

سیستم توصیه‌گر اجتماعی مقاوم مبتنی بر یادگیری تقابلی گراف با نويز تخاصمی و ترازسازی دو - دامنه‌ای

محمد مهدی کیخا^{۱*}، ابوالفضل نادى^۲

^۱ استادیار گروه علوم کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران

^۲ استادیار گروه علوم کامپیوتر، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشکده‌گان علوم، دانشگاه تهران، تهران، ایران

چکیده

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۵/۰۲/۰۹

تاریخ پذیرش:

۱۴۰۵/۰۳/۲۸

کلیدواژه‌ها:

سیستم‌های توصیه‌گر اجتماعی،
یادگیری تقابلی گراف، نويز
تخاصمی، شبکه‌های عصبی
گراف، فیلتر مشارکتی

نویسنده مسئول:

keikha@cs.usb.ac.ir

بهره‌گیری از شبکه‌های اجتماعی به عنوان یک منبع اطلاعاتی کمکی، راهکاری مؤثر برای غلبه بر چالش پراکندگی داده‌ها در سیستم‌های توصیه‌گر محسوب می‌شود. با این حال، روابط اجتماعی در دنیای واقعی غالباً نويز دار بوده و فرض «همسویی کامل ترجیحات میان دوستان» همواره صادق نیست. اخیراً، یادگیری تقابلی گراف برای مقابله با این نويزها مورد توجه قرار گرفته است، اما رویکردهای رایج با تکیه بر روش‌های تصادفی مانند حذف یال‌ها، ساختار معنایی گراف را مخدوش کرده و بازنمایی‌های ناپایداری تولید می‌کنند. برای رفع این محدودیت‌ها، در این مقاله یک چارچوب نوین مبتنی بر یادگیری تقابلی گراف با استفاده از نويز تخاصمی پیشنهاد شده است. در این معماری، به جای ایجاد اختلال در ساختار گراف، با بهره‌گیری از روش گرادیان سریع، اختلالات هدفمندی به فضای پیوسته بازنمایی‌ها تزریق می‌شود تا نماهای تقابلی "سخت" و مقاومی تولید گردد. علاوه بر این، یک رویکرد یادگیری تقابلی دوگانه توسعه یافته است که شامل ترازسازی درون دامنه‌ای (برای استخراج ویژگی‌های خالص هر گراف) و میان‌دامنه‌ای (برای انتقال هدفمند سیگنال‌های مفید اجتماعی به دامنه تعاملی) است. ارزیابی‌های تجربی بر روی چهار مجموعه داده واقعی (Yelp, Epinions, Trustfilm, Ciao) نشان می‌دهد که مدل پیشنهادی در مقایسه با جدیدترین روش‌های پایه، به طور میانگین به میزان ۸/۵٪ در شاخص Recall و ۷/۲٪ در شاخص NDCG بهبود عملکرد داشته است. این نتایج اثربخشی استفاده از نويز تخاصمی را در استخراج بازنمایی‌های مقاوم و بهبود دقت توصیه‌ها تأیید می‌کند.

doi : 10.22034/ABMIR.2026.24499.1238

E-ISSN: 2821-2037

/The Author 2026. 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

در عصر دیجیتال، موتورهای جستجو و سیستم‌های توصیه‌گر ابزارهایی کلیدی برای غلبه بر گرانباری اطلاعات و ارائه محتوای شخصی‌سازی شده هستند [۱]. فیلتر مشارکتی (CF) به عنوان روشی پرکاربرد، ترجیحات آینده را بر اساس تعاملات تاریخی پیش‌بینی می‌کند [۲]؛ اما در مواجهه با پراکندگی شدید داده‌ها و شروع سرد با محدودیت مواجه است، زیرا تعاملات ثبت شده برای یادگیری دقیق کافی نیست [۳].

برای جبران کمبود داده‌های تعاملی، توصیه‌گرهای اجتماعی بر پایه نظریه تأثیرپذیری کاربران از دوستانشان توسعه یافته‌اند [۴]. شبکه‌های عصبی گراف (GNNs) با توانایی پردازش داده‌های ساختاریافته، به استاندارد طلایی این حوزه تبدیل شده‌اند [۵]. این مدل‌ها با تجمیع پیام‌ها در گراف‌های تعاملی و اجتماعی، وابستگی‌های مرتبه بالا را استخراج کرده و بازنمایی‌های غنی‌تری می‌سازند [۶].

با این حال، بهره‌گیری از اطلاعات اجتماعی پیچیدگی‌هایی دارد. برخلاف فرض ساده‌انگارانه روش‌های پیشین، ترجیحات دوستان همواره همسو نیست و هم‌زمان دارای هم‌پوشانی و واگرایی است (مثلاً سلیقه مشابه در موسیقی اما متفاوت در لباس) [۷]. افزون‌براین، گراف‌های اجتماعی غالباً حاوی نویز، پیوندهای منسوخ و بی‌معنی هستند. استفاده مستقیم از این روابط نویزدار در GNN، موجب انتشار سیگنال‌های گمراه‌کننده شده و پایداری و دقت مدل را به شدت کاهش می‌دهد [۶]، [۸].

برای مقابله با این پراکندگی و نویز، یادگیری تقابلی گراف (GCL) با ایجاد دیدگاه‌های افزوده و بیشینه‌سازی توافق میان آن‌ها، یادگیری ویژگی‌های ذاتی و مقاوم را تسهیل می‌کند [۹]. با این وجود، روش‌های فعلی GCL غالباً برای تولید این دیدگاه‌ها به رویکردهای تصادفی (نظیر حذف گره یا یال) متکی‌اند. این روش‌های تصادفی در گراف‌های به شدت درهم‌تنیده، اطلاعات حیاتی را تخریب کرده و با تولید نمای تقابلی بی‌کیفیت، باعث افت عملکرد مدل می‌شوند [۱۰].

برای غلبه بر محدودیت‌های فوق، در این مقاله یک چارچوب نوین و یکپارچه مبتنی بر یادگیری تقابلی گراف با بهره‌گیری از نویز تخصصی^۱ برای سیستم‌های توصیه‌گر اجتماعی پیشنهاد می‌شود. رویکرد پیشنهادی به جای استفاده از افزونگی‌های تصادفی و مخرب، از روش گرادیان سریع (FGM) برای تزریق نویزهای هدفمند و تخصصی به فضای پیوسته بردارهای بازنمایی گره‌ها استفاده می‌کند. این نویزها در جهت بیشینه‌سازی خطای مدل تولید می‌شوند و در نتیجه، نمای تخصصی حاصل، مدل را مجبور می‌کند تا بازنمایی‌های بسیار مقاوم‌تری از کاربران و آیتم‌ها بیاموزد که در برابر پیوندهای نویزدار اجتماعی آسیب‌پذیر نباشند.

علاوه بر این، برای حل چالش واگرایی ترجیحات و همسوسازی بهینه دانش میان دامنه‌های تعاملی و اجتماعی، چارچوب پیشنهادی یک مکانیزم یادگیری تقابلی دوگانه و هم‌زمان را به کار می‌گیرد. این رویکرد از دو فرایند مکمل تشکیل شده است. نخست، یادگیری تقابلی درون دامنه‌ای^۲ در هر یک از گراف‌ها به صورت مستقل، بازنمایی‌های اصلی را با نسخه‌های تخصصی آن‌ها (تولید شده توسط FGM) مقایسه می‌کند تا ویژگی‌های مقاوم و مختص به هر دامنه با حداکثر خلوص استخراج شوند. به طور هم‌زمان، یادگیری تقابلی میان‌دامنه‌ای^۳ بازنمایی‌های کاربران را از دو گراف اجتماعی و تعاملی در یک فضای تقابلی مشترک تراز می‌نماید. این هم‌تراز سازی تضمین می‌کند که مدل تنها آن دسته از سیگنال‌های اجتماعی را که با رفتار تعاملی کاربر همبستگی مثبت دارند، تقویت کرده و از انتقال اطلاعات حاصل از روابط اجتماعی نامرتبط و واگرا جلوگیری به عمل آورد.

در نهایت، مدل پیشنهادی با ترکیب خطای رتبه‌بندی شخصی‌سازی شده بیزی^۴ (BPR) و توابع هزینه تقابلی، بهینه‌سازی می‌شود. نوآوری‌های اصلی این مقاله را می‌توان در موارد زیر خلاصه نمود:

- طراحی یک چارچوب توصیه‌گر اجتماعی جدید که با جایگزین کردن افزونگی‌های تصادفی با نویز تخصصی در

^۴ Inter-domain Contrastive Learning

^۵ Bayesian Personalized Ranking

^۱ Adversarial Noise

^۲ Fast Gradient Method

^۳ Intra-domain Contrastive Learning

غیرخطی و پیچیده‌تری را ثبت کنند. باین‌حال، این مدل‌ها اغلب تنها تعاملات مستقیم را در نظر می‌گرفتند و از روابط مرتبه بالاتر در گراف تعاملات کاربر-آیتم غافل بودند.

