. Li, C. Song, J. Chang, D. Liu, C. Wang, STSCR: Exploring spatialtemporal sequential influence and social information for location recommendation, Neurocomputing 319 (2018) 118-133.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [22] C. Yan, Q. Zhang, Merging visual features and temporal dynamics in sequential recommendation, *Neurocomputing* 362 (2019) 11-18.
- [23] S. Hochreiter, J. Schmidhuber, Long short-term memory, *Neural computation* 9(8) (1997) 1735-1780.
- [24] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio, Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation, in: *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014, pp. 1724-1734.
- [25] F. Yu, Q. Liu, S. Wu, L. Wang, T. Tan, A dynamic recurrent model for next basket recommendation, in: *Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval*, 2016, pp. 729-732.
- [26] Q. Cui, S. Wu, Q. Liu, W. Zhong, L. Wang, MV-RNN: A multi-view recurrent neural network for sequential recommendation, *IEEE Transactions on Knowledge and Data Engineering* 32 (2020) 317-331.
- [27] T. Qu, W. Wan, S. Wang, Visual content-enhanced sequential recommendation with feature-level attention, *Neurocomputing* 443 (2021) 262-271.
- [28] K. Sun, T. Qian, X. Chen, M. Zhong, Context-aware seq2seq translation model for sequential recommendation, *Information Sciences* 581 (2021) 60-72.
- [29] Q. Cui, S. Wu, Y. Huang, L. Wang, A hierarchical contextual attention-based network for sequential recommendation, *Neurocomputing* 358 (2019) 141-149.
- [30] W. Yuan, H. Wang, X. Yu, N. Liu, Z. Li, Attention-based context-aware sequential recommendation model, *Information Sciences* 510 (2020) 122-134.
- [31] H. Wang, P. Li, Y. Liu, J. Shao, Towards real-time demand-aware sequential POI recommendation, *Information Sciences* 547 (2021) 482-497.
- [32] L. Zhang, P. Wang, J. Li, Z. Xiao, H. Shi, Attentive Hybrid Recurrent Neural Networks for sequential recommendation, *Neural Computing and Applications* (2021) 1-15.
- [33] Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, Ł. Kaiser, I. Polosukhin, Attention is all you need, in: *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017, pp. 6000-6010.
- [34] J. Devlin, M. W. Chang, K. Lee, K. Toutanova, Bert: Pre-training of deep bidirectional transformers for language understanding, *arXiv preprint arXiv: 1810.04805* (2018) 1-16.
- [35] L. Wu, S. Li, C. J. Hsieh, J. Sharpnack, SSE-PT: Sequential recommendation via personalized transformer, in: *Proceedings of the 14th ACM Conference on Recommender Systems*, 2020, pp. 328-337.
- [36] C. Xu, J. Feng, P. Zhao, F. Zhuang, D. Wang, Y. Liu, V. S. Sheng, Long-and shortterm self-attention network for sequential recommendation, *Neurocomputing* 423 (2021) 580-589.
- [37] T. N. Kipf, M. Welling, Semi-supervised classification with graph convolutional networks, in: *Proceedings of the 5th International Conference on Learning Representations (ICLR)*, 2017, pp. 1-14.
- [38] P. Veličković, G. Cucurull, A. Casanova, A. Romero, P. Lio, Y. Bengio, Graph attention networks, in: *Proceedings of the 6th International Conference on Learning Representations (ICLR)*, 2018, pp. 1-12.
- [39] W. L. Hamilton, R. Ying, J. Leskovec, Inductive representation learning on large graphs, in: *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017, pp. 1025-1035.
- [40] W. Fan, Y. Ma, Q. Li, Y. He, E. Zhao, J. Tang, D. Yin, Graph neural networks for social recommendation, in: *Proceedings of the 30th International Conference on World Wide Web*, 2019, pp. 417-426.
