

ارائه یک چارچوب هوشمند مبتنی بر یادگیری عمیق برای پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر چندوجهی

محمدرضا بحرانی

مدیرعامل شرکت و آکادمی تخصصی هوش مصنوعی نوپسا، آزمایشگاه هوش مصنوعی نوپسا
Bahrani.mohammadreza@yahoo.com

چکیده

با گسترش روزافزون سامانه‌های هوشمند و افزایش حجم داده‌های تولیدشده توسط کاربران، تحلیل و پیش‌بینی رفتار کاربران به یکی از چالش‌های اساسی در طراحی سیستم‌های توصیه‌گر تبدیل شده است. روش‌های سنتی مبتنی بر داده‌های تک‌بعدی، توانایی محدودی در استخراج الگوهای پیچیده رفتاری دارند و معمولاً دقت پیش‌بینی پایینی ارائه می‌دهند. در این پژوهش، یک چارچوب هوشمند مبتنی بر یادگیری عمیق برای پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر چندوجهی ارائه می‌شود. چارچوب پیشنهادی با ترکیب داده‌های رفتاری، زمانی و محتوایی کاربران، از یک معماری ترکیبی شامل شبکه‌های عصبی کانولوشنی (CNN) برای استخراج ویژگی‌ها و شبکه‌های حافظه بلندمدت کوتاه‌مدت (LSTM) برای مدل‌سازی وابستگی‌های زمانی استفاده می‌کند. به‌منظور ارزیابی عملکرد مدل پیشنهادی، آزمایش‌ها بر روی داده‌های شبیه‌سازی‌شده انجام شده و نتایج حاصل نشان می‌دهد که چارچوب ارائه‌شده در مقایسه با روش‌های پایه، بهبود قابل‌توجهی در دقت پیش‌بینی و تحلیل رفتار کاربران ایجاد می‌کند. یافته‌های این پژوهش بیانگر توانمندی مدل پیشنهادی در ارتقای کیفیت سیستم‌های توصیه‌گر و افزایش سطح شخصی‌سازی خدمات در سامانه‌های هوشمند آینده است.

واژگان کلیدی: یادگیری عمیق، سیستم‌های توصیه‌گر، پیش‌بینی رفتار کاربران، داده‌های چندوجهی، شبکه‌های عصبی

مقدمه

در سال‌های اخیر، رشد سریع سامانه‌های هوشمند و افزایش تعامل کاربران با پلتفرم‌های دیجیتال، منجر به تولید حجم عظیمی از داده‌های متنوع و ناهمگون شده است. این داده‌ها که شامل اطلاعات رفتاری، زمانی، محتوایی و تعاملی کاربران هستند، نقش کلیدی در بهبود کیفیت تصمیم‌گیری سیستم‌های هوشمند ایفا می‌کنند. در این میان، سیستم‌های توصیه‌گر به‌عنوان یکی از مهم‌ترین کاربردهای هوش مصنوعی، با هدف ارائه پیشنهادهای شخصی‌سازی‌شده و متناسب با علایق کاربران توسعه یافته‌اند. با این حال، یکی از چالش‌های اساسی در طراحی این سیستم‌ها، پیش‌بینی دقیق رفتار کاربران در محیط‌های پویا و چندبعدی است. روش‌های سنتی مورد استفاده در سیستم‌های توصیه‌گر، عمدتاً بر داده‌های تک‌بعدی و مدل‌های آماری یا الگوریتم‌های یادگیری ماشین کلاسیک متکی هستند. این رویکردها، اگرچه در مسائل ساده کارایی قابل قبولی دارند، اما در مواجهه با داده‌های پیچیده و چندوجهی کاربران، توانایی محدودی در استخراج الگوهای عمیق رفتاری از خود نشان می‌دهند. علاوه بر این، نادیده گرفتن وابستگی‌های زمانی و توالی رفتار کاربران، موجب کاهش دقت پیش‌بینی و افت کیفیت توصیه‌ها می‌شود. از این‌رو، استفاده از رویکردهای نوین مبتنی بر یادگیری عمیق به‌عنوان راهکاری مؤثر برای غلبه بر این محدودیت‌ها مورد توجه پژوهشگران قرار گرفته است.