برای رفع این محدودیت، شبکه‌های عصبی گراف (GNNs) به‌عنوان یک چارچوب قدرتمند معرفی شدند [۴]. مدل‌های GNN با بهره‌گیری از مکانیزم انتشار پیام^۳، اطلاعات را از گره‌های همسایه تجمیع کرده و بازنمایی‌های غنی‌تری تولید می‌کنند که روابط چند گامی^۴ را در خود جای داده است. روش‌های جدید از این ساختار برای استخراج سیگنال‌های همکاری مرتبه بالا استفاده کردند [۱۱]. پس‌از آن، LightGCN [۱۲] با حذف تبدیل‌های خطی و خود اتصالی‌ها در لایه‌های انتشار، نشان داد که یک طراحی ساده‌تر می‌تواند ضمن بهینه‌سازی فرایند آموزش، به عملکرد بهتری نیز منجر شود. باوجود این موفقیت‌های چشمگیر، این مدل‌ها همچنان با یک چالش اساسی روبه‌رو هستند: حساسیت به نویز در داده‌های تعاملی. وجود پیوندهای تصادفی یا غیرواقعی می‌تواند فرایند انتشار پیام را مختل کرده و کیفیت بازنمایی‌های نهایی را به شدت کاهش دهد [۱۳].

۲-۲ سیستم‌های توصیه‌گر اجتماعی

سیستم‌های توصیه‌گر اجتماعی با این فرض بنیادی شکل گرفتند که تصمیمات کاربران تحت تأثیر دوستان و ارتباطات اجتماعی آن‌ها قرار دارد [۱]. این مدل‌ها با ادغام اطلاعات شبکه اجتماعی در فرایند مدل‌سازی، به دنبال کاهش مشکلاتی نظیر پراکندگی داده‌ها و شروع سرد هستند [۳]. مدل‌های اولیه مانند SoRec [۱۴] و SocialMF [۱۵]، اطلاعات اجتماعی را به‌عنوان یک عبارت تنظیم‌کننده^۵ وارد چارچوب تجزیه ماتریس می‌کردند تا بردارهای پنهان کاربران متصل در شبکه اجتماعی به یکدیگر نزدیک‌تر شوند. با پیشرفت شبکه‌های عصبی گراف، مدل‌هایی نظیر GraphRec [۱۶] و DiffNet [۱۷] توانستند گراف تعاملات و گراف اجتماعی را به‌صورت هم‌زمان مدل‌سازی کنند. اگرچه این رویکردها دقت بالاتری به ارمغان آوردند، اما اکثر آن‌ها بر یک فرض شکننده استوارند: همسویی ترجیحات^۶؛ به این معنا که دوستان همواره

سطح بردارهای بازنمایی گره‌ها، آسیب‌پذیری مدل در برابر روابط اجتماعی کاذب را به‌طور چشمگیری کاهش می‌دهد. ▪ توسعه یک ساختار یادگیری تقابلی دوگانه (درون دامنه‌ای و میان‌دامنه‌ای) که به‌طور هوشمندانه‌ای ضمن حفظ استقلال ویژگی‌های دامنه تعاملی و اجتماعی، همسویی ترجیحات مرتبط را تسهیل می‌بخشد. ▪ ارزیابی‌های تجربی بر روی مجموعه داده‌های معتبر دنیای واقعی که نشان می‌دهد مدل پیشنهادی در مقایسه با روش‌های جدید، عملکرد برتری در معیارهای ارزیابی مختلف به ثبت می‌رساند.

ساختار ادامه مقاله به شرح زیر سازمان‌دهی شده است: بخش ۲ به‌مرور پیشینه پژوهش در زمینه سیستم‌های توصیه‌گر اجتماعی و یادگیری تقابلی گراف می‌پردازد. در بخش ۳، چارچوب پیشنهادی و جزئیات روش‌شناسی مدل به‌طور جامع فرمول‌بندی و تشریح می‌شود. بخش ۴ به تشریح تنظیمات آزمایشگاهی، ارزیابی روی مجموعه داده‌ها و تحلیل نتایج تجربی اختصاص یافته است. در نهایت، بخش ۵ به جمع‌بندی دستاوردهای مقاله پرداخته و چشم‌اندازی از مسیرهای پژوهشی آتی را ترسیم می‌کند.

۲- کارهای مرتبط

در این بخش، به‌مرور جامع پیشینه پژوهش در سه حوزه کلیدی مرتبط با روش پیشنهادی می‌پردازیم: سیستم‌های توصیه‌گر مبتنی بر شبکه‌های عصبی گراف، سیستم‌های توصیه‌گر اجتماعی و یادگیری تقابلی گراف.

۲-۱ سیستم‌های توصیه‌گر مبتنی بر GNN

روش‌های سنتی فیلتر مشارکتی (CF) [۱۳] به‌ویژه مدل‌های مبتنی بر تجزیه ماتریس^۱ (MF) [۸]، به دلیل سادگی و اثربخشی، مدت‌ها سنگ بنای سیستم‌های توصیه‌گر بوده‌اند. این روش‌ها با یادگیری بردارهای پنهان^۲ برای کاربران و آیتم‌ها، تعاملات میان آن‌ها را مدل‌سازی می‌کنند. با ظهور یادگیری عمیق، مدل‌هایی مانند NCF [۱۰] با استفاده از پرسپترون‌های چندلایه (MLP) توانستند تعاملات

^۴ Multi-hop

^۵ Regularization Term

^۶ Preference Homophily

^۱ Matrix Factorization

^۲ Latent Vectors

^۳ Message Passing

GCL [۲۲] و Social Graph Diffusion [۲۳] بر ایجاد نماهای تقابلی از طریق ساختارهای مختلف (گراف اجتماعی و تعاملی) تمرکز کرده‌اند تا دانش را میان دامنه‌ها منتقل کنند.

با وجود این پیشرفت‌ها، وابستگی اکثر روش‌ها به داده‌افزایی‌های مخرب ساختار یا فرایندهای بهینه‌سازی بسیار پرهزینه، نشان‌دهنده یک شکاف پژوهشی قابل توجه در این حوزه است. در این میان، رویکردی بدیع و کارآمدتر که تاکنون کمتر به آن پرداخته شده، تولید نماهای تقابلی از طریق تزریق نویز در فضای بازنمایی^۴ است. این راهکار قادر است بدون دست‌کاری ساختار اصلی گراف، نماهای سخت^۵ و درعین حال معناداری ایجاد کند که تاب‌آوری مدل را در برابر نویز به میزان چشمگیری افزایش می‌دهد. در همین راستا و در بخش ۳، چارچوب پیشنهادی خود را معرفی می‌کنیم؛ چارچوبی که با اتکا به این ایده و بهره‌گیری از نویزهای تخصصی هدفمند، شکاف پژوهشی موجود را برطرف ساخته و بازنمایی‌های مقاومی برای سیستم توصیه‌گر اجتماعی ارائه می‌دهد.

۳- روش پیشنهادی

پیرو مباحث مطرح‌شده در بخش ۲ پیرامون محدودیت‌های روش‌های سنتی تقویت داده، در این بخش چارچوب پیشنهادی برای سیستم توصیه‌گر اجتماعی معرفی می‌گردد. هدف اصلی این معماری، استخراج بازنمایی‌های غنی و مقاوم از کاربران و آیتم‌ها با بهره‌گیری از گراف‌های تعاملی و اجتماعی است. برای غلبه بر مشکل نویز و پراکندگی داده‌ها، این چارچوب تقویت داده‌های ساختاری (مانند حذف تصادفی یال‌ها) را کنار گذاشته و به جای آن از تولید نماهای تخصصی در فضای بازنمایی بهره می‌برد. در شکل ۱، نمای کلی این معماری شامل بخش‌های انتشار پیام، تولیدگر نویز تخصصی و مکانیزم یادگیری تقابلی دوگانه نشان داده شده است که در ادامه، اجزای ساختاری و ریاضی آن به تفصیل تشریح می‌شوند.

تمایلات مشابهی دارند. درواقعیت، روابط اجتماعی غالباً حاوی نویز هستند (مانند دنبال کردن افراد مشهور بدون داشتن سلیقه مشترک) و ترجیحات کاربران در حوزه‌های مختلف می‌تواند کاملاً واگرا باشد [۶]. در این راستا، مدل ارائه شده در [۱۸] با استفاده از شبکه‌های مبتنی بر مکانیزم همجوشی دوطرفه، گامی در جهت فیلترکردن نویز در روابط اجتماعی برداشته است. با این وجود، همچنان نیاز به روش‌هایی احساس می‌شود که بتوانند بدون تأثیرپذیری منفی از نویز و واگرایی ترجیحات، دانش مفید را از گراف اجتماعی استخراج کنند.

۲-۳ یادگیری تقابلی گراف برای توصیه‌گرها

یادگیری تقابلی^۱ به عنوان یک مفهوم موفق در یادگیری خودنظارتی، باهدف یادگیری بازنمایی‌های مقاوم از طریق بهینه‌سازی توافق میان نماهای مختلف از یک داده ظهور کرده است. در حوزه توصیه‌گرها، یادگیری تقابلی گراف^۲ (GCL) برای مقابله با پراکندگی داده‌ها بسیار مورد توجه قرار گرفته است [۷].

روش‌های GCL بر اساس استراتژی تولید نما دسته‌بندی می‌شوند. رایج‌ترین رویکرد، استفاده از داده‌افزایی‌های تصادفی مبتنی بر ساختار^۳ است. به عنوان مثال، SGL [۱۹] با اعمال حذف تصادفی گره و یال بر روی گراف، نماهای تقابلی ایجاد می‌کند. اگرچه این روش‌ها مؤثرند، اما ماهیت تصادفی آن‌ها می‌تواند به تخریب اطلاعات معنایی حیاتی در گراف منجر شده و بازنمایی‌های ناپایداری تولید کند.

