

سازوکار نرخ یادگیری تطبیقی مبتنی بر احساسات برای سیستم‌های توصیه‌گر عصبی در محیط‌های یادگیری تقویت‌شده با فناوری

محمدمهران لسان‌صدق^۱، علی محمد لطیف^{۲*}، سیما عمادی^۳

^۱ دانشجوی دکتری گروه مهندسی کامپیوتر، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران

^۲ استاد گروه مهندسی کامپیوتر، دانشگاه یزد، یزد، ایران

^۳ دانشیار گروه مهندسی کامپیوتر، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران

مقاله پژوهشی

چکیده

در اکوسیستم‌های یادگیری تقویت‌شده با فناوری، تغییرات پویای علایق یادگیرندگان که به‌عنوان رانش مفهوم شناخته می‌شود و ناتوانی مدل‌های توصیه‌گر سنتی در انطباق سریع با این تغییرات، چالشی بنیادین محسوب می‌شود. اگرچه سیستم‌های توصیه‌گر عصبی در مدل‌سازی تعاملات غیرخطی موفق بوده‌اند؛ اما استفاده از نرخ‌های یادگیری ایستا یا سازوکارهای کاهش‌دهنده استاندارد در این مدل‌ها، منجر به کندی در واکنش به تغییرات ناگهانی سلیقه کاربر می‌گردد. این پژوهش با هدف غلبه بر این محدودیت، یک سازوکار نرخ یادگیری تطبیقی نوین ارائه می‌دهد که در آن نرخ به‌روزرسانی وزن‌های مدل، تابعی مستقیم از شدت و قطبیت احساسات کاربر است که توسط مدل زبانی BERT استخراج می‌شود. فرضیه اصلی این است که احساسات منفی سیگنالی قوی برای نیاز به "اصلاح سریع" مدل هستند. نتایج ارزیابی تجربی بر روی مجموعه‌داده‌گان مرتبط نشان می‌دهد که این رویکرد، نرخ انطباق مدل با تغییرات ناگهانی سلیقه را تا ۱۳ درصد نسبت به مدل پایه پالایش همکارانه عصبی افزایش داده و ضمن ارتقای دقت رتبه‌بندی، سرعت همگرایی سیستم را در محیط‌های پویا به‌طور معناداری بهبود می‌بخشد.

تاریخ دریافت:

۱۴۰۵/۰۱/۱۶

تاریخ پذیرش:

۱۴۰۵/۰۴/۲۲

کلیدواژه‌ها:

سیستم توصیه‌گر آموزشی، نرخ یادگیری تطبیقی، پالایش همکارانه عصبی، تحلیل احساسات، یادگیری عمیق، رانش مفهوم

نویسنده مسئول:

alatif@yazd.ac.ir

doi : 10.22034/ABMIR.2026.24443.1232

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2026.24443.1232)

/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

تحلیل احساسات^۶ می‌تواند لایه‌ای پنهان از وضعیت روانی کاربر را آشکار سازد. برای مثال، احساساتی نظیر سردرگمی یا ناامیدی، سیگنال‌هایی قوی مبنی بر عدم تناسب محتوای ارائه‌شده با سطح دانش یا نیاز کاربر هستند [۱۳]. اگرچه مطالعات اخیر تلاش کرده‌اند با ادغام تحلیل احساسات در سیستم‌های توصیه‌گر، دقت پیش‌بینی را بهبود بخشند [۱۴، ۱۵]؛ اما اکثر این رویکردها احساسات را تنها به‌عنوان یک ویژگی ورودی^۷ یا عامل وزن‌دهی ایستا در نظر می‌گیرند [۱۶].

شکاف پژوهشی بنیادین در اینجا است که تاکنون از سیگنال‌های عاطفی به‌عنوان یک پارامتر کنترلی فعال در سطح بهینه‌سازی مدل استفاده نشده است. الگوریتم‌های بهینه‌سازی استاندارد مانند Adam یا RMSProp، نرخ یادگیری^۸ را تنها بر اساس تاریخچه ریاضی گرادین‌ها تنظیم می‌کنند و نسبت به محتوای معنایی بازخورد کاربر کور هستند. این پژوهش استدلال می‌کند که یک سیستم هوشمند باید در مواجهه با نارضایتی کاربر (بازخورد منفی)، رفتار خود را تغییر دهد؛ به این معنا که نرخ یادگیری خود را به‌صورت تطبیقی افزایش دهد تا سریع‌تر از وضعیت فعلی (که منجر به نارضایتی شده) فاصله گرفته و الگوهای جدید را فراگیرد. پژوهش حاضر با هدف پاسخ به این چالش‌ها، یک چارچوب ترکیبی نوین ارائه می‌دهد که مدل‌سازی پالایش همکارانه عصبی را با درک معنایی عمیق^۹ BERT ادغام می‌کند. نوآوری اصلی و متمایز این تحقیق، طراحی یک سازوکار نرخ یادگیری تطبیقی احساس‌محور است. در این سازوکار، نمره احساسی استخراج‌شده از نظرات متنی یادگیرنده، نرخ یادگیری مدل را در هر گام آموزشی تعدیل می‌کند. این رویکرد مدل را قادر می‌سازد تا پویایی سلیقه یادگیرنده را با حساسیت بالاتری دنبال کند، در مواجهه با تغییرات ناگهانی سلیقه واکنش سریع‌تری نشان دهد و سیستم توصیه‌گر را از یک مدل واکنشی به یک مدل تطبیقی و انسان‌محور ارتقا دهد.