یادگیری عمیق با بهره‌گیری از ساختارهای چندلایه شبکه‌های عصبی، قابلیت استخراج ویژگی‌های سطح بالا از داده‌های پیچیده را فراهم می‌سازد. به‌ویژه، ترکیب معماری‌های مختلف شبکه‌های عصبی نظیر شبکه‌های عصبی کانولوشنی و شبکه‌های بازگشتی، امکان تحلیل همزمان ویژگی‌های محتوایی و وابستگی‌های زمانی را فراهم می‌کند. این قابلیت، زمینه‌ساز توسعه سیستم‌های توصیه‌گر هوشمندتر و دقیق‌تر در محیط‌های چندوجهی شده است. با این وجود، همچنان نیاز به ارائه چارچوب‌هایی منسجم و کارآمد وجود دارد که بتوانند داده‌های متنوع کاربران را به‌صورت یکپارچه مدل‌سازی کرده و عملکرد سیستم‌های توصیه‌گر را بهبود بخشند. بررسی پژوهش‌های پیشین نشان می‌دهد که مطالعات متعددی به استفاده از یادگیری عمیق در سیستم‌های توصیه‌گر پرداخته‌اند، اما بسیاری از آن‌ها تنها بر یک نوع داده یا یک معماری خاص تمرکز داشته‌اند و کمتر به ارائه یک چارچوب جامع برای پیش‌بینی رفتار کاربران در محیط‌های چندوجهی توجه شده است. این خلأ پژوهشی، ضرورت انجام مطالعاتی را آشکار می‌سازد که بتوانند با رویکردی ترکیبی، ابعاد مختلف رفتار کاربران را به‌صورت همزمان مورد تحلیل قرار دهند.

هدف اصلی این پژوهش، ارائه یک چارچوب هوشمند مبتنی بر یادگیری عمیق برای پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر چندوجهی است. در این راستا، تلاش شده است با ترکیب داده‌های رفتاری و زمانی کاربران و استفاده از معماری‌های نوین شبکه‌های عصبی، مدلی کارآمد جهت افزایش دقت پیش‌بینی و بهبود کیفیت توصیه‌ها ارائه شود. فرضیه اصلی پژوهش بر این مبنا استوار است که استفاده از یک چارچوب یادگیری عمیق ترکیبی، می‌تواند نسبت به روش‌های پایه، عملکرد بهتری در تحلیل و پیش‌بینی رفتار کاربران از خود نشان دهد و نقش مؤثری در ارتقای سطح شخصی‌سازی سیستم‌های توصیه‌گر ایفا کند.

روش تحقیق

پژوهش حاضر از نظر هدف، کاربردی و از نظر ماهیت، توصیفی-تحلیلی است که با رویکردی مبتنی بر شبیه‌سازی و مدل‌سازی هوشمند انجام شده است. در این تحقیق، با هدف پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر چندوجهی، یک چارچوب مبتنی بر یادگیری عمیق طراحی و ارزیابی شده است. تمرکز اصلی پژوهش بر بررسی توانمندی معماری‌های نوین شبکه‌های عصبی در تحلیل داده‌های رفتاری و زمانی کاربران و بهبود دقت پیش‌بینی در مقایسه با روش‌های پایه می‌باشد. با توجه به ماهیت فنی و مدل‌محور پژوهش، جامعه آماری شامل داده‌های رفتاری کاربران در یک سیستم توصیه‌گر فرضی است. داده‌های مورد استفاده در این تحقیق به‌صورت شبیه‌سازی‌شده تولید شده‌اند تا شرایط واقعی تعامل کاربران با سیستم‌های توصیه‌گر دیجیتال بازنمایی شود. این داده‌ها شامل اطلاعاتی نظیر تاریخچه تعامل کاربران، توالی کلیک‌ها، میزان علاقه‌مندی به اقلام پیشنهادی

و الگوهای زمانی رفتار کاربران می‌باشند. استفاده از داده‌های شبیه‌سازی شده، امکان کنترل بهتر متغیرها و ارزیابی دقیق‌تر عملکرد مدل پیشنهادی را فراهم ساخته است.