برای غلبه بر این چالش، مدل‌هایی نظیر EGCL [۲۰] یادگیری تقابلی بدون داده‌افزایی^۴ را پیشنهاد داده‌اند تا از تخریب ساختار جلوگیری شود. رویکردهای دیگری مانند RCGRL [۲۱] از یادگیری تقویتی برای یافتن سیاست بهینه در تغییر گراف بهره می‌برند که باوجود قدرت بالا، پیچیدگی محاسباتی شدیدی به همراه دارند. در سمتی دیگر، روش‌هایی مانند Multi-topology

^۴ Augmentation-free CL


^۵ Perturbations in Representation Space

^۶ Hard Views

^۱ Contrastive Learning

^۲ Graph Contrastive Learning

^۳ Structure-based Stochastic Augmentations



شکل (۱): نمای کلی چارچوب پیشنهادی شامل ماژول انتشار پیام، تولیدگر نويز تخصصی مبتنی بر FGM، و یادگیری تقابلی درون دامنه‌ای و میان‌دامنه‌ای

بازنمایی‌ها استفاده می‌گردد. درنهایت، ماژول یادگیری تقابلی دوگانه (شامل ترازسازی درون‌دامنه‌ای و میان‌دامنه‌ای) برای بهینه‌سازی و همسوسازی این بازنمایی‌ها به کار گرفته می‌شود. در ادامه، جزئیات و روابط ریاضی هر یک از این مؤلفه‌ها به تفصیل تشریح می‌گردند.

همان‌طور که در شکل ۱ مشاهده می‌شود، معماری چارچوب پیشنهادی از سه ماژول اصلی تشکیل شده است: ابتدا در ماژول انتشار پیام، بازنمایی‌های اولیه گره‌ها از طریق گراف‌های تعاملی و اجتماعی استخراج می‌شوند. سپس، به جای استفاده از روش‌های تصادفی مانند حذف بال، از یک تولیدگر نويز تخصصی (مبتنی بر FGM) برای ایجاد نماهای نويزی و مقاوم در فضای پیوسته

۱-۳ فرمول‌بندی مسئله و مقداردهی اولیه

مجموعه کاربران را با $U = u_1, u_2, \dots, u_M$ و مجموعه آیت‌ها را با $I = i_1, i_2, \dots, i_N$ در نظر می‌گیریم که در آن M تعداد کاربران و N تعداد آیت‌ها است. تعاملات کاربری به صورت یک ماتریس $Y \in \mathbb{R}^{M \times N}$ تعریف می‌شود؛ به طوری که اگر کاربر u با آیت i تعامل داشته باشد $y_{ui} = 1$ و در غیر این صورت 0 خواهد بود. همچنین، گراف اجتماعی کاربران با ماتریس مجاورت $A_{social} \in \mathbb{R}^{M \times M}$ مدل‌سازی می‌گردد.

در گام نخست، شناسه هر کاربر و آیت به یک بردار متراکم در فضای پنهان با بعد d نگاشت می‌شود. ماتریس بردارهای بازنمایی گره‌ها برای کاربران به صورت $E_U^{(0)} \in \mathbb{R}^{M \times d}$ و برای آیت‌ها به صورت $E_I^{(0)} \in \mathbb{R}^{N \times d}$ تعریف می‌گردد. این ماتریس‌ها، پارامترهای آموزش‌پذیر مدل (مجموعه Θ) را تشکیل می‌دهند.

۲-۳ رمزگذار گراف و انتشار پیام چندلایه

برای استخراج الگوهای ساختاری و وابستگی‌های مرتبه بالاتر، از مکانیزم انتشار پیام گراف با الهام از معماری‌های ساده‌شده (بدون توابع فعال‌ساز غیرخطی) استفاده می‌کنیم. این فرایند در دو دامنه مجزا انجام می‌پذیرد:

۱-۲-۳ دامنه تعاملی^۱:

گراف دویخشی تعاملات کاربر-آیت دارای ماتریس مجاورت ساختاریافته‌ای است که به صورت تقارنی نرمال‌سازی می‌شود. ماتریس نرمال‌شده را با $\hat{A}_{inter} = D_{inter}^{-1/2} A_{inter} D_{inter}^{-1/2}$ نشان می‌دهیم که در آن D_{inter} ماتریس درجه برای گراف تعاملی است. در لایه l -ام از شبکه عصبی گراف، بردارهای بازنمایی به شکل زیر به‌روزرسانی می‌شوند:

$$E_{inter}^{(l)} = \hat{A}_{inter} E_{inter}^{(l-1)} \quad (۱)$$

در این رابطه، $E_{inter}^{(l)}$ بازنمایی کاربران و آیت‌ها در لایه l پس از دریافت پیام از همسایگان تعاملی است.

۲-۲-۳ دامنه اجتماعی^۲:

به طور مشابه، ماتریس روابط اجتماعی به صورت $\hat{A}_{social} = D_{social}^{-1/2} A_{social} D_{social}^{-1/2}$ نرمال‌سازی می‌شود (D_{social} ماتریس درجه گراف اجتماعی است). انتشار پیام در این دامنه (فقط برای کاربران) به این صورت است:

$$E_{social}^{(l)} = \hat{A}_{social} E_{social}^{(l-1)} \quad (۲)$$

۳-۲-۳ تجميع لایه‌ها^۳:

به منظور جلوگیری از پدیده هموارسازی بیش‌ازحد^۴ که معمولاً در شبکه‌های گراف عمیق رخ می‌دهد، خروجی تمامی L لایه با استفاده از عملگر ادغام میانگین^۵ ترکیب می‌شوند تا بازنمایی نهایی هر گره به دست آید:

$$E_{inter}^{final} = \frac{1}{L+1} \sum_{l=0}^L E_{inter}^{(l)} \quad (۳)$$

$$E_{social}^{final} = \frac{1}{L+1} \sum_{l=0}^L E_{social}^{(l)} \quad (۴)$$

در نهایت، بردار استخراج‌شده برای یک کاربر خاص u در دامنه تعاملی را با $e_{u,inter}$ و در دامنه اجتماعی را با $e_{u,social}$ مشخص می‌کنیم.

پدیده هموارسازی بیش‌ازحد در شبکه‌های عصبی گرافی عمیق زمانی رخ می‌دهد که با افزایش تعداد لایه‌ها، بازنمایی تمام گره‌ها به یک بردار همگن و غیرقابل تمایز همگرا می‌شود و اطلاعات محلی گره از دست می‌رود. ادغام میانگین یا ترکیب خروجی تمامی لایه‌ها، مشابه یک اتصال میان‌بر^۶ عمل می‌کند. لایه‌های ابتدایی حاوی اطلاعات محلی و ساختاری نزدیک گره (همسایگان درجه یک) هستند، درحالی‌که لایه‌های عمیق‌تر، اطلاعات سراسری‌تری را استخراج می‌کنند. با میانگین‌گیری روی خروجی همه لایه‌ها، مدل تضمین می‌کند که ویژگی‌های محلی و اولیه گره‌ها در بازنمایی نهایی حفظ‌شده و تحت تأثیر همگرایی لایه‌های آخر محو نمی‌شوند.

^۴ Over-smoothing

^۵ Mean Pooling

^۶ Residual Connection

^۱ Interaction Domain

^۲ Social Domain

^۳ Layer Aggregation

$$E' = E + \Delta$$

(۷)

پس از محاسبه E' ، این بازنمایی‌های نويزدار به جای بازنمایی‌های اولیه، وارد لایه‌های انتشار پیام گراف (گراف تعاملی و اجتماعی) می‌شوند و خروجی آن‌ها برای محاسبه تابع زیان تقابلی مورد استفاده قرار می‌گیرد.

$$\tilde{e}_{u,inter} = e_{u,inter} + \Delta_{u,inter} \quad (۸)$$

$$\tilde{e}_{u,social} = e_{u,social} + \Delta_{u,social} \quad (۹)$$

از نظر هندسی، بازنمایی‌ها نقاطی در یک فضای بازنمایی چندبعدی هستند. شدت نويز تخصصی (که معمولاً با پارامتری مثل ϵ کنترل می‌شود) شعاع کره‌ای را تعیین می‌کند که در آن به دنبال بدترین اختلال می‌گردیم. اگر این شدت خیلی بزرگ انتخاب شود، نويز تولید شده نقطه بازنمایی را آن قدر از مکان اصلی خود دور می‌کند که از مرز معنایی خود عبور کرده و وارد ناحیه معنایی نمونه‌های دیگر (مثلاً کاربران با سلیقه کاملاً متفاوت) می‌شود. این امر باعث می‌شود که نمای تقابلی تولید شده دیگر نشان‌دهنده همان کاربر یا آیتم نباشد (منظور همان False Positive است). در نتیجه، مدل در حین یادگیری تقابلی سعی می‌کند دو نقطه بی‌ربط را به هم نزدیک کند که منجر به فروپاشی فضای بازنمایی و افت شدید عملکرد سیستم توصیه‌گر می‌شود.

۳-۴ یادگیری تقابلی دوگانه^۳

برای اطمینان از اینکه مدل قادر است ویژگی‌های مشترک و مکمل دو دامنه را به درستی بیاموزد، از یک تابع زیان تقابلی مبتنی بر InfoNCE بهره می‌گیریم. فرمول پایه برای هم‌ترازی دو بردار v_i و v'_i در یک دسته^۴ با اندازه B به صورت زیر تعریف می‌شود. تابع زیان تقابلی (InfoNCE) برای یک دسته (Batch) با اندازه B محاسبه می‌گردد. فرض کنید بردار v_i نمای اولیه (تمیز) و بردار v'_i نمای نويزدار (تخصصی) برای گره i باشد که یک زوج مثبت را تشکیل می‌دهند. سایر گره‌های موجود در همان دسته به عنوان نمونه‌های منفی در نظر گرفته می‌شوند. فرمول زیان برای گره i به صورت زیر است:

۳-۳ تولید نماهای تقابلی با نويز تخصصی

در روش‌های استاندارد یادگیری تقابلی گراف (مانند SGL)، نماهای متفاوت معمولاً از طریق حذف تصادفی یال‌ها تولید می‌شوند که این امر می‌تواند به ازدست‌رفتن اطلاعات کلیدی ساختار گراف منجر شود. در روش پیشنهادی، این الگو جایگزین شده و از روش گرادیان سریع (FGM) برای اعمال اختلالات هوشمند در فضای متراکم بازنمایی استفاده می‌گردد.