ادغام فناوری‌های دیجیتال در فرایندهای آموزشی منجر به شکل‌گیری پارادایم یادگیری تقویت‌شده با فناوری^۱ شده است که پتانسیل بالایی برای ارتقای کیفیت و عدالت آموزشی دارد [۱]. رشد انفجاری حجم محتوای دیجیتال، یادگیرندگان را با چالش اضافه‌بار اطلاعاتی مواجه کرده است که یافتن منابع متناسب با نیازهای فردی را دشوار می‌سازد [۲]. در این راستا، سیستم‌های توصیه‌گر آموزشی^۲ به‌عنوان ابزاری حیاتی برای فیلتر کردن هوشمند اطلاعات و ارائه مسیرهای یادگیری شخصی‌سازی‌شده توسعه‌یافته‌اند [۳، ۴]. برخلاف سیستم‌های توصیه‌گر در حوزه‌های تجاری، سیستم‌های توصیه‌گر آموزشی باید پیچیدگی‌های شناختی و پویایی‌های خاص فرایند یادگیری انسان را در نظر بگیرند [۵]. یکی از موفق‌ترین معماری‌ها در این حوزه، پالایش همکارانه عصبی^۳ است که با جایگزینی ضرب داخلی ماتریس‌ها با شبکه‌های عصبی عمیق، قادر به مدل‌سازی تعاملات غیرخطی و پیچیده بین کاربر و محتوا است [۶]. با وجود این موفقیت، به‌کارگیری مدل‌های عصبی استاندارد در محیط‌های آموزشی با چالش جدی پویایی علایق روبرو است. علایق آموزشی یک ویژگی ایستا نیست، بلکه تابعی پویا از عواملی همچون پیشرفت سطح دانش، تغییر اهداف یادگیری و شرایط محیطی است [۷]. تغییرات ناگهانی در نیازهای یادگیرنده (مثلاً تغییر تمرکز از یک مبحث مقدماتی به پیشرفته یا تغییر کامل موضوع مورد مطالعه) پدیده‌ای است که در یادگیری ماشین به‌عنوان رانش مفهوم^۴ شناخته می‌شود [۸]. مدل‌های مرسوم که بر پایه فرضیات ایستا بنا شده‌اند، در مواجهه با این تغییرات دچار اینرسی شده و قادر به انطباق سریع نیستند، که این امر منجر به کاهش اعتماد کاربر و افت تعامل می‌شود [۹، ۱۰].

از سوی دیگر، پژوهش‌های علوم شناختی و تربیتی به‌طور گسترده تأیید کرده‌اند که عواطف و احساسات^۵ نقشی تعیین‌کننده در فرایندهای توجه، انگیزش و پذیرش اطلاعات ایفا می‌کنند [۱۱، ۱۲].

^۶ Sentiment Analysis

^۷ Input Feature

^۸ Learning Rate

^۹ Bidirectional Encoder Representations from Transformers -BERT

^۱ Technology-Enhanced Learning – TEL

^۲ Educational Recommender Systems – ERS

^۳ Neural Collaborative Filtering - NCF

^۴ Concept Drift

^۵ Emotions

۲- پیشنهاد پژوهش

مراجع پژوهشی مرتبط با این مطالعه را می‌توان در دو جریان اصلی طبقه‌بندی نمود: نخست، مطالعاتی که بر مدل‌سازی تغییرات زمانی و پویایی سلیقه کاربران در سیستم‌های توصیه‌گر تمرکز دارند و دوم، رویکردهایی که تحلیل احساسات را با فرایندهای توصیه‌گری ادغام کرده‌اند.

۲-۱ مدل‌سازی پویایی سلیقه و تعاملات در آموزش

در محیط‌های یادگیری تقویت‌شده با فناوری، سلیقه و نیازهای یادگیرندگان ماهیتی سیال دارد. رویکردهای سنتی پالایش همکارانه که بر ماتریس‌های تعامل ایستا تکیه دارند، در مواجهه با رانش مفهوم دچار افت عملکرد می‌شوند. برای حل این چالش، پژوهش‌گران به سمت مدل‌های مبتنی بر گراف و دنباله روی آورده‌اند.

لی و همکاران در سال ۲۰۲۲ چارچوب RANGCF را توسعه دادند که با افزودن گره‌های منطقه‌ای به گراف کاربر-آیتم و استفاده از شبکه‌های عصبی گراف، تعاملات سلسله‌مراتبی را استخراج می‌کند. اگرچه این روش دقت توصیه‌ها را بهبود بخشید؛ اما تغییرات زمانی را به‌صورت محدود و تنها در بستر مکانی در نظر گرفت [۶]. در رویکردی پویاتر، فن و همکاران (۲۰۲۵) مدل DRSKG را پیشنهاد دادند که سلیقه کاربران را بر پایه گراف‌های دانش فضا-زمان^۱ مدل‌سازی می‌کند. نوآوری آن‌ها در انتقال علایق پویای کاربر در طول زمان بود که منجر به بهبود ۷ درصدی در دقت گردید [۹].

با هدف مدل‌سازی دقیق‌تر وابستگی‌های زمانی، کیم و همکاران در سال ۲۰۲۴ برای نخستین بار از شبکه‌های گراف زمانی در سیستم‌های توصیه‌گر استفاده کردند تا تغییرات ویژگی‌های گره‌ها و یال‌ها را در لحظه ثبت کنند. نتایج آن‌ها نشان داد که مدل‌سازی دینامیک می‌تواند تا ۱۰ درصد معیار NDCG را نسبت به مدل‌های ایستا ارتقا دهد [۹]. در سال ۲۰۲۲، شیا و همکاران با معرفی سیستم TGT مبتنی بر ترنسفورمرهای گراف زمانی، تلاش کردند تعاملات چندگانه (مانند کلیک و خرید) را در توصیه‌گرهای ترتیبی

مدل کنند [۱۰]. لی و همکاران در سال ۲۰۲۴ با استفاده از یادگیری تضادی^۲ و سازوکار توجه پویا، تلاش کردند ویژگی‌های شخصی‌سازی‌شده را در ادغام‌ها تقویت کنند [۱۷]. نقد مشترک بر این دسته از مطالعات آن است که اگرچه در مدل‌سازی ریاضی زمان و توالی موفق بوده‌اند؛ اما عامل محرک تغییر سلیقه که اغلب ریشه در وضعیت عاطفی و شناختی یادگیرنده دارد را نادیده گرفته و با تغییرات تنها به‌عنوان یک پدیده آماری برخورد کرده‌اند.