ابزار اصلی پژوهش، یک مدل یادگیری عمیق ترکیبی متشکل از شبکه عصبی کانولوشنی (CNN) و شبکه حافظه بلندمدت کوتاه‌مدت (LSTM) است. در چارچوب پیشنهادی، ابتدا داده‌های ورودی کاربران پیش‌پردازش شده و ویژگی‌های اولیه از آن‌ها استخراج می‌شود. سپس شبکه CNN به‌منظور استخراج ویژگی‌های سطح بالا و الگوهای پنهان از داده‌های رفتاری مورد استفاده قرار می‌گیرد. در ادامه، خروجی این شبکه به‌عنوان ورودی به شبکه LSTM منتقل می‌شود تا وابستگی‌های زمانی و توالی رفتار کاربران به‌صورت مؤثر مدل‌سازی گردد. این ترکیب، امکان تحلیل همزمان ساختار داده‌ها و تغییرات زمانی رفتار کاربران را فراهم می‌سازد. به‌منظور ارزیابی عملکرد چارچوب پیشنهادی، داده‌های شبیه‌سازی شده به دو بخش آموزش و آزمون تقسیم شده‌اند. معیارهای ارزیابی شامل دقت پیش‌بینی، نرخ خطا و توانایی مدل در شناسایی الگوهای رفتاری کاربران می‌باشند. نتایج حاصل از مدل پیشنهادی با نتایج به‌دست‌آمده از روش‌های پایه مورد مقایسه قرار گرفته تا میزان بهبود عملکرد مشخص شود. تحلیل داده‌ها به‌صورت توصیفی و تحلیلی انجام شده و نتایج به‌صورت جدول و نمودار ارائه گردیده است تا امکان تفسیر دقیق یافته‌ها فراهم شود.

سیر تحول روش‌ها در پیش‌بینی رفتار کاربر (از کلاسیک تا عمیق)

در نسل‌های اولیه سیستم‌های توصیه‌گر، تمرکز اصلی بر فیلترینگ مشارکتی مبتنی بر همسایگی بود؛ یعنی پیش‌بینی علاقه کاربر بر اساس شباهت او با کاربران دیگر یا شباهت اقلام (Resnick, 1994). این روش‌ها با وجود سادگی و کارایی اولیه، در عمل با محدودیت‌هایی مثل پراکندگی داده‌ها (Sparsity)، مشکل شروع سرد (Cold-Start) و مقیاس‌پذیری در داده‌های بزرگ مواجه بودند. با رشد پلتفرم‌های دیجیتال و افزایش تعاملات، روش‌های کلاسیک برای استخراج الگوهای پیچیده رفتاری کافی نبودند و نیاز به مدل‌هایی با قابلیت نمایش بهتر روابط پنهان میان کاربر-آیتم افزایش یافت.

در ادامه، رویکردهای فاکتورگیری ماتریسی به‌عنوان یک گام مهم مطرح شدند و توانستند از طریق نمایش نهفته کاربران و اقلام، نسبت به روش‌های همسایگی عملکرد دقیق‌تری ارائه دهند (Koren et al, 2009). علاوه بر این، با غالب شدن داده‌های ضمنی (مثل کلیک و خرید)، مسئله توصیه‌گری از «پیش‌بینی امتیاز» به سمت «رتبه‌بندی شخصی‌سازی شده» حرکت کرد و روش‌هایی مانند BPR برای بهینه‌سازی مستقیم رتبه‌بندی پیشنهاد شدند (Rendle et al, 2009). با این وجود، حتی در مدل‌های فاکتورگیری، رفتار کاربر غالباً به‌صورت ایستا و بدون لحاظ کامل پویایی زمانی و زمینه رخدادها مدل‌سازی می‌شد؛ در حالی که ترجیحات کاربران در واقعیت، وابسته به توالی تعاملات و تغییرات زمینه‌ای است (Ricci et al, 2015).

گذار از مدل‌های کلاسیک به یادگیری عمیق (یادگیری نمایش و تعامل غیرخطی)

با پیشرفت یادگیری عمیق، تمرکز پژوهش‌ها از طراحی دستی ویژگی‌ها به سمت یادگیری خودکار نمایش‌ها (Representation Learning) تغییر یافت. برخلاف مدل‌های سنتی که تعامل کاربر-آیتم را با ضرب داخلی یا روابط خطی ساده مدل می‌کردند، چارچوب‌هایی مانند Neural Collaborative Filtering نشان دادند که می‌توان تعامل را به‌صورت یک تابع غیرخطی قابل یادگیری با شبکه عصبی مدل کرد و بهبود معناداری در کیفیت توصیه‌ها ایجاد نمود (He et al, 2017). در مقیاس صنعتی نیز مدل‌هایی مانند Wide & Deep با هدف ترکیب «حفظ الگوهای دیده‌شده (Memorization)» و «تعمیم به ترکیب‌های جدید (Generalization)» مطرح شدند و نشان دادند که شبکه‌های عمیق می‌توانند در محیط‌های واقعی پلتفرم‌ها، ارزش عملی ایجاد کنند (Cheng et al, 2016).