برخلاف روش‌های مبتنی بر حذف یال که با تغییر ساختار گراف ممکن است مسیرهای ارتباطی مهم و حیاتی شبکه را از بین ببرند، تزریق نويز تخصصی در فضای بازنمایی، هندسه اصلی گراف را کاملاً حفظ می‌کند. این نويزهای تخصصی به عنوان نمونه‌های منفی سخت^۱ عمل کرده و مرزهای تصمیم‌گیری مدل را چالش‌برانگیزتر می‌کنند. در نتیجه، مدل مجبور می‌شود بازنمایی‌های پایدارتر و مقاوم‌تری بیاموزد که وابستگی کمتری به نوسانات کوچک دارند، بدون آنکه خطر از بین رفتن سیگنال‌های همسایگی مفید وجود داشته باشد.

بدین منظور، ابتدا گرادیان تابع زیان اصلی (BPR) نسبت به ماتریس بازنمایی‌ها (E) محاسبه می‌شود:

$$g = \nabla_E \mathcal{L}_{BPR} \quad (۵)$$

سپس، نويز تخصصی Δ با نرمال‌سازی این گرادیان و ضرب آن در پارامتر کنترل‌کننده دامنه نويز (یعنی ϵ) محاسبه می‌گردد:

$$\Delta = \epsilon \frac{g}{\|g\|_2} \quad (۶)$$

در این رابطه، ϵ یک پارامتر حیاتی است که شدت اختلال را تنظیم می‌کند و $\|g\|_2$ همان نرمال‌سازی درجه دوم^۲ ماتریس گرادیان است که جهت جلوگیری از تغییر مقیاس بیش‌ازحد گرادیان‌ها به کار می‌رود. با افزودن این نويز به بردارهای پایه، نماهای تخصصی (نماهای سخت) برای هر دو دامنه تولید می‌شوند. در واقع، نويز محاسبه شده Δ به بازنمایی‌های اولیه گره‌ها افزوده می‌شود تا بازنمایی‌های نويزدار (تخصصی) به دست آیند. اگر ماتریس بازنمایی اولیه را E در نظر بگیریم، نمای تخصصی E' به شکل زیر محاسبه می‌شود:

^۳ Dual Contrastive Learning

^۴ Batch

^۱ Hard Negatives

^۲ L2-Norm

$$\mathcal{L}_{inter} = \sum_{u \in U} \mathcal{L}_{InfoNCE}(e_{u,social}, \tilde{e}_{u,inter}) \quad (12)$$

در روش پیشنهادی در این مقاله، یادگیری تقابلی میان‌دامنه‌ای به‌عنوان یک سازوکار بهینه‌سازی اطلاعات متقابل بین دامنه اجتماعی و دامنه تعاملی عمل می‌کند. از آنجاکه گراف‌های اجتماعی غالباً دارای نویز هستند (مثلاً دو کاربر دوست هستند؛ اما سلاقی متفاوتی دارند)، با هم‌تراز نمودن بازنمایی کاربر در گراف اجتماعی با بازنمایی وی در گراف تعاملات، مدل مجبور می‌شود تنها آن دسته از ویژگی‌های اجتماعی را حفظ کند که با رفتار واقعی کاربر همخوانی دارند. درنتیجه، اثر روابط نامرتبط که نمود خارجی در تعاملات ندارند، به‌طور خودکار تضعیف و فیلتر می‌شود.

۳-۵ پیش‌بینی و تابع زیان نهایی

جهت پیش‌بینی احتمال تعامل کاربر u با آیتم i ، از ضرب داخلی بازنمایی‌های نهایی تعاملی آن‌ها استفاده می‌شود:

$$\hat{y}_{ui} = (e_{u,inter})^T e_{i,inter} \quad (13)$$

وظیفه اصلی توصیه‌گر از طریق بهینه‌سازی تابع زیان BPR انجام می‌گیرد. این تابع بر این فرض استوار است که کاربر به آیتم‌های تعامل داشته (i) نسبت به آیتم‌های تعامل نداشته (j) ترجیح بالاتری قائل است:

$$\mathcal{L}_{BPR} = - \sum_{(u,i,j) \in \mathcal{O}} \log \sigma(\hat{y}_{ui} - \hat{y}_{uj}) \quad (14)$$

که در آن $\mathcal{O}$ مجموعه داده‌های آموزشی (شامل سه‌گانه‌های کاربر، آیتم مثبت، آیتم منفی) و $\sigma(\cdot)$ تابع فعال‌ساز است.

درنهایت، تمامی توابع زیان معرفی شده در یک تابع هدف جامع ترکیب می‌شوند تا مدل به‌صورت یکپارچه آموزش ببیند:

$$\mathcal{L}_{total} = \mathcal{L}_{BPR} + \lambda_{intra} \mathcal{L}_{intra} + \lambda_{inter} \mathcal{L}_{inter} + \lambda_{reg} \|\Theta\|_2^2 \quad (15)$$

در رابطه (۱۵) λ_{intra} و λ_{inter} ضرایبی برای کنترل شدت تأثیر یادگیری تقابلی دوگانه هستند. پارامتر λ_{reg} نیز ضریب تنظیم‌کننده نرمال‌سازی درجه دوم روی پارامترهای مدل (Θ) است که جهت جلوگیری از بیش‌برازش اعمال می‌گردد.

با تعریف این تابع هدف یکپارچه و تشریح دقیق مکانیزم‌های مدل، چارچوب پیشنهادی قادر به یادگیری بازنمایی‌هایی بسیار مقاوم و دقیق خواهد بود. در بخش ۴، با معرفی مجموعه داده‌ها و معیارهای

$$\mathcal{L}_{InfoNCE}(v_i, v'_i) = - \log \frac{\exp(\text{sim}(v_i, v'_i)/\tau)}{\sum_{j=1}^B \exp(\text{sim}(v_i, v'_j)/\tau)} \quad (10)$$

که در آن، $\text{sim}(\cdot, \cdot)$ تابع شباهت کسینوسی بین دو بردار بوده و τ پارامتر دما است که حساسیت مدل را نسبت به نمونه‌های منفی کنترل می‌کند. زیان تقابلی کل برای مدل در هر مرحله آموزش، برابر با میانگین این مقدار برای تمامی B نمونه موجود در دسته^۱ خواهد بود. این ساختار تضمین می‌کند که بازنمایی هر گره به نسخه نویزدار خود نزدیک شده و از سایر گره‌های موجود در دسته دور شود.

پارامتر دما (τ) در تابع زیان تقابلی InfoNCE، نقش کنترل‌کننده سختی یا تمرکز مدل بر روی نمونه‌های منفی دشوار را بر عهده دارد. مقدار کوچک‌تر τ باعث می‌شود توزیع احتمال حاصل از Softmax تیزتر شود؛ یعنی مدل توجه و پنازتی بیشتری به نمونه‌های منفی که بسیار شبیه به نمونه لنگر^۲ هستند اختصاص می‌دهد و سعی می‌کند آن‌ها را با شدت بیشتری از نمونه مثبت دور کند. برعکس، مقادیر بزرگ‌تر τ باعث توزیع هموارتر می‌شود که در آن همه نمونه‌های منفی به‌طور نسبتاً مساوی دفع می‌شوند؛ بنابراین، تنظیم دقیق τ به مدل کمک می‌کند تا بین جداسازی دقیق و جلوگیری از بیش‌برازش تعادل ایجاد کند.

ما این تابع را در دو سطح مجزا اعمال می‌کنیم:

۳-۴-۱ تقابل درون دامنه‌ای:

این مکانیزم وظیفه دارد بازنمایی تمیز هر کاربر را با نسخه نویزدار تخصیصی همان کاربر در همان دامنه هم‌تراز کند؛ این امر موجب افزایش پایداری مدل در برابر نویز درونی هر گراف می‌شود:

$$\mathcal{L}_{intra} = \sum_{u \in U} [\mathcal{L}_{InfoNCE}(e_{u,inter}, \tilde{e}_{u,inter}) + \mathcal{L}_{InfoNCE}(e_{u,social}, \tilde{e}_{u,social})] \quad (11)$$

۳-۴-۲ تقابل میان‌دامنه‌ای:

به‌منظور انتقال دانش و استخراج سیگنال‌های پنهان میان رفتار تعاملی و شبکه دوستان، نمای تمیز دامنه اجتماعی با نمای تخصیصی دامنه تعاملی مقایسه می‌شود. این فرایند تضمین می‌کند که گراف اجتماعی از سیگنال‌های غنی‌تر تعاملی بهره‌مند گردد:

² Anchor

¹ Batch

پیشنهادی به صورت خطی با تعداد لبه‌های گراف رابطه دارد و برای مجموعه داده‌های بزرگ مقیاس پذیر است.