۲-۲ سیستم‌های توصیه‌گر آگاه از احساسات

دسته دوم مطالعات، بر استخراج سیگنال‌های عاطفی از بازخوردهای متنی و ادغام آن در فرایند توصیه تمرکز دارند. این رویکردها فرض می‌کنند که احساسات کاربر، شاخصی قوی برای پیش‌بینی رضایت آینده است.

در سال ۲۰۲۱ ژانگ و همکاران، مدل SIFN را معرفی کردند که از یک لایه هم‌جوشی^۳ برای ترکیب ویژگی‌های استخراج‌شده توسط BERT با ویژگی‌های تعاملی کاربر-آیتم استفاده می‌کرد. این مدل نشان داد که افزودن اطلاعات احساسی می‌تواند خطای پیش‌بینی را کاهش دهد. دانگ و همکاران در سال ۲۰۲۲ از تکنیک‌های مبتنی بر پرامپت در مدل‌های زبانی برای استخراج احساسات و تزریق آن به پالایش همکارانه استفاده کردند که منجر به بهبود ۳۰ درصدی در معیارهای رتبه‌بندی شد [۱۵].

در حوزه خاص آموزش الکترونیکی، کارابیل و همکاران در سال ۲۰۲۳ یک سیستم مبتنی بر BiGRU توسعه دادند که احساسات استخراج‌شده از پاسخ‌های یادگیرندگان را به مدل توصیه اضافه می‌کرد و موفق شد مشکل شروع سرد^۴ را تا حدی تعدیل کند [۱۶]. در سال ۲۰۲۳ باتیا و همکاران، چارچوبی برای توصیه‌گر دوره‌های MOOCE ارائه دادند که با تحلیل احساسات نظرات، تنوع توصیه‌ها را افزایش می‌داد [۱۹].

رویکردهای پیشرفته‌تر سعی در ترکیب منابع داده‌ای متنوع داشته‌اند. سالازار و همکاران در سال ۲۰۲۴ یک معماری


³ Fusion Layer

⁴ Cold Start

¹ Spatiotemporal Knowledge Graphs

² Contrastive Learning


سیگنال‌های عاطفی از متن، ماژول پالایش همکارانه عصبی برای مدل‌سازی تعاملات غیرخطی کاربر-آیتم و سازوکار نرخ یادگیری تطبیقی که به‌عنوان کنترل‌کننده فرایند بهینه‌سازی عمل می‌کند.



شکل (۱): معماری مدل پیشنهادی

۳-۱ مازول استخراج احساسات

به‌منظور درک عمیق بازخوردهای متنی کاربران در محیط‌های آموزشی، از مدل زبانی BERT (نسخه BERT-base-uncased) استفاده شده است. برخلاف روش‌های سنتی که بر واژگان کلیدی تکیه‌دارند، BERT با سازوکار توجه خود، بافت معنایی و وابستگی‌های دوطرفه کلمات را درک می‌کند. معماری این ماژول در شکل (۲) نشان داده‌شده است:



شکل (۲): ماژول استخراج احساسات

فرایند استخراج سیگنال احساسی شامل مراحل زیر است:

چندوجهی^۱ پیشنهاد دادند که داده‌های متنی، صوتی و فیزیولوژیک را ترکیب می‌کرد [۱۸]. اباکریم و همکاران در سال ۲۰۲۵ نیز با ترکیب تحلیل احساسات و مدل انتقال تصمیم^۲، تعاملات کاربر را به صورت توالی حالت - عمل - پاداش مدل‌سازی کردند که منجر به بهبود ۱۱ درصدی در نرخ اصابت^۳ شد [۴]. در سال ۲۰۲۴ کوی و همکاران نیز با وزن‌دهی به یال‌های گراف دانش بر اساس بار احساسی نظرات، توانستند ویژگی‌های دقیق‌تری از آیتم‌ها استخراج کنند [۲۰].

۲-۳ تحلیل شکاف پژوهشی

پیشینه پژوهشی فوق نشان‌دهنده یک شکاف روش‌شناختی آشکار است. مطالعات گروه اول [۹]، [۶] بر پویایی سلیقه تمرکز دارند اما از بُعد عاطفی غافل هستند. مطالعات گروه دوم [۱۵]، [۴] احساسات را وارد مدل کرده‌اند؛ اما نحوه ادغام آن‌ها در بیشتر وقت‌ها به صورت نافع‌ال انجام می‌شود و احساسات تنها به عنوان یک ویژگی ورودی به شبکه عصبی داده می‌شود.

از سیگنال‌های عاطفی به‌عنوان یک پارامتر کنترلی فعال در سطح الگوریتم بهینه‌سازی تاکنون استفاده نشده است. در مدل‌های فعلی، اگر کاربر احساس نارضایتی شدید (احساس منفی) داشته باشد، مدل کماکان با همان نرخ یادگیری استاندارد، وزن‌ها را به‌روزرسانی می‌کند، درحالی‌که منطق تطبیقی حکم می‌کند در چنین شرایطی سرعت یادگیری برای فاصله گرفتن از فضای نامطلوب افزایش یابد. پژوهش حاضر با پیشنهاد نرخ یادگیری تطبیقی احساس‌محور، قصد دارد این حلقه مفقوده را تکمیل نماید.

۳- روش پیشنهادی

در این پژوهش، یک معماری ترکیبی و چندلایه برای سیستم توصیه‌گر آموزشی پیشنهاد شده است که قادر است به‌صورت هم‌زمان تعاملات شناختی (رفتار کاربر) و وضعیت عاطفی (احساسات کاربر) را پردازش نماید. همان‌طور که در شکل (۱) مشاهده می‌شود، این معماری از سه مؤلفه کلیدی تشکیل شده است: ماژول تحلیل احساسات مبتنی بر BERT برای استخراج


³ Hit Rate

⁴ Self-Attention

¹ Multimodal

² Decision Transformer

- لایه خروجی با استفاده از تابع فعال‌سازی سیگموئید^۵، احتمال تعامل ($\hat{y}_{ui}$) را پیش‌بینی می‌کند.