- [41] J. Yu, H. Yin, J. Li, M. Gao, Z. Huang, L. Cui, Enhance social recommendation with adversarial graph convolutional networks, *IEEE Transactions on Knowledge and Data Engineering* (2020) 1-13.
- [42] L. Yang, Z. Liu, Y. Dou, J. Ma, P. S. Yu, ConsisRec: Enhancing GNN for Social Recommendation via Consistent Neighbor Aggregation, in: *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2021, pp. 2141-2145.
- [43] Z. Wang, W. Wei, G. Cong, X. L. Li, X. L. Mao, M. Qiu, Global context enhanced graph neural networks for session-based recommendation, in: *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2020, pp. 169-178.
- [44] B. Wang, W. Cai, Knowledge-enhanced graph neural networks for sequential recommendation, *Information* 11(8) (2020) 388.
- [45] K. He, H. Fan, Y. Wu, S. Xie, R. Girshick, Momentum Contrast for Unsupervised Visual Representation Learning, in: *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, pp. 9726-9735.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [46] X. Chen, H. Fan, R. Girshick, K. He, Improved baselines with momentum contrastive learning, arXiv preprint arXiv: 2003.04297 (2020) 1-3.
- [47] T. Chen, S. Kornblith, M. Norouzi, G. Hinton, A Simple Framework for Contrastive Learning of Visual Representations, in: Proceedings of the 37th International Conference on Machine Learning (ICML), 2020, pp. 1597-1607
- [48] T. Chen, S. Kornblith, K. Swersky, M. Norouzi, G. Hinton, Big Self-Supervised Models are Strong Semi-Supervised Learners, Advances in Neural Information Processing Systems 33 (2020) 22243-22255.
- [49] T. Yao, X. Yi, D. Z. Cheng, F. Yu, T. Chen, A. Menon, L. Hong, E. H. Chi, S. Tjoa, J. Kang, E. Ettinger, Self-supervised Learning for Large-scale Item Recommendations, arXiv preprint arXiv: 2007.12865 (2020) 1-10.
- [50] K. Zhou, H. Wang, W. X. Zhao, Y. Zhu, S. Wang, F. Zhang, Z. Wang, J. R. Wen, S3-Rec: Self-Supervised Learning for Sequential Recommendation with Mutual Information Maximization, in: Proceedings of the 29th ACM International Conference on Information and Knowledge Management, 2020, pp. 1893-1902.
- [51] X. Xin, A. Karatzoglou, I. Arapakis, J. M. Jose, Self-Supervised Reinforcement Learning for Recommender Systems, in: Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020, pp. 931-940.
- [52] X. Yuan, H. Chen, Y. Song, X. Zhao, Z. Ding, Improving Sequential Recommendation Consistency with Self-Supervised Imitation, in: Proceedings of the 30th International Joint Conference on Artificial Intelligence (IJCAI), 2021, pp. 3321-3327.
- [53] Z. Liu, Y. Ma, Y. Ouyang, Z. Xiong, Contrastive learning for recommender system, arXiv preprint arXiv: 2101.01317 (2021) 1-10.
- [54] X. Xie, F. Sun, Z. Liu, S. Wu, J. Gao, B. Ding, B. Cui, Contrastive Learning for Sequential Recommendation, arXiv preprint arXiv: 2010.14395 (2021) 1-11.
- [55] Y. Qin, P. Wang, C. Li, The World is Binary: Contrastive Learning for Denoising Next Basket Recommendation, in: Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2021, pp. 859-868.
- [56] W. X. Zhao, S. Mu, Y. Hou, Z. Lin, K. Li, Y. Chen, Y. Lu, H. Wang, C. Tian, X. Pan, Y. Min, Z. Feng, X. Fan, X. Chen, P. Wang, W. Ji, Y. Li, X. Wang, J.-R. Wen, RecBole: Towards a unified, comprehensive and efficient framework for recommendation algorithms, in: Proceedings of the 30th ACM International Conference on Information and Knowledge Management, 2021, pp. 4653-4664.