۴- آزمایش‌ها و ارزیابی نتایج

پس از تبیین معماری مدل و فرمول‌بندی‌های ریاضی روش پیشنهادی در بخش ۳، در این بخش، به منظور ارزیابی کارایی و اثربخشی روش پیشنهادی، مجموعه‌ای از آزمایش‌های جامع روی یک مجموعه داده استاندارد و شناخته شده در حوزه سیستم‌های توصیه گر اجتماعی انجام شده است. هدف اصلی از طراحی این آزمایش‌ها، پاسخگویی به دو پرسش اساسی پژوهشی است. نخست آنکه عملکرد چارچوب پیشنهادی در مقایسه با مدل‌های جدید در سیستم‌های توصیه گر (اعم از مدل‌های مبتنی بر اطلاعات اجتماعی و بدون آن) چگونه ارزیابی می‌شود. پرسش دوم نیز به بررسی میزان تأثیرگذاری پارامترهای کلیدی مدل، از جمله ضرایب یادگیری تقابلی و شعاع نویز تخصصی، بر عملکرد نهایی سیستم پرداخته و به دنبال یافتن مقادیر بهینه برای این تنظیمات است.

۴-۱ مجموعه داده

برای ارزیابی تجربی روش پیشنهادی و مقایسه جامع آن با روش‌های پایه، از چهار مجموعه داده معتبر و پرکاربرد در حوزه سیستم‌های پیشنهاددهنده اجتماعی استفاده شده است: Ciao، Epinions، Yelp و Trustfilm.

این مجموعه داده‌ها شامل دو نوع اطلاعات اصلی هستند: (۱) گراف تعاملات کاربر - آیتم (مانند امتیازدهی یا خرید) که به دلیل ماهیت پراکنده این شبکه‌ها، یادگیری بازنمایی‌های دقیق را چالش برانگیز می‌کند؛ و (۲) گراف روابط اجتماعی بین کاربران (مانند فهرست دوستان یا اعتماد) که به عنوان اطلاعات کمکی برای غلبه بر مشکل پراکندگی داده‌ها و بهبود کیفیت پیشنهادها استفاده می‌شود.

تنوع در ابعاد و میزان پراکندگی این چهار مجموعه داده، ارزیابی دقیق‌تری از مقیاس‌پذیری و پایداری مدل پیشنهادی در شرایط مختلف فراهم می‌کند. آمار و مشخصات دقیق این مجموعه داده‌ها در جدول ۱ خلاصه شده است.

ارزیابی، به بررسی تجربی این چارچوب پرداخته و عملکرد آن را در مقایسه با روش‌های جدید تحلیل خواهیم کرد.

۳-۶ تحلیل پیچیدگی

در این بخش، پیچیدگی زمانی و فضایی روش پیشنهادی را مورد تحلیل قرار می‌دهیم. فرض کنید U تعداد کاربران، I تعداد آیتم‌ها، E_r تعداد لبه‌های تعاملی (کاربر-آیتم)، E_s تعداد لبه‌های اجتماعی (کاربر-کاربر)، d بعد بردار بازنمایی، L تعداد لایه‌های شبکه عصبی گرافی و B اندازه دسته در هر تکرار باشد.

۳-۶-۱ پیچیدگی فضایی

از آنجاکه روش پیشنهادی همانند مدل‌های مبتنی بر LightGCN [۱۳]، از ماتریس‌های وزن سنگین و تبدیل‌های غیرخطی در لایه‌های انتشار پیام استفاده نمی‌کند، تنها پارامترهای قابل آموزش مدل، ماتریس بازنمایی اولیه برای کاربران و آیتم‌ها هستند؛ بنابراین، پیچیدگی فضایی مدل برابر با $O((|U| + |I|) \times d)$ است که بسیار بهینه بوده و از نظر مصرف حافظه با روش‌های پایه ماتریسی برابری می‌کند.

۳-۶-۲ پیچیدگی زمانی

پیچیدگی زمانی مدل شامل سه بخش اصلی در هر دوره (Epoch) است:

- **انتشار پیام:** برای استخراج بازنمایی‌ها در گراف تعاملی و اجتماعی، هزینه محاسباتی در L لایه برابر با $O(L \cdot (|U| + |I|) \cdot d)$ است.
 - **تولید نویز تخصصی:** اعمال نویز FGM نیازمند محاسبه گرادیان و جمع برداری است که در هر دسته $O(B \cdot d)$ و برای کل داده‌ها $O((|U| + |I|) \cdot d)$ زمان می‌برد.
 - **یادگیری تقابلی و بهینه‌سازی:** محاسبه توابع زیان تقابلی دوگانه و BPR نیازمند ضرب داخلی بردارهاست که برای کل گره‌ها از مرتبه $O(B \cdot d)$ در هر دسته و در کل $O((|U| + |I|) \cdot d)$ است.
- با توجه به اینکه معمولاً $(|U| + |I|) \gg (|E_r| + |E_s|)$ است، پیچیدگی زمانی کلی مدل برابر با $O(L \cdot (|E_r| + |E_s|) \cdot d)$ خواهد بود. این نشان می‌دهد که زمان اجرای روش

۲-۲-۴ معیارهای ارزیابی

به منظور سنجش دقت فهرست‌های توصیه‌شده توسط مدل‌ها، از معیارهای استاندارد ارزیابی رتبه‌بندی شامل Precision@20, Recall@20, NDCG@20 و MAP@20 استفاده شده است. در این معیارها، نماد @ به همراه عدد ۲۰ نشان‌دهنده نقطه برش^۱ است؛ بدین معنا که عملکرد سیستم توصیه‌گر تنها بر روی ۲۰ پیشنهاد برتر ارائه‌شده به کاربر ارزیابی می‌شود.

۳-۴ مقایسه عملکرد و تحلیل نتایج

به منظور ارزیابی اثربخشی روش پیشنهادی، عملکرد آن با ۸ روش پایه (شامل مدل‌های سنتی فیلترینگ مشارکتی، مدل‌های مبتنی بر شبکه‌های عصبی گرافی، و روش‌های پیشرفته مبتنی بر اطلاعات اجتماعی و یادگیری تقابلی) بر روی چهار مجموعه داده مختلف مقایسه شده است. نتایج جامع این ارزیابی بر اساس معیارهای Precision@20, Recall@20, MAP@20 و NDCG@20 در جدول ۲ گزارش شده است.

۱-۳-۴ تحلیل برتری‌های روش پیشنهادی

همان‌طور که در جدول ۲ مشاهده می‌شود، روش پیشنهادی در اکثریت قریب به اتفاق معیارها و روی تمامی مجموعه داده‌ها عملکرد برتری نسبت به مدل‌های رقیب از خود نشان می‌دهد. دلایل اصلی این برتری را می‌توان در موارد زیر خلاصه کرد:

- **غلبه بر پراکندگی داده‌ها:** در مقایسه با مدل‌های پایه مانند BPRMF و LightGCN، روش پیشنهادی با بهره‌گیری از مازول یادگیری تقابلی، توانسته است سیگنال‌های نظارتی بیشتری از خود داده‌ها استخراج کند که این امر به‌ویژه در دیتاست‌های بسیار پراکنده مانند Epinions منجر به جهش قابل توجهی در معیار NDCG شده است.
- **استفاده بهینه از روابط اجتماعی:** در مقایسه با مدل‌های آگاه از گراف اجتماعی مانند ++Diffnet و DcRec، روش پیشنهادی صرفاً به تجمیع ساده همسایگان بسنده نمی‌کند، بلکه با اعمال نویزهای در فضای حالات ابعاد، بازنمایی‌های بسیار مقاوم‌تری در برابر لینک‌های نویزدار و نامرتب

جدول (۱): آمار و ویژگی‌های مجموعه داده‌های Ciao, Yelp, Trustfilm و Epinions

نام مجموعه داده	کاربران (users)	آیتم‌ها (Items)	تعاملات (Actions)	روابط اجتماعی (Social relations)	درصد پراکندگی (Sparsity)
Ciao	۷۲۶۷	۱۱۲۱۱	۱۴۷۹۹۵	۱۱۱۷۸۱	۹۹/۸۲
Yelp	۸۱۶۳	۷۹۰۰	۷۳۰۹۸	۱۸۴۴۹۶	۰/۱۱۳
Epinions	۸۶۱۳۰	۳۷۲۵	۱۶۷۵۰	۵۸۲۳۱۵	۰/۰۰۵
Trustfilm	۱۶۴۲	۲۰۷۱	۳۵۴۹۷	۱۸۵۳	۹۸/۹۶

۲-۴ تنظیمات آزمایش

۱-۲-۴ روش‌های پایه برای مقایسه

برای اعتبارسنجی کارایی چارچوب پیشنهادی، عملکرد آن با طیف متنوعی از مدل‌های جدید مقایسه شده است که شامل دسته‌های زیر هستند:

BPRMF [۲۴]: یک رویکرد پایه مبتنی بر تجزیه ماتریس که از تابع زیان BPR استفاده می‌کند.

LightGCN [۱۲]: یک مدل پیشرفته مبتنی بر GNN برای فیلترسازی مشارکتی که فرایند انتشار پیام را با حذف تغییرات غیرخطی، ساده‌سازی کرده است.

DiffNet++ [۲۵]: یک توصیه‌گر اجتماعی که از شبکه‌های عصبی گرافی برای مدل‌سازی هم‌زمان و یکپارچه گراف تعاملات و گراف اجتماعی بهره می‌برد.

XSimGCL [۲۶]: روشی نوین مبتنی بر یادگیری تقابلی که به جای استفاده از افزونه‌سازی ساختاری (مانند حذف یال)، از افزودن نویز تصادفی به بازنمایی‌ها استفاده می‌کند.