شکل (۳): ماژول پالایش همکارانه عصبی

۳-۳ سازوکار نرخ یادگیری تطبیقی احساس‌محور

در روش‌های متداول مانند Adam، نرخ یادگیری (η) مستقل از معنای بازخورد کاربر تنظیم می‌شود. در رویکرد پیشنهادی، فرض می‌شود که احساسات منفی سیگنالی برای نیاز به تغییر سریع در پارامترهای مدل است.

یک تابع کنترلی پویا طراحی شد که نرخ یادگیری لحظه‌ای (η_t) را در هر گام آموزشی (t) بر اساس نمره احساسی استخراج‌شده (S_t) تعدیل می‌کند. رابطه ریاضی این سازوکار به شرح رابطه (۱) است:

$$\eta_t = (1 - S_t \cdot \gamma) \cdot \eta_0 \quad (1)$$

که در آن:

η_0 نرخ یادگیری پایه (اولیه) است که در این پژوهش برابر با ۰/۰۰۱ تنظیم شده است.

S_t نمره احساسی نرمال‌سازی شده برای دسته داده فعلی^۶ است ($S_t \in [-1, 1]$).

γ ضریب حساسیت است که شدت تأثیر احساسات بر نرخ یادگیری را کنترل می‌کند.

(۱) پیش‌پردازش و توکن‌سازی: متون نظرات با استفاده از توکن‌ساز اختصاصی BERT پردازش شده و به توکن‌های زیرکلمه‌ای^۱ تبدیل می‌شوند.

(۲) تنظیم دقیق^۲: مدل پیش‌آموزش‌دیده بر روی داده‌های متنی دامنه آموزشی تنظیم دقیق می‌شود تا بتواند ظرافت‌های زبانی خاص محیط‌های یادگیری مانند بیان سردرگمی یا اشتیاق را شناسایی کند.

(۳) استخراج بردار ویژگی: خروجی توکن ویژه [CLS] از آخرین لایه پنهان مدل، به عنوان بردار تعبیه‌شده^۳ معنایی کل جمله استخراج می‌شود.

(۴) محاسبه نمره احساسی: این بردار به یک لایه طبقه‌بند متصل می‌شود تا احتمال تعلق متن به کلاس‌های احساسی (مثبت، منفی، خنثی) محاسبه گردد. سپس خروجی نهایی نرمال‌سازی شده و به یک اسکالر در بازه $[-1, +1]$ تبدیل می‌شود که در آن $+1$ نشان‌دهنده رضایت کامل و -1 نشان‌دهنده نارضایتی شدید است.

۳-۲ ماژول پالایش همکارانه عصبی

هسته اصلی توصیه‌گر بر پایه چارچوب پالایش همکارانه عصبی بنا شده است تا بر محدودیت خطی بودن در روش‌های فاکتورگیری ماتریس غلبه کند. این ماژول در شکل (۳) نشان داده شده است: در این ماژول:

- کاربران و آیتم‌ها ابتدا به فضاهای برداری با ابعاد ۶۴ نگاشت می‌شوند.
- بردارهای کاربر (u_i) و آیتم (v_i) از طریق عملیات الحاق^۴ ترکیب شده تا فضای ویژگی مشترکی ایجاد شود.
- بردار ترکیبی حاصل، به یک شبکه پرسپترون چندلایه با ساختار هرمی (تعداد نرون‌های ۱۲۸، ۶۴ و ۳۲ در لایه‌های متوالی) تغذیه می‌شود. از تابع فعال‌سازی ReLU برای مدل‌سازی غیرخطی و تکنیک Dropout برای جلوگیری از بیش‌برازش استفاده شده است.

^۴ Concatenation

^۵ Sigmoid

^۶ Batch

^۱ Sub-word tokens

^۲ Fine-tuning

^۳ Embedding

در دقت توصیه‌ها و سرعت انطباق با تغییرات سلیقه می‌شود یا خیر؟

۴-۱ توصیف مجموعه‌داده‌گان

برای اطمینان از تعمیم‌پذیری نتایج، از سه مجموعه‌داده‌گان با ویژگی‌های متمایز استفاده شده است:

(۱) MovieLens-1M: به‌عنوان یک معیار استاندارد^۳ برای ارزیابی عملکرد پایه پالایش همکارانه عصبی (بدون داده متنی). از آنجا که این مجموعه داده فاقد بازخوردهای متنی است، ماژول تحلیل احساسات مبتنی بر BERT برای این مجموعه فعال نشد و سازوکار نرخ یادگیری تطبیقی با مقدار پایه نرخ یادگیری اجرا گردید. استفاده از این مجموعه داده صرفاً با هدف ارزیابی پایداری مدل در محیط‌های فاقد اطلاعات احساسی و مقایسه با سایر روش‌های توصیه‌گر انجام شده است.


(۲) Amazon Books: این مجموعه داده‌گان به دلیل برخورداری از حجم عظیمی از نظرات متنی کاربران، بستری ایده‌آل برای آموزش و ارزیابی ماژول تحلیل احساسات (BERT) فراهم می‌کند.

(۳) ReMashed-TEL: یک مجموعه‌داده‌گان تخصصی در حوزه یادگیری تقویت‌شده با فناوری که شامل تعاملات ضمنی و بازخوردهای آموزشی واقعی است و برای سنجش کاربردپذیری مدل در محیط عملیاتی استفاده شده است. مشخصات آماری این مجموعه‌داده‌گان در جدول (۱) خلاصه شده است.