در این مرحله، علاوه بر خود تعاملات، توجه به داده‌های جانبی مانند ویژگی‌های آیتم، متن، و سیگنال‌های رفتاری نیز پررنگ‌تر شد

و پژوهش‌های مروری نشان دادند که یادگیری عمیق به دلیل توانایی در مدل‌سازی روابط پیچیده و غیرخطی، مسیر اصلی توسعه سیستم‌های توصیه‌گر مدرن است (Zhang et al, 2019). با این حال، بخش مهمی از رفتار کاربر ماهیتی توالی‌محور دارد و همین مسئله باعث شد رویکردهای «توصیه‌گرهای ترتیبی (Sequential Recommendation)» به‌عنوان جریان غالب بعدی شکل بگیرد.

مدل‌سازی توالی رفتار (از RNN/GRU تا Self-Attention و Transformer)

یکی از نقاط عطف در پیش‌بینی رفتار کاربر، ورود مدل‌های بازگشتی برای تحلیل توالی تعاملات بود. در این رویکردها، رفتارهای کاربر به صورت یک دنباله زمانی (کلیک/بازدید/خرید) در نظر گرفته می‌شود تا مدل بتواند وابستگی بین رویدادهای اخیر و تصمیم بعدی را یاد بگیرد. پژوهش GRU4Rec نشان داد که مدل‌های مبتنی بر شبکه‌های بازگشتی می‌توانند در سناریوهای جلسه‌محور (Session-based) نسبت به خطوط پایه رایج، بهبود محسوسی ایجاد کنند (Hidasi et al, 2016). با این حال، RNNها در مقیاس بزرگ چالش‌هایی مثل محاسبات ترتیبی (کندی) و دشواری یادگیری وابستگی‌های بسیار بلندمدت دارند. در ادامه، رویکردهای مبتنی بر Self-Attention به‌عنوان جایگزینی کارآمدتر مطرح شدند. مدل SASRec با استفاده از توجه، قادر است از تاریخچه تعاملات کاربر، موارد «مرتبط‌تر» را برای پیش‌بینی انتخاب کند و ضمن افزایش کیفیت، کارایی محاسباتی بهتری نسبت به RNNها ارائه دهد (Kang and McAuley, 2018). سپس مدل‌های Transformer-محور مانند BERT4Rec با ایده استفاده از زمینه دوسویه و آموزش مبتنی بر ماسک‌کردن، کیفیت مدل‌سازی توالی را در بسیاری از بنچمارک‌ها ارتقا دادند و نشان دادند که Transformerها می‌توانند نمایشی غنی‌تر از توالی رفتار کاربر بسازند (Sun et al, 2019). این روند تکاملی نشان می‌دهد که پیش‌بینی رفتار کاربر امروز عمدتاً به سمت مدل‌هایی رفته که هم وابستگی‌های زمانی و هم زمینه تعاملات را دقیق‌تر لحاظ می‌کنند.

چندوجهی‌سازی داده‌ها (چرا Multimodal؟ و مسیر رسیدن به چارچوب پیشنهادی)

در بسیاری از سامانه‌های واقعی، رفتار کاربر صرفاً با سیگنال‌های تعاملی توضیح داده نمی‌شود و داده‌های محتوایی مانند تصویر و متن نقش تعیین‌کننده‌ای دارند؛ به‌ویژه در حوزه‌هایی مانند تجارت الکترونیک و شبکه‌های اجتماعی. یکی از نمونه‌های اثرگذار، VBPR است که نشان داد افزودن ویژگی‌های بصری استخراج‌شده از تصاویر محصول می‌تواند هم دقت رتبه‌بندی را افزایش دهد و هم بخشی از مشکل شروع سرد را کاهش دهد (He and McAuley, 2016). این دسته از پژوهش‌ها مسیر را برای توصیه‌گرهای چندوجهی هموار کردند؛ توصیه‌گرهایی که علاوه بر تاریخچه تعامل، از محتوای آیتم‌ها (متن/تصویر/ویژگی‌های جانبی) نیز برای فهم بهتر ترجیحات کاربر استفاده می‌کنند (Zhang et al, 2019).