توصیه‌گرهای اجتماعی مبتنی بر GCL: این گروه شامل مدل‌های به‌روز و پیشرفته‌ای نظیر DcRec [۲۷] و DSL [۲۸] و DENS [۲۹] و EAGCN [۳۰] و EGCL [۲۰] است که از یادگیری تقابلی بر روی گراف‌های تعاملی و اجتماعی استفاده می‌کنند. در این میان، EGCL [۲۰] به دلیل معماری کارآمد، به عنوان یکی از قوی‌ترین مدل‌های پیشرو در این ارزیابی در نظر گرفته شده است.

^۱ Cut-off

علی‌رغم برتری کلی، در دو مورد جزئی رقابت بسیار نزدیکی با مدل پیشرفته EAGCN مشاهده می‌شود که از منظر منطق سیستم‌های توصیه‌گر کاملاً قابل توجه است:

▪ **معیار Recall@20 در مجموعه داده Yelp:** در این دیتاست،

میزان Recall روش پیشنهادی (۳/۱۷۵۵) تفاوت بسیار ناچیزی با مدل EAGCN (۳/۱۸۰۰) دارد. این مسئله به این دلیل است که دیتاست Yelp دارای تنوع رفتاری بالایی است و مدل EAGCN با رویکردی تهاجمی‌تر سعی در بازیابی طیف گسترده‌تری از آیتم‌ها دارد که به قیمت افت دقت تمام می‌شود. در مقابل، روش پیشنهادی موفق شده است با حفظ تمرکز بر کیفیت رتبه‌بندی، مقادیر Precision و NDCG بالاتری را ثبت کند. در سیستم‌های توصیه‌گر واقعی، دقت بالا در فهرست‌های کوتاه (Top-K) و کیفیت رتبه‌بندی (NDCG) از اهمیت کاربردی به مراتب بالاتری نسبت به بازیابی صرف (Recall) برخوردار است.

▪ **معیار MAP@20 در مجموعه داده Trustfilm:** مقدار

MAP برای روش پیشنهادی در مقایسه با EAGCN با اختلاف بسیار ناچیز، کمتر است. شبکه اجتماعی در Trustfilm متراکم‌تر است و مدل‌های مبتنی بر گراف با لایه‌های عمیق توجه (مانند EAGCN) ممکن است در محاسبه میانگین دقت، اندکی پایدارتر عمل کنند. با این حال، مازول خصمانه و تقابلی در روش پیشنهادی باعث شده است تا مدل در یافتن آیتم‌های دقیقاً مرتبط برتری داشته باشد که این موضوع خود را در بهبود Precision و مهم‌تر از همه معیار NDCG نشان می‌دهد.

به‌طور خلاصه، نتایج جدول ۲ ثابت می‌کند که روش پیشنهادی یک تعادل بسیار بهینه میان دقت بازیابی و کیفیت رتبه‌بندی ایجاد کرده و در مقایسه با پیشرفته‌ترین روش‌های موجود، مدلی قوی‌تر و جامع‌تر برای سیستم‌های توصیه‌گر مبتنی بر شبکه‌های اجتماعی ارائه می‌دهد.

اجتماعی تولید می‌کند. این رویکرد باعث برتری روش پیشنهادی در دیتاست Ciao در تمامی معیارها شده است.

جدول (۲): مقایسه عملکرد کلی روش پیشنهادی با روش‌های پایه بر

روی چهار مجموعه داده

Dataset	Method	Precision @20	Recall @20	MAP @20	NDC G @20
Yelp	BPRMF	۰/۴۲۸۴	۲/۲۱۵۴	۰/۷۰۵۱	۱/۲۲۱۲
	LightGCN	۰/۵۱۸۲	۲/۶۹۸۱	۰/۹۰۱۵	۱/۵۳۲۳
	XSimGCL	۰/۵۵۳۵	۲/۹۰۹۲	۰/۹۷۱۵	۱/۶۲۹۱
	DENS	۰/۵۸۷۵	۲/۹۹۸۹	۱/۰۰۵۸	۱/۷۰۱۳
	Diffnet++	۰/۵۴۳۸	۲/۸۸۹۵	۰/۹۶۶۴	۱/۶۲۱۴
	DcRec	۰/۵۵۶۴	۲/۹۳۸۱	۰/۹۷۸۸	۱/۶۳۱۵
	DSL	۰/۵۶۹۲	۲/۹۹۸۲	۰/۹۹۱۲	۱/۶۳۹۳
	EAGCN	۰/۶۰۲۵	۳/۱۸۰۰	۱/۰۳۵۱	۱/۷۷۲۳
	روش پیشنهادی	۰/۶۱۸۳	۳/۱۷۵۵	۱/۰۵۰۸	۱/۷۷۷۹
Epinions	BPRMF	۰/۰۱۰۹	۰/۰۲۷۸	۰/۰۱۰۱	۰/۰۲۰۴
	LightGCN	۰/۰۱۴۶	۰/۰۳۹۹	۰/۰۱۵۸	۰/۰۳۰۲
	XSimGCL	۰/۰۱۵۵	۰/۰۴۱۷	۰/۰۱۶۴	۰/۰۳۱۴
	DENS	۰/۰۱۵۶	۰/۰۴۳۵	۰/۰۱۷۱	۰/۰۳۲۴
	Diffnet++	۰/۰۱۵۱	۰/۰۴۱۱	۰/۰۱۶۱	۰/۰۳۱۱
	DcRec	۰/۰۱۵۷	۰/۰۴۲۳	۰/۰۱۶۵	۰/۰۳۱۷
	DSL	۰/۰۱۶۰	۰/۰۴۲۷	۰/۰۱۶۸	۰/۰۳۲۲
	EAGCN	۰/۰۱۶۴	۰/۰۴۳۹	۰/۰۱۷۳	۰/۰۳۳۹
	روش پیشنهادی	۰/۰۱۷۸	۰/۰۴۶۸	۰/۰۱۹۳	۰/۰۳۵۹
Trustfilm	BPRMF	۰/۰۶۴۲	۰/۶۴۳۱	۰/۳۷۵۸	۰/۴۴۵۲
	LightGCN	۰/۰۷۰۱	۰/۷۰۲۵	۰/۴۱۵۵	۰/۴۹۴۷
	XSimGCL	۰/۰۷۴۹	۰/۷۴۲۱	۰/۴۴۵۱	۰/۵۲۴۴
	DENS	۰/۰۷۳۷	۰/۷۳۳۳	۰/۴۳۵۲	۰/۵۱۴۵
	Diffnet++	۰/۰۷۷۳	۰/۷۷۱۸	۰/۴۶۴۹	۰/۵۴۴۲
	DcRec	۰/۰۸۰۱	۰/۷۹۱۵	۰/۴۸۴۸	۰/۵۶۴۱
	DSL	۰/۰۸۱۵	۰/۸۰۱۶	۰/۴۹۹۶	۰/۵۷۸۸
	EAGCN	۰/۰۸۲۵	۰/۸۱۱۵	۰/۵۰۶۵	۰/۵۸۸۷
	روش پیشنهادی	۰/۰۸۴۱	۰/۸۱۸۸	۰/۵۰۵۱	۰/۵۹۵۱
Ciao	BPRMF	۰/۰۲۲۳	۰/۰۶۵۴	۰/۰۳۵۱	۰/۰۴۵۹
	LightGCN	۰/۰۲۶۸	۰/۰۷۵۳	۰/۰۴۱۵	۰/۰۵۲۷
	XSimGCL	۰/۰۲۹۵	۰/۰۸۲۸	۰/۰۴۵۷	۰/۰۵۶۸
	DENS	۰/۰۲۸۱	۰/۰۸۰۹	۰/۰۴۴۱	۰/۰۵۵۳
	Diffnet++	۰/۰۳۱۷	۰/۰۸۸۲	۰/۰۴۸۹	۰/۰۵۹۶
	DcRec	۰/۰۳۳۹	۰/۰۹۲۶	۰/۰۵۰۳	۰/۰۶۲۱
	DSL	۰/۰۳۴۳	۰/۰۹۵۶	۰/۰۵۱۴	۰/۰۶۴۹
	EAGCN	۰/۰۳۵۱	۰/۰۹۷۳	۰/۰۵۲۱	۰/۰۶۵۶
	روش پیشنهادی	۰/۰۳۵۶	۰/۰۹۹۴	۰/۰۵۲۴	۰/۰۶۶۱

۴-۴ مطالعه حذفی و آزمون معناداری آماری^۱

به منظور بررسی میزان مشارکت و اهمیت هر یک از ماژول‌های طراحی شده در معماری مدل، یک مطالعه حذفی بر روی مجموعه داده Ciao انجام شده است. در این آزمایش، عملکرد مدل کامل روش پیشنهادی با سه نسخه تغییر یافته از آن مقایسه شده است:

▪ **نسخه w/o CL:** مدل بدون ماژول یادگیری تقابلی.

▪ **نسخه w/o ADV:** مدل بدون آموزش نویزهای خصمانه.

▪ **نسخه w/o SOCIAL:** مدل بدون استفاده از اطلاعات و گراف روابط اجتماعی.

علاوه بر این، برای پاسخ به این سؤال که آیا بهبودهای به دست آمده توسط مدل کامل از نظر آماری معنادار هستند یا خیر، از آزمون معناداری آماری استفاده شده و مقادیر p-value محاسبه گردیده است. نتایج این ارزیابی در جدول ۳ گزارش شده است.