جدول (۱): مشخصات آماری مجموعه‌داده‌گان

میانگین طول نظرات	تعداد تعاملات	تعداد آیتم‌ها	تعداد کاربران	مجموعه‌داده‌گان
-	۱,۰۰۰,۰۰۹	۳,۹۰۰	۶,۰۴۰	MovieLens-1M
۸۵ کلمه	۲,۹۸۴,۶۳۹	۳۶۷,۹۸۲	۵۲,۶۴۳	Amazon Books
۶۰ کلمه	۱۵۰,۰۰۰	۵,۰۰۰	۱,۲۰۰	ReMashed-TEL

تحلیل رفتار فرمول: این سازوکار به این صورت عمل می‌کند که اگر بازخورد کاربر حاوی احساسات منفی شدید باشد (مانند سردرگمی)، سیستم نرخ یادگیری را افزایش می‌دهد ($\eta_t < \eta_0$) تا از نوسان‌های شدید وزن‌ها جلوگیری کرده و با احتیاط بیشتری مدل را به‌روزرسانی کند. در صورت دریافت سیگنال‌های مثبت (رضایت)، نرخ یادگیری کاهش می‌یابد ($\eta_t > \eta_0$) تا همگرایی به سمت الگوهای مطلوب تسریع شود. این استراتژی باعث می‌شود مدل در نواحی نامطمئن فضای ویژگی، گام‌های کوچک‌تر و دقیق‌تری بردارد. این ماژول مطابق با شکل (۴) می‌باشد.



شکل (۴): ماژول نرخ یادگیری تطبیقی

۳-۴ فرایند آموزش و یکپارچه‌سازی

فرایند آموزش مدل به‌صورت یکپارچه^۱ انجام می‌شود. تابع هزینه^۲ مورد استفاده، آنتروپی متقاطع باینری است که برای مسائل پیش‌بینی احتمال تعامل مناسب است. در هر تکرار^۳ از الگوریتم بهینه‌ساز Adam، ابتدا نمره احساسی S_t برای دسته داده جاری محاسبه شده، سپس نرخ یادگیری η_t طبق رابطه (۱) به‌روزرسانی می‌شود و در نهایت گرادینان‌ها اعمال می‌گردند.

۴- آزمایش‌ها و نتایج

در این بخش، عملکرد مدل پیشنهادی از طریق مجموعه‌ای از آزمایش‌های تجربی بر روی سه پایگاه داده متنوع مورد ارزیابی قرار می‌گیرد. هدف اصلی، پاسخ به این پرسش است که آیا ادغام سازوکار نرخ یادگیری تطبیقی احساس محور، منجر به بهبود معنادار

³ Iteration


⁴ Benchmark

¹ End-to-End


² Loss Function

جدول (۲): مقایسه عملکرد مدل پیشنهادی با روش‌های پایه

مدل	مجموعه داده	HR@10	NDCG@10
SVD	MovieLens	۰/۶۸۵	۰/۵۰۲
	Amazon	۰/۷۰۲	۰/۵۴۳
	ReMashed	۰/۶۹۳	۰/۵۵۹
MLP	MovieLens	۰/۷۰۹	۰/۵۱۹
	Amazon	۰/۷۴۲	۰/۵۶۱
	ReMashed	۰/۷۲۴	۰/۵۸۴
NCF	MovieLens	۰/۷۳۳	۰/۵۲۶
	Amazon	۰/۷۶۸	۰/۵۷۸
	ReMashed	۰/۷۵۷	۰/۶۰۱
پیشنهادی	MovieLens	۰/۷۵۲	۰/۵۳۴
	Amazon	۰/۸۱۸	۰/۵۹۸
	ReMashed	۰/۷۹۶	۰/۶۲۳



نمودار (۱): مقایسه عملکرد مدل پیشنهادی بر مبنای HR@10



نمودار (۲): مقایسه عملکرد مدل پیشنهادی بر مبنای

NDCG@10

۲-۴ معیارهای ارزیابی

مدل‌ها با استفاده از چارچوب PyTorch و بر روی یک سرور مجهز به پردازنده گرافیکی NVIDIA RTX 4090 پیاده‌سازی شدند. برای ماژول متنی، از مدل پیش‌آموزش‌دیده BERT-base uncased کتابخانه HuggingFace استفاده شد که بر روی داده‌های آموزشی تنظیم دقیق شده است. پارامترهای مدل نهایی با استفاده از چارچوب Optuna بهینه‌سازی شدند: اندازه دسته^۱ برابر با ۲۵۶، نرخ یادگیری اولیه (η_0) برابر با ۰/۰۰۱ و ضریب حساسیت (γ) برابر با ۰/۲ تعیین گردید. برای ارزیابی عملکرد، از معیارهای استاندارد بازیابی اطلاعات استفاده شده است:

- نرخ اصابت ($HR@10$): نشان‌دهنده حضور آیتم هدف در ۱۰ پیشنهاد برتر.
- معیار رتبه‌بندی $NDCG@10$: سنجش کیفیت رتبه‌بندی با در نظر گرفتن جایگاه آیتم صحیح.

۳-۴ فرایند آزمایش

به‌منظور تضمین قابلیت بازتولید نتایج، تمامی مجموعه داده‌ها ابتدا از نظر تعاملات تکراری و کاربران با کمتر از پنج تعامل پاکسازی شدند. سپس داده‌ها به‌صورت زمانی به سه بخش آموزش (۸۰ درصد)، اعتبارسنجی (۱۰ درصد) و آزمون (۱۰ درصد) تقسیم شدند. برای هر تعامل مثبت، چهار نمونه منفی به روش Negative Sampling تولید گردید. تمامی آزمایش‌ها با مقدار ثابت $Seed=42$ انجام شدند. نتایج گزارش‌شده میانگین پنج اجرای مستقل بوده و انحراف معیار نیز برای تحلیل آماری محاسبه گردید.

۴-۴ مقایسه عملکرد با مدل‌های پایه

مدل پیشنهادی با سه روش پایه مقایسه شد (تجزیه مقادیر منفرد)، MLP (پرسترون چندلایه ساده) و NCF (پالایش همکارانه عصبی استاندارد بدون تحلیل احساسات). نتایج کمی حاصل از آزمایش‌ها در جدول (۲) و نمودارهای تفکیکی (۱) الی (۲) ارائه شده است.