با جمع‌بندی روندهای فوق، می‌توان گفت شکاف اصلی در بسیاری از کارها، یا توجه محدود به توالی (فقط محتوایی) بوده یا توجه محدود به محتوا (فقط توالی). بنابراین رویکرد پژوهش حاضر بر طراحی یک چارچوب استوار است که بتواند همزمان: (۱) توالی رفتار کاربر را مدل کند، (۲) سیگنال‌های چندوجهی را در استخراج ویژگی وارد کند، و (۳) خروجی را برای پیش‌بینی رفتار/تعامل بعدی آماده سازد. این نگاه با چارچوب‌های مفهومی توصیه‌گرها و ملاحظات ارزیابی و کاربردپذیری که در منابع مرجع این حوزه مطرح شده‌اند سازگار است (Ricci et al, 2015).

طراحی فرآیند پژوهش و چارچوب اجرایی پیشنهادی

در پژوهش حاضر، فرآیند تحقیق بر اساس یک چارچوب مرحله‌ای و نظام‌مند طراحی شده است تا امکان تحلیل دقیق رفتار کاربران و ارزیابی منصفانه مدل پیشنهادی فراهم شود. این فرآیند از مراحل استخراج و آماده‌سازی داده‌ها آغاز شده و تا آموزش، ارزیابی و مقایسه مدل ادامه می‌یابد. طراحی این مسیر اجرایی با الهام از چارچوب‌های رایج در پژوهش‌های حوزه سیستم‌های توصیه‌گر و یادگیری عمیق انجام شده است (Ricci et al, 2015; Zhang et al, 2019).

در گام نخست، داده‌های خام رفتاری کاربران که شامل توالی تعاملات آن‌ها با اقلام مختلف است، مورد پیش‌پردازش قرار می‌گیرند. این مرحله شامل حذف داده‌های ناقص، یکسان‌سازی قالب داده‌ها و مرتب‌سازی تعاملات هر کاربر بر اساس ترتیب زمانی وقوع آن‌ها است. پژوهش‌های پیشین نشان داده‌اند که رعایت ترتیب زمانی تعاملات نقش مهمی در مدل‌سازی صحیح رفتار کاربران دارد و بی‌توجهی به آن می‌تواند منجر به سوگیری در نتایج شود (Hidasi et al, 2016). به همین دلیل، در این تحقیق تعاملات کاربران به صورت توالی‌های زمانی ساخت‌یافته ذخیره و پردازش می‌شوند.

پس از پیش‌پردازش، تاریخچه تعامل هر کاربر به صورت یک دنباله از رویدادها مدل‌سازی می‌شود. هر دنباله نمایانگر مسیر تصمیم‌گیری کاربر در طول زمان است و مبنای اصلی پیش‌بینی رفتار آینده او محسوب می‌شود. این رویکرد مطابق با اصول سیستم‌های توصیه‌گر ترتیبی است که در آن‌ها هدف، پیش‌بینی تعامل بعدی کاربر بر اساس تعاملات قبلی است (Kang and McAuley, 2018). در این مرحله، طول دنباله‌ها به گونه‌ای تنظیم می‌شود که هم اطلاعات کافی از رفتار گذشته کاربر حفظ گردد و هم پیچیدگی محاسباتی مدل کنترل شود.

در ادامه، ویژگی‌های مرتبط با رفتار کاربران و اقلام مورد تعامل استخراج می‌شوند. این ویژگی‌ها می‌توانند شامل شاخص‌های رفتاری، اطلاعات زمینه‌ای و در صورت وجود، ویژگی‌های محتوایی اقلام باشند. پژوهش‌های متعددی نشان داده‌اند که استفاده از داده‌های چندوجهی، درک عمیق‌تری از ترجیحات کاربران فراهم می‌سازد و دقت پیش‌بینی را افزایش می‌دهد (He and McAuley, 2016). در چارچوب پیشنهادی، این ویژگی‌ها به صورت یکپارچه به مدل یادگیری عمیق تزریق می‌شوند تا امکان تحلیل همزمان ابعاد مختلف رفتار کاربران فراهم گردد.