جدول (۳): نتایج مطالعه حذفی و آزمون معناداری آماری بر روی مجموعه داده Ciao

وضعیت معناداری	P-Value	NDCG@20	MAP@20	Recall@20	Precision@20	مدل
-	-	۰/۰۶۶۵	۰/۰۵۲۷	۰/۰۹۹۸	۰/۰۳۵۹	روش پیشنهادی (مدل کامل)
*	۰/۰۴۱۵	۰/۰۶۵۱	۰/۰۵۱۱	۰/۰۹۹۱	۰/۰۳۴۵	نسخه w/o CL
*	۰/۰۱۴۲	۰/۰۶۳۷	۰/۰۴۸۹	۰/۰۹۷۲	۰/۰۳۲۸	نسخه w/o ADV
*	۰/۰۳۶۸	۰/۰۶۴۵	۰/۰۵۰۴	۰/۰۹۸۵	۰/۰۳۳۸	نسخه w/o SOCIAL

۴-۴-۱ تحلیل نتایج مطالعه حذفی

بر اساس نتایج جدول ۳، حذف هر یک از اجزای اصلی منجر به افت عملکرد مدل می‌شود که این امر ضرورت وجود تمامی ماژول‌ها را در معماری پیشنهادی اثبات می‌کند:

▪ **بیشترین افت عملکرد (اهمیت ماژول ADV):** زمانی که ماژول آموزش خصمانه (w/o ADV) حذف می‌شود، مدل شدیدترین افت را در تمامی معیارها تجربه می‌کند (به عنوان مثال، افت NDCG از ۰/۰۶۶۵ به ۰/۰۶۳۷). این موضوع نشان می‌دهد که تزریق نویزهای خصمانه نقش حیاتی در افزایش مقاومت مدل در برابر داده‌های نویزدار و جلوگیری از بیش برآزش دارد.

▪ **اهمیت اطلاعات اجتماعی:** حذف گراف اجتماعی (w/o SOCIAL) باعث کاهش قابل توجه دقت می‌شود، زیرا مدل توانایی خود را در بهره‌گیری از ترجیحات مشترک میان کاربران مرتبط از دست می‌دهد.

▪ **نقش یادگیری تقابلی:** نسخه w/o CL نیز نسبت به مدل کامل عملکرد ضعیف‌تری دارد که نشان‌دهنده اهمیت سیگنال‌های نظارت فردی^۲ در غلبه بر مشکل پراکندگی داده‌هاست.

▪ **تحلیل معناداری آماری:** همان‌طور که در ستون آخر جدول ۳ مشاهده می‌شود، مقادیر p-value برای تمامی نسخه‌های حذفی در مقایسه با مدل کامل، کمتر از سطح آستانه استاندارد ($p\text{-value} < 0.05$) است. این مقادیر (به‌ویژه مقدار ۰/۰۱۴۲) برای نسخه بدون نویز خصمانه (از نظر آماری ثابت می‌کند که برتری روش پیشنهادی تصادفی نبوده و بهبودهای حاصل شده به دلیل طراحی دقیق و ترکیب مؤثر ماژول‌های تقابلی و خصمانه، کاملاً معنادار است).


۴-۵ تحلیل حساسیت پارامترها

برای درک بهتر از رفتار مدل و بررسی پایداری آن، تأثیر تغییرات پارامترهای کلیدی بر روی معیار Recall@20 مورد تحلیل قرار گرفت (نتایج در شکل ۲ قابل مشاهده است).

^۲ Self-supervised

^۱ Ablation Study and Statistical Significance

Hyperparameter Tuning Results



شکل (۲): تأثیر تغییرات پارامترهای کلیدی بر عملکرد مدل (معیار Recall@20)

نمای تولیدشده تفاوت معناداری با نمای اصلی نداشته و چالش کافی برای یادگیری ایجاد نمی‌کند؛ درحالی‌که مقادیر بسیار بزرگ منجر به مخدوش شدن مفاهیم ذاتی و تخریب بازنمایی ویژگی‌های کاربر و آیتم می‌شود.

در بررسی اثر شدت نویز تخصصی بر فضای بازنمایی، نتایج نشان می‌دهد که اعمال نویز کنترل‌شده به‌عنوان یک عامل تنظیم‌کننده عمل کرده و مقاومت مدل را افزایش می‌دهد. با این حال، چنانچه شدت نویز از حد بهینه فراتر رود، بردارهای بازنمایی کاربران و آیتم‌ها دچار انحراف شدید شده و از ناحیه و همسایگی معنایی خود خارج می‌شوند. از منظر هندسی، نویز بیش‌ازحد، ساختار ذاتی گراف را مخدوش کرده و باعث از بین رفتن تمایز بین خوشه‌های معنایی می‌گردد؛ پدیده‌ای که درنهایت به فروپاشی بازنمایی و افت شدید دقت سیستم توصیه‌گر منجر می‌شود.

نتایج تجربی این بخش، اثربخشی راهکارهای پیشنهادی را در غلبه بر چالش‌های پراکندگی و نویز داده‌ها تأیید می‌کند. در بخش نهایی،

تأثیر پارامتر دما (τ): این پارامتر حساسیت مدل را در تفکیک نمونه‌های منفی کنترل می‌کند (با دامنه بررسی ۰/۰۵ تا ۰/۲). مشاهدات نشان می‌دهد که در $\tau = 0.15$ ، مدل بهترین تعادل را در دفع نمونه‌های منفی سخت حفظ می‌کند.

تأثیر ضرایب تقابلی (λ_{intra} و λ_{inter}): این ضرایب وظیفه برقراری تعادل میان تابع هدف اصلی (BPR) و توابع زیان تقابلی را بر عهده دارند. آزمایش‌ها حاکی از آن است که تنظیم $\lambda_{intra} = 1e^{-5}$ و $\lambda_{inter} = 1e^{-8}$ بهینه‌ترین خروجی را ارائه می‌دهد. مقادیر بیش‌ازحد بزرگ این ضرایب موجب انحراف مدل از وظیفه اصلی شده و مقادیر بسیار کوچک نیز اثر تنظیم‌کنندگی یادگیری تقابلی را خنثی می‌کنند. همچنین، اختلاف مقیاس میان این دو ضریب نشان‌دهنده اهمیت بیشتر حفظ ساختار درون دامنه‌ای، در قیاس با هم‌ترازسازی شدید میان‌دامنه‌ای است.

تأثیر شعاع نویز تخصصی (ϵ): دامنه نویز واردشده به بازنمایی‌ها توسط این پارامتر تعیین می‌گردد. نتایج نشان می‌دهد که مدل در $\epsilon = 0.1$ به اوج کارایی خود می‌رسد. در مقادیر بسیار کوچک،

دوستان به دامنه تعاملی منتقل شود. نتایج آزمایش‌های جامع بر روی مجموعه داده دنیای واقعی نشان داد که مدل پیشنهادی با اختلاف معناداری (تا ۲۴ درصد بهبود در معیار Recall@20) بر قوی‌ترین مدل‌های پایه نظیر EGCL غلبه می‌کند که این امر، کارایی استراتژی مبتنی بر نویز تخصصی را به اثبات می‌رساند.

با وجود دستاوردهای پژوهش حاضر، این چارچوب می‌تواند در چندین جهت به عنوان مسیرهای پژوهشی آینده گسترش یابد. نخستین گام، یکپارچه‌سازی گراف‌های پویا است؛ به گونه‌ای که در نظر گرفتن بعد زمان و تکامل پویای روابط اجتماعی و تعاملات کاربران می‌تواند به مدل‌سازی دقیق‌تر تغییرات ترجیحات در طول زمان کمک کند. جهت‌گیری دوم به توسعه مکانیزم‌های تولید نویز تطبیقی اختصاص دارد، جایی که به جای استفاده از یک شعاع ثابت (ϵ) برای نویز تخصصی، می‌توان از روش‌های یادگیری خودکار جهت تنظیم پویای شدت نویز برای هر گره (کاربر یا آیتم) بسته به میزان محبوبیت یا پراکندگی داده‌های آن بهره برد. در نهایت، ادغام اطلاعات چندرسانه‌ای از طریق به کارگیری اطلاعات متنی (مانند نظرات کاربران) و تصویری در فرایند یادگیری تقابلی تخصصی، چشم‌انداز روشنی برای ارتقای بیش‌ازپیش کیفیت ترازسازی میان‌دامنه‌ای در سیستم‌های توصیه‌گر مدرن ارائه می‌دهد.

References

- [1] M. A. Shu-Ting, G. I. Felicia, L. Vivian, and C. H. Wang, "A survey of social recommender systems," *Social Netw. Anal. Mining*, vol. 6, no. 1, pp. 1–21, 2016.
- [2] J. S. Breese, D. Heckerman, and C. Kadie, "Empirical analysis of predictive algorithms for collaborative filtering," in *Proc. 14th Conf. Uncertainty in Artif. Intell. (UAI)*, 1998, pp. 43–52.
- [3] X. Cai, C. Huang, L. Xia, and X. Ren, "LightGCL: Simple yet effective graph contrastive learning for recommendation," in *Proc. 11th Int. Conf. Learn. Represent. (ICLR)*, 2023.
- [4] S. Raza, M. Rahman, S. Kamawal, A. Toroghi, A. Raval, F. Navah, and A. Kazemeini, "A comprehensive review of recommender systems: Transitioning from theory to practice," *Comput. Sci. Rev.*, vol. 59, p. 100849, 2026.

به جمع‌بندی دستاوردهای پژوهش و ارائه چشم‌اندازی از کارهای آینده پرداخته خواهد شد.