¹ Batch Size

مورد استفاده قرار گرفته است. مطابق جدول، مدل پیشنهادی اختلاف معناداری با سایر روش‌ها دارد که نشان‌دهنده جامعیت ساختاری و قدرت مدل‌سازی بالاتر آن در مقایسه با رویکردهای موجود است. جدول (۴): مقایسه نرمال‌شده عملکرد (بر اساس پوشش قابلیت‌ها +

قدرت مدل‌سازی)

مدل	عمق احساسات	علاقه پویا	مناسب برای TEL	امتیاز کلی
Dang et al.	۰/۶	۰/۳	۰/۲	۰/۳۷
Hussain et al.	۰/۵	۰/۴	۰/۸	۰/۵۷
SIFN	۰/۷	۰/۳	۰/۳	۰/۴۳
مدل پیشنهادی	۰/۹	۰/۹	۰/۹۵	۰/۹۲

با مقایسه کیفی روش پیشنهادی با روش‌های بروز، نتایجی که در نمودار (۳) نشان داده شده است، به دست آمد.



■ Dang et al ■ Hussain et al ■ SIFN ■ مدل پیشنهادی

نمودار (۳): مقایسه کمی مدل پیشنهادی با مدل‌های پیشرفته

۴-۶ تحلیل انطباق با تغییر سلیقه

برای شبیه‌سازی رانش مفهوم، ۳۰ درصد از کاربران هر مجموعه داده به صورت تصادفی انتخاب شدند. تاریخچه تعاملات این کاربران به دو بازه زمانی متوالی تقسیم گردید. در بخش دوم، ترجیحات کاربران به صورت مصنوعی تغییر داده شد؛ به گونه‌ای که بیش از ۷۰ درصد تعاملات جدید از دسته‌ای متفاوت نسبت به علائق غالب دوره اول انتخاب گردیدند. این فرایند در پنج اجرای مستقل تکرار شد و نتایج نهایی به صورت میانگین گزارش شدند. معیار نرخ تطبیق به عنوان درصد کاربرانی که آیتم‌های ژانر جدید در ۱۰ پیشنهاد برتر آن‌ها ظاهر شده‌اند، تعریف شد. نتایج در جدول (۵) و نمودار (۴) ارائه شده است.

باتوجه به نتایج آزمایش‌ها، مدل پیشنهادی در تمامی معیارها و مجموعه‌داده‌گان عملکرد برتری داشته است. بیشترین میزان بهبود در مجموعه‌داده‌گان Amazon Books مشاهده می‌شود که در آن معیار HR@10 از ۰/۷۳۸ در مدل پایه به ۰/۸۱۸ در مدل پیشنهادی (افزایش حدود ۶/۵٪) رسیده است. این جهش عملکردی در داده‌های دارای متن غنی (Amazon و ReMashed)، اثبات‌کننده فرضیه اصلی پژوهش است: ادغام سیگنال‌های عاطفی استخراج‌شده توسط BERT، مدل را در درک علائق ضمنی کاربران توانمندتر می‌سازد. برای ارزیابی معناداری آماری نتایج، هر آزمایش پنج بار اجرا شد. پیش از اعمال آزمون t زوجی، نرمال بودن توزیع داده‌ها با آزمون Shapiro-Wilk بررسی گردید. نتایج آزمون t زوجی نشان داد که بهبودهای حاصل در معیار NDCG@10 از نظر آماری معنادار هستند ($p < 0.01$). همچنین اندازه اثر محاسبه‌شده بر اساس Cohen's d برابر ۰/۸۱ بود که بیانگر اثر بزرگ سازوکار پیشنهادی است.

۴-۵ مقایسه با روش‌های پیشرفته

با مقایسه روش پیشنهادی با برخی از روش‌هایی که احساسات را لحاظ کرده‌اند نتایجی که در جدول (۳) آمده است، به دست آمد.

جدول (۳): مقایسه روش‌ها از دید کاربردی

ویژگی‌ها	Dang et al.	Hussain et al.	SIFN	مدل پیشنهادی
تحلیل احساسات عمیق	محدود	متوسط	بله	بله (BERT)
فیلترینگ مشارکتی عصبی	بله	خیر	بله	بله
تطبیق با تغییر علائق	خیر	محدود	خیر	بله
تمرکز بر TEL	خیر	بله	خیر	بله
ارزیابی Top-N	محدود	خیر	بله	بله (کامل)

جدول (۴) امتیاز کلی مدل‌های پیشرفته را بر اساس ترکیب نرمال‌شده معیارهای کیفی و ساختاری نمایش می‌دهد. این امتیاز کلی به منظور ارائه یک دید مقایسه‌ای سطح بالا میان مدل‌هایی که روی مجموعه‌داده‌ها و سناریوهای متفاوت ارزیابی شده‌اند،

۷-۴ تحلیل حساسیت احساسی

برای راستی‌آزمایی این که آیا مدل همبستگی میان احساسات و تعامل را آموخته است، ضریب همبستگی پیرسون بین میانگین نمره احساسی کاربر (S_u) و امتیاز پیش‌بینی‌شده توسط مدل ($\hat{Y}_u$) محاسبه شد. نتیجه همبستگی مثبت $r < 0.67$ ($p < 0.01$) را نشان داد. این یافته تأیید می‌کند که مدل پیشنهادی یاد گرفته است که کاربرانی با احساسات مثبت‌تر، احتمال تعامل بالاتری دارند و بالعکس؛ این امر در مدل‌های سنتی پالایش همکارانه عصبی نادیده گرفته می‌شود.

۵- نتیجه‌گیری و کارهای آتی

۱-۵ نتیجه‌گیری

این پژوهش با هدف حل چالش بنیادین پویایی سلیقه^۲ در سیستم‌های توصیه‌گر آموزشی، یک معماری ترکیبی نوین ارائه نمود که پالایش همکارانه عصبی را با تحلیل احساسات عمیق ادغام می‌کند. برخلاف رویکردهای پیشین که احساسات را تنها به‌عنوان یک ویژگی ورودی ایستا در نظر می‌گرفتند، این مطالعه برای نخستین بار از سیگنال‌های عاطفی به‌عنوان یک پارامتر کنترلی فعال در سطح الگوریتم بهینه‌سازی استفاده کرد.