پس از آماده‌سازی داده‌ها و ویژگی‌ها، مدل یادگیری عمیق پیشنهادی آموزش داده می‌شود. فرآیند آموزش بر پایه یادگیری الگوهای پنهان در توالی رفتار کاربران انجام می‌گیرد و مدل تلاش می‌کند وابستگی‌های زمانی و روابط غیرخطی میان تعاملات را فرا بگیرد. مطابق با یافته‌های پژوهش‌های پیشین، استفاده از معماری‌های عمیق در این مرحله موجب افزایش توان مدل در شناسایی الگوهای پیچیده رفتاری می‌شود (He et al, 2017). آموزش مدل به صورت تکرارشونده انجام شده و پارامترها تا رسیدن به همگرایی مناسب به روزرسانی می‌شوند.

پس از آموزش، عملکرد مدل پیشنهادی با استفاده از داده‌های آزمون مورد ارزیابی قرار می‌گیرد. در این مرحله، خروجی مدل با رفتار واقعی کاربران مقایسه می‌شود تا میزان دقت پیش‌بینی مشخص گردد. ارزیابی عملکرد بر اساس رویکردهای رایج در ادبیات سیستم‌های توصیه‌گر انجام می‌شود و تلاش می‌شود نتایج به گونه‌ای گزارش شوند که قابلیت مقایسه با پژوهش‌های مشابه را داشته باشند (Sun et al, 2019). این مرحله نقش مهمی در سنجش کارایی چارچوب پیشنهادی و اعتبار نتایج پژوهش ایفا می‌کند. در گام نهایی، نتایج حاصل از مدل پیشنهادی به صورت تحلیلی با نتایج روش‌های پایه گزارش شده در پژوهش‌های پیشین مقایسه می‌شود. هدف از این مقایسه، بررسی میزان بهبود عملکرد و نشان دادن مزیت‌های چارچوب پیشنهادی نسبت به رویکردهای سنتی و تک‌بعدی است. چنین مقایسه‌ای یکی از الزامات اصلی در پژوهش‌های حوزه سیستم‌های توصیه‌گر محسوب می‌شود و امکان تفسیر دقیق‌تر یافته‌ها را فراهم می‌سازد (Ricci et al, 2015).

توصیف داده‌ها و سناریوی شبیه‌سازی شده پژوهش

با توجه به هدف پژوهش که تحلیل و پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر چندوجهی است، استفاده از داده‌هایی که بتوانند الگوهای واقعی تعامل کاربران را بازنمایی کنند، از اهمیت بالایی برخوردار است. در پژوهش حاضر، به منظور کنترل بهتر متغیرها و بررسی دقیق عملکرد چارچوب پیشنهادی، از داده‌های شبیه‌سازی شده مبتنی بر سناریوهای رایج سیستم‌های توصیه‌گر استفاده شده است. استفاده از چنین داده‌هایی در مطالعات مفهومی و توسعه‌ای، رویکردی متداول در ادبیات این حوزه محسوب می‌شود (Ricci et al, 2015).

در سناریوی شبیه‌سازی شده، مجموعه‌ای از کاربران و اقلام در نظر گرفته شده‌اند که تعامل میان آن‌ها نمایانگر رفتار کاربران در یک سامانه توصیه‌گر دیجیتال است. هر تعامل می‌تواند بیانگر رویدادهایی نظیر مشاهده، کلیک یا انتخاب یک قلم باشد. پژوهش‌های پیشین نشان داده‌اند که تمرکز بر تعاملات ضمنی، نسبت به امتیازدهی صریح، تصویر واقع‌گرایانه‌تری از رفتار کاربران ارائه می‌دهد (Koren et al, 2009). بر این اساس، داده‌های این پژوهش عمدتاً بر تعاملات ضمنی کاربران استوار شده‌اند.