۵- نتیجه‌گیری و کارهای آینده

در این مقاله، به بررسی و حل چالش‌های بنیادین موجود در سیستم‌های توصیه‌گر اجتماعی، از جمله پراکندگی تعاملات، نویز ذاتی گراف‌های اجتماعی و واگرایی ترجیحات میان کاربران پرداختیم. مدل‌های پیشین مبتنی بر یادگیری تقابلی، عمدتاً از افزونگی‌های تصادفی و مخرب ساختاری برای تولید نماهای تقابلی استفاده می‌کردند که به افت کیفیت بازنمایی‌ها منجر می‌شد. برای غلبه بر این محدودیت، یک چارچوب یادگیری تقابلی یکپارچه و نوین پیشنهاد گردید که رویکرد متداول تقویت داده‌های ساختاری را با تزریق نویز تخصصی در فضای پیوسته بردارهای بازنمایی گره‌ها جایگزین می‌کند.

این نوآوری به مدل اجازه داد تا بدون تخریب ساختار گراف، بازنمایی‌های به‌شدت مقاومی را در برابر پیوندهای نویزدار و روابط اجتماعی کاذب بیاموزد. علاوه بر این، با طراحی یک مکانیزم تقابلی دوگانه، توانستیم سیگنال‌های رفتاری و اجتماعی را به گونه‌ای هوشمندانه هم‌تراز کنیم که تنها اطلاعات مرتبط و همسو از شبکه

- [5] F. Wu, A. H. Souri, L. J. Li, Y. Liu, and T. Mei, "A comprehensive survey on graph neural networks," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 32, no. 1, pp. 4–24, 2021.
- [6] M. M. Keikha, S. Barahoie, and A. Nadi, "Grace: A scalable framework for graph embedding with autoencoder-based feature compression and random walks," *Int. J. Data Sci. Anal.*, vol. 22, Art. no. 128, 2026, doi: 10.1007/s41060-026-01091-z.
- [7] C. Song, T. Wu, Y. Liu, J. Ge, and P. S. Yu, "Social recommendation with bi-polarized preference and inter-domain knowledge transfer," in *Proc. 28th ACM Int. Conf. Inf. Knowl. Manage. (CIKM)*, 2019, pp. 117–126.
- [8] M. M. Keikha and H. Rezaei, "CF-X: A multi-view chaotic-fuzzy network representation learning framework for heterophilic graphs," *Appl. Soft Comput.*, vol. 197, Art. no. 115127, 2026.
- [9] Y. Koren, R. Bell, and C. Volinsky, "Matrix factorization techniques for recommender

- systems,” *Computer*, vol. 42, no. 8, pp. 30–37, 2009.
- [10] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T. S. Chua, “Neural collaborative filtering,” in *Proc. 26th Int. Conf. World Wide Web (WWW)*, 2017, pp. 173–182.
- [11] M. M. Keikha and S. Barahouei, “A novel deep learning-based approach for graph dimensionality reduction by using fuzzy logic and random walks,” *Applied and basic Machine intelligence research*, vol. 2, no. 1, pp. 131–141, 2025 [In Persian].
- [12] X. He, K. Deng, X. Wang, Y. Li, Y. Zhang, and M. Wang, “LightGCN: Simplifying and powering graph convolution network for recommendation,” in *Proc. 43rd Int. ACM SIGIR Conf. Res. Develop. Inf. Retrieval*, 2020, pp. 639–648.
- [13] J. Zhang, X. Lin, X. Wang, and Q. Li, “Adaptive diffusion in graph neural networks for recommendation,” *Knowl.-Based Syst.*, vol. 230, Art. no. 107380, 2021.
- [14] H. Ma, H. Yang, M. R. Lyu, and I. King, “SoRec: Social recommendation using probabilistic matrix factorization,” in *Proc. 17th ACM Conf. Inf. Knowl. Manage. (CIKM)*, 2008, pp. 931–940.
- [15] S. Jamali and M. Ester, “A matrix factorization technique with trust propagation for recommendation in social networks,” in *Proc. 4th ACM Conf. Recommender Syst. (RecSys)*, 2010, pp. 135–142.
- [16] W. Fan et al., “Graph neural networks for social recommendation,” in *Proc. World Wide Web Conf. (WWW)*, 2019, pp. 417–426.
- [17] L. Wu, J. Li, P. Cui, C. Li, B. Wang, and X. Wu, “Diffnet: A differential influence network for social recommendation,” *IEEE Trans. Knowl. Data Eng.*, vol. 33, no. 4, pp. 1438–1449, 2021.
- [18] Y. Liu, Q. Ren, S. Fu, and Y. Liu, “KAN-infused social recommendation: A contrastive graph learning approach with bidirectional feature fusion,” *Inf. Fusion*, vol. 125, Art. no. 103448, 2026.
- [19] J. Wu, X. Wang, F. Feng, X. He, L. Chen, J. Lian, and X. Xie, “Self-supervised graph learning for recommendation,” in *Proc. 44th Int. ACM SIGIR Conf. Res. Develop. Inf. Retrieval*, 2021, pp. 726–735.
- [20] B. Wu, B. Zhang, Y. Tian, C. Li, J. Liang, and Y. Ye, “EGCL: An effective and efficient graph contrastive learning framework for social recommendation,” *ACM Trans. Inf. Syst.*, vol. 44, no. 3, Art. no. 58, Feb. 2026.
- [21] T. Yang, T. Chen, X. Wang, and Z. Guan, “RCGRL: Reinforcement-optimized contrastive graph representation learning for social recommendation,” *arXiv preprint*, 2024.
- [22] Y. Xie, J. Jia, C. Wen, D. Li, and M. Li, “Multi-topology contrastive graph representation learning,” *Sci. China Inf. Sci.*, vol. 69, no. 2, pp. 122102:1–122102:11, 2026.
- [23] Z. Zhang, H. Zhang, B. Wang, and J. Zhu, “Social graph diffusion and disentangled representations learning for multimodal recommendation,” *J. King Saud Univ. Comput. Inf. Sci.*, 2026.
- [24] S. Rendle, C. Freudenthaler, Z. Gantner, and L. Schmidt-Thieme, “BPR: Bayesian personalized ranking from implicit feedback,” in *Proc. 25th Conf. Uncertainty in Artif. Intell. (UAI)*, 2009, pp. 452–461.
- [25] L. Wu, J. Li, P. Sun, R. Hong, Y. Ge, and M. Wang, “Diffnet++: A neural influence and interest diffusion network for social recommendation,” *IEEE Trans. Knowl. Data Eng.*, vol. 34, no. 10, pp. 4753–4766, 2020.
- [26] J. Yu, H. Yin, X. Xia, T. Chen, L. Cui, and Q. V. Nguyen, “Are graph augmentations necessary? Simple graph contrastive learning for recommendation,” in *Proc. 45th Int. ACM SIGIR Conf. Res. Develop. Inf. Retrieval*, 2022, pp. 1294–1303.
- [27] L. Wu et al., “DcRec: Dual contrastive learning for social recommendation,” *IEEE Trans. Knowl. Data Eng.*, 2022.
- [28] T. Wang, L. Xia, and C. Huang, “Denoised self-augmented learning for social recommendation,” in *Proc. 32nd Int. Joint Conf. Artif. Intell., Palo Alto, CA, USA: AAAI Press*, 2022, pp. 2324–2331.
- [29] J. Ding, G. Yu, X. He, Y. Xiang, and Y. Shen, “DENS: Disentangled negative sampling for contrastive learning in recommendation,” *IEEE Trans. Knowl. Data Eng.*, 2023.
- [30] B. Wu, L. Zhong, L. Yao, and Y. Ye, “EAGCN: An efficient adaptive graph convolutional network for item recommendation in social internet of things,” *IEEE Internet Things J.*, vol. 9, no. 17, pp. 16386–16401, 2022.

Robust Social Recommendation via Adversarial Graph Contrastive Learning and Dual-Domain Alignment

Mohammad Mehdi Keikha^{1*}, Abolfazl Nadi²

¹ Assistant Professor, Department of Computer Science, University of Sistan and Baluchestan, Zahedan, Iran

² Assistant Professor, Department of Computer Science, School of Mathematics, Statistics and Computer Science, College of Science, University of Tehran, Tehran, Iran

Article Information

Original Research Paper

Received:

2026 April 29

Accepted:

2026 June 18

Keywords:

Social Recommender Systems, Graph Contrastive Learning, Adversarial Noise, Graph Neural Networks, Collaborative Filtering

Corresponding Author*:

keikha@cs.usb.ac.ir

Abstract

Leveraging social networks as an auxiliary information source is considered an effective solution to overcome the data sparsity challenge in recommender systems. However, real-world social relations are often noisy, and the assumption of "perfect preference alignment among friends" does not always hold true. Recently, Graph Contrastive Learning (GCL) has garnered attention to tackle this noise; nevertheless, conventional approaches relying on stochastic methods such as edge dropping distort the graph's semantic structure and yield unstable representations. To address these limitations, this paper proposes a novel framework based on graph contrastive learning utilizing adversarial noise. In this architecture, instead of perturbing the graph structure, targeted perturbations are injected into the continuous representation space using the Fast Gradient Method (FGM) to generate "hard" and robust contrastive views. Furthermore, a dual contrastive learning approach is developed, comprising intra-domain alignment (to extract the pure features of each graph) and cross-domain alignment (to purposively transfer useful social signals to the interaction domain). Empirical evaluations on four real-world datasets (Yelp, Epinions, Trustfilm, Ciao) demonstrate that the proposed model outperforms state-of-the-art baseline methods, achieving an average performance improvement of 8.5% in the Recall metric and 7.2% in the NDCG metric. These results verify the effectiveness of employing adversarial noise in extracting robust representations and improving recommendation accuracy.



: 10.22034/ABMIR.2026.24499.1238

E-ISSN: [2821-2037](#)

/The Author 2026. Published by Yazd University This is an open access article under the CC BY 4.0 License <https://creativecommons.org/licenses/by/4.0/>.