یافته‌های کلیدی این پژوهش عبارت‌اند از:

(۱) ارتقای دقت توصیه‌ها: ادغام مدل زبانی BERT با شبکه عصبی توصیه‌گر، منجر به بهبود معنادار در معیارهای رتبه‌بندی شد. به‌ویژه در محیط‌های غنی از متن (مانند مجموعه‌داده‌گان Amazon Books)، معیار $HR@10$ تا ۶۰٪ بهبود یافت که نشان‌دهنده توانایی مدل در درک علایق ضمنی کاربران است.

(۲) واکنش سریع به رانش مفهوم: سازوکار نرخ یادگیری تطبیقی احساس محور اثربخشی خود را در سناریوهای تغییر سلیقه ناگهانی اثبات کرد. نتایج نشان داد که این سازوکار نرخ انطباق را از ۷۵٪ در مدل پایه به ۸۸٪ ارتقا داده و همان‌طور


جدول (۵): مقایسه نرخ تطبیق پس از تغییر سلیقه

مدل	HR@10	NDCG@10	بهبود
NCF	۰/۷۴۲	۰/۵۴۸	۰
NCF + Adaptive LR	۰/۷۶۱	۰/۵۷۱	+۰/۴/۲
NCF+BERT	۰/۷۸۹	۰/۵۹۲	+۰/۸/۰
FULL	۰/۷۹۶	۰/۶۲۳	+۰/۱۳/۷



نمودار (۴): نتایج مطالعه حذف مؤلفه برای بررسی سهم اجزای مدل مدل پیشنهادی مجهز به نرخ یادگیری تطبیقی، تنها پس از ۳ دوره آموزشی^۱ به نرخ تطبیق ۰/۷۵ رسید، درحالی‌که مدل پایه NCF برای رسیدن به همین سطح نیازمند ۶ دوره بود. همان‌طور که در نمودار (۵) نشان داده‌شده است این شتاب در یادگیری، ناشی از عملکرد فرمول پیشنهادی است که در مواجهه با نارضایتی کاربر (ناشی از عدم تطابق پیشنهادها با سلیقه جدید)، نرخ یادگیری را دستخوش تغییر کرده و مدل را وادار به بازآرایی سریع وزن‌ها می‌کند.

روند تطبیق‌پذیری مدل‌ها در طول زمان



نمودار (۵): روند تطبیق‌پذیری مدل‌ها در طول زمان

² Dynamic Preference

¹ Epoch

▪ تک وجهی بودن: این مدل تنها بر بازخوردهای متنی تمرکز دارد و از سایر نشانگرهای عاطفی مهم در آموزش آنلاین مانند حالات چهره در ویدئوکنفرانس یا لحن صدا استفاده نشده است.

۳-۵ پیشنهادها برای کارهای آتی

بر اساس یافته‌ها و محدودیت‌های ذکر شده، مسیرهای پژوهشی زیر پیشنهاد می‌گردد:

(۱) تحلیل چندوجهی^۲: توسعه مدلی که بتواند علاوه بر متن، داده‌های صوتی و تصویری را نیز پردازش کند. استفاده از مدل‌هایی نظیر CLIP برای هم‌راستاسازی داده‌های چندرسانه‌ای می‌تواند دقت تشخیص احساسات را افزایش دهد.

(۲) بومی‌سازی مدل‌های زبانی: با توجه به نیاز روزافزون پلتفرم‌های آموزشی بومی، جایگزینی BERT انگلیسی با مدل‌های زبانی فارسی نظیر ParsBERT یا HooshBERT برای استخراج دقیق‌تر احساسات در متون فارسی پیشنهاد می‌شود.

یادگیری تقویتی^۳: در مدل فعلی، ضریب حساسیت (γ) ثابت در نظر گرفته شده است. پژوهش‌های آتی می‌توانند از عامل‌های یادگیری تقویتی برای تنظیم پویای این فرآیند بر اساس پاداش‌های بلندمدت (مانند موفقیت تحصیلی یادگیرنده) استفاده کنند.

References

- [1] L. Shi, "The integration of advanced AI-enabled emotion detection and adaptive learning systems for improved emotional regulation," J. Educ. Comput. Res., vol. 63, no.1, pp. 173–201, 2025.
- [2] R. Karthika, V. E. Jesi, M. S. Christo, L. J. Deborah, A. Sivaraman, and S. Kumar, "Intelligent personalised learning system based on emotions in e-learning," Pers. Ubiquitous Comput., vol. 27, no.6, pp. 2211–2223, 2023.
- [3] Y. Wang, "Research on online learner modeling and course recommendation based on

که در نمودار ۵ نشان داده شده است، زمان همگرایی را به‌طور قابل توجهی کاهش می‌دهد.

(۳) همبستگی عاطفی-شناختی: تحلیل‌های آماری وجود همبستگی مثبت و قوی $r = 0.67$ میان احساسات مثبت و نرخ پذیرش توصیه‌ها را تأیید کرد، که فرضیه اصلی مبنی بر نقش تعیین‌کننده عواطف در یادگیری را تقویت می‌کند.

این پژوهش نشان داد که گذر از مدل‌های واکنشی به مدل‌های تطبیقی که نسبت به وضعیت روانی یادگیرنده حساس هستند، گامی ضروری برای توسعه نسل آینده سیستم‌های یادگیری هوشمند است.

۲-۵ محدودیت‌ها

علیرغم دستاوردهای فوق، این پژوهش با محدودیت‌هایی روبرو بود که باید در تفسیر نتایج لحاظ گردند:

- هزینه محاسباتی: استفاده از مدل‌های زبانی بزرگ مانند BERT و تنظیم دقیق آن‌ها نیازمند منابع پردازشی قدرتمند (GPU) است که ممکن است پیاده‌سازی آن را در دستگاه‌های لبه^۱ یا محیط‌های با منابع محدود دشوار سازد.
- وابستگی به کیفیت متن: کارایی ماژول تحلیل احساسات به شدت وابسته به کیفیت نظرات کاربران است. متون حاوی نویز، غلط‌های املایی زیاد یا زبان عامیانه غیرمعمول می‌تواند دقت استخراج سیگنال احساسی (S_t) را کاهش دهد.

emotional factors," Sci. Program., vol. 2022, no. 1, p.,2022.

- [4] H. Ezaldeen, R. Misra, S. K. Bisoy, R. Alatrash, and R. Priyadarshini, "A hybrid E-learning recommendation integrating adaptive profiling and sentiment analysis," J. Web Semant., vol. 72, p.,2022.
- [5] S. Abakarim, S. Qassimi, and S. Rakrak, "Emotion and sentiment enriched decision transformer for personalized recommendations," Sci. Rep., vol. 15, no.1,2025.
- [6] S. Li et al., "Region-aware neural graph collaborative filtering for personalized

³ Reinforcement Learning

¹ Edge Devices

² Multimodal Analysis

- recommendation," *Int. J. Digit. Earth*, vol. 15, no.1, pp. 1446–1462, 2022.
- [7] X. Fan, Y. Ji, and B. Hui, "A dynamic preference recommendation model based on spatiotemporal knowledge graphs," *Complex Intell. Syst.*, vol. 11, no. 1, p.46,2025.
- [8] J. Wu, Y. Xu, B. Zhang, Z. Xu, and B. Li, "Graph-based Dynamic Preference Modeling for Personalized Recommendation," in *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, 2024, pp. 356–368.
- [9] Y. Kim, Y. Lee, V. Yuan, A. Lee, and Y. Lee, "A temporal graph network framework for dynamic recommendation," *arXivPrepr.arXiv2403.16066*, 2024.
- [10] L. Xia, C. Huang, Y. Xu, and J. Pei, "Multi-behavior sequential recommendation with temporal graph transformer," *IEEE Trans. Knowl. Data Eng.*, vol. 35, no.6, pp. 6099–6112, 2022.
- [11] T. Sargazi Moghadam, A. Darejeh, M. Delaramifar, and S. Mashayekh, "Toward an artificial intelligence-based decision framework for developing adaptive e-learning systems to impact learners' emotions," *Interact. Learn. Environ.*, vol. 32, no.7, pp. 3665–3685, 2024.
- [12] T. Hussain, L. Yu, M. Asim, A. Ahmed, and M. A. Wani, "Enhancing e-learning adaptability with automated learning style identification and sentiment analysis: a hybrid deep learning approach for smart education," *Information*, vol. 15, no. 5, p.277,2024.
- [13] Y. Tian, S. Peng, X. Zhang, T. Rodemann, K. C. Tan, and Y. Jin, "A Recommender System for Metaheuristic Algorithms for Continuous Optimization Based on Deep Recurrent Neural Networks," *IEEE Trans. Artif. Intell.*, vol. 1, no.1, pp. 5–18, 2021.
- [14] E. Dang, Z. Hu, and T. Li, "Enhancing collaborative filtering recommender with prompt-based sentiment analysis," *arXiv Prepr. arXiv2207.12883*, 2022.
- [15] K. Zhang et al., "Sifn: A sentiment-aware interactive fusion network for review-based item recommendation," in *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*, 2021, pp. 3627–3631.
- [16] Karabila, N. Darraz, A. El-Ansari, N. Alami, M. Lazaar, and M. El Mallahi, "Recommendation system using Deep Learning-based sentiment analysis," in *2023Sixth International Conference on Vocational Education and Electrical Engineering*, 2023, pp. 41–47.
- [17] H. Li, J. Zheng, B. Jin, and H. Zhu, "Adaptive Knowledge Contrastive Learning with Dynamic Attention for Recommender Systems," *Electronics*, vol. 13, no. 18, p. 3594, 2024.
- [18] J. C. Salazar, J. Aguilar, J. Monsalve-Pulido, and E. Montoya, "A generic architecture of an affective recommender system for e-learning environments," *Univers. Access Inf. Soc.*, vol. 23, no. 3, pp. 1115–1134, 2024.
- [19] Bhatia et al., "A Sentiment Analysis-Based Recommender Framework for Massive Open Online Courses Toward Education 4.0," in *Lecture Notes in Networks and Systems*, 2023, vol. 421, pp. 817–827.
- [20] Y. Cui, H. Yu, X. Guo, H. Cao, and L. Wang, "RAKCR: Reviews sentiment-aware based knowledge graph convolutional networks for Personalized Recommendation," *Expert Syst. Appl.*, vol. 248, p. 123403, 2024.

A Sentiment-Driven Adaptive Learning Rate Mechanism for Neural Recommender Systems in Technology-Enhanced Learning

Mohammad Mehran Lesan Sedgh¹, Alimohammad Latif^{2*}, Sima Emadi³

¹ PhD student, Department of Computer Engineering, Ya. C., Islamic Azad University, Yazd, Iran

² Professor, Department of Computer Engineering, Yazd University, Yazd, Iran

³ Associate Professor, Department of Computer Engineering, Ya. C., Islamic Azad University, Yazd, Iran

Article Information

Original Research Paper

Received:

2026 April 5

Accepted:

2026 July 13

Keywords:

Educational Recommender Systems, Adaptive Learning Rate, Neural Collaborative Filtering, Sentiment Analysis, Deep Learning, Concept Drift

Corresponding Author*:

alatif@yazd.ac.ir

Abstract

In technology enhanced learning ecosystems, the dynamic evolution of learners' interests—commonly referred to as concept drift—and the inability of traditional recommender models to rapidly adapt to these changes constitute a fundamental challenge. Although neural recommender systems have demonstrated strong capability in modeling complex nonlinear interactions, the use of static learning rates or conventional decay mechanisms often leads to slow responsiveness to abrupt shifts in user preferences. To address this limitation, the present study proposes a novel adaptive learning rate mechanism in which the weight update rate of the model is directly governed by the intensity and polarity of user sentiments extracted using a BERT based language model. The central hypothesis is that negative sentiments act as a strong signal indicating the need for rapid model correction. Experimental evaluation on relevant datasets shows that the proposed approach improves the model's adaptation rate to sudden preference changes by up to 13% compared with a baseline Neural Collaborative Filtering model. In addition, the method enhances ranking accuracy while significantly improving system convergence speed in dynamic environments.



: 10.22034/ABMIR.2026.24443.1232

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/>.