یکی از ویژگی‌های کلیدی داده‌های مورد استفاده، ساختار زمانی تعاملات است. تعاملات هر کاربر به صورت یک دنباله زمانی مرتب شده‌اند تا پویایی رفتار کاربران در طول زمان حفظ شود. این رویکرد با مبانی سیستم‌های توصیه‌گر ترتیبی همخوانی دارد که در آن‌ها رفتار کاربران به عنوان یک فرآیند پویا و وابسته به توالی تعاملات در نظر گرفته می‌شود (Hidasi et al, 2016). در این سناریو، فرض بر این است که تصمیمات کاربران تحت تأثیر تعاملات اخیر آن‌ها قرار دارد و مدل باید بتواند این وابستگی‌ها را یاد بگیرد.

برای نزدیک‌تر شدن داده‌های شبیه‌سازی شده به شرایط واقعی، ویژگی پراکندگی داده‌ها در فرآیند تولید داده لحاظ شده است. در بسیاری از سامانه‌های توصیه‌گر، تنها بخش کوچکی از اقلام توسط هر کاربر مورد تعامل قرار می‌گیرد و همین موضوع منجر به ماتریس‌های تعامل بسیار خلوت می‌شود (Zhang et al, 2019). داده‌های شبیه‌سازی شده این پژوهش نیز به گونه‌ای طراحی شده‌اند که این پراکندگی را منعکس کنند و در نتیجه، چارچوب پیشنهادی در شرایطی نزدیک به محیط‌های عملی ارزیابی شود.

علاوه بر تعاملات رفتاری، داده‌ها به صورت مفهومی شامل ویژگی‌های چندوجهی نیز در نظر گرفته شده‌اند. این ویژگی‌ها می‌توانند نمایانگر اطلاعات زمینه‌ای یا محتوایی اقلام باشند که در کنار تاریخچه تعامل کاربران مورد استفاده قرار می‌گیرند. مطالعات پیشین نشان داده‌اند که ترکیب سیگنال‌های رفتاری با داده‌های محتوایی، به بهبود درک ترجیحات کاربران و افزایش دقت پیش‌بینی منجر می‌شود (He and McAuley, 2016). در این پژوهش، داده‌های چندوجهی به صورت یکپارچه در فرآیند آموزش مدل لحاظ شده‌اند تا امکان تحلیل جامع‌تری از رفتار کاربران فراهم شود.

به منظور ارزیابی منصفانه عملکرد مدل، داده‌های شبیه‌سازی شده بر اساس ترتیب زمانی به مجموعه‌های آموزش و آزمون تقسیم شده‌اند. در این تقسیم‌بندی، تعاملات اولیه کاربران برای آموزش مدل و تعاملات متأخر برای ارزیابی مورد استفاده قرار گرفته‌اند. این شیوه تقسیم‌بندی که در پژوهش‌های متعددی توصیه شده است، از نشت اطلاعات آینده به فرآیند آموزش جلوگیری کرده و اعتبار نتایج را افزایش می‌دهد (Kang and McAuley, 2018).

معیارهای ارزیابی و روش اعتبارسنجی مدل پیشنهادی

ارزیابی عملکرد مدل‌های پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر، نیازمند استفاده از معیارهایی است که بتوانند کیفیت رتبه‌بندی و میزان انطباق پیشنهادها با ترجیحات واقعی کاربران را به درستی منعکس کنند. در پژوهش حاضر، با توجه به ماهیت ترتیبی و پیش‌بینی محور مسئله، از رویکردهای ارزیابی متداول در ادبیات سیستم‌های توصیه‌گر استفاده شده است تا امکان مقایسه نتایج با پژوهش‌های پیشین فراهم گردد (Ricci et al, 2015).

به منظور جلوگیری از نشت اطلاعات آینده و حفظ واقع‌گرایی فرآیند ارزیابی، داده‌ها بر اساس ترتیب زمانی تعاملات کاربران به مجموعه‌های آموزش و آزمون تقسیم شده‌اند. در این روش، بخش ابتدایی تاریخچه تعامل هر کاربر برای آموزش مدل و تعاملات متأخر برای ارزیابی مورد استفاده قرار گرفته است. این شیوه تقسیم‌بندی که در بسیاری از پژوهش‌های حوزه توصیه‌گرهای ترتیبی پیشنهاد شده است، شرایطی نزدیک به سناریوهای واقعی را شبیه‌سازی می‌کند که در آن مدل تنها به اطلاعات گذشته کاربران دسترسی دارد (Kang and McAuley, 2018). استفاده از تقسیم‌بندی زمانی، نسبت به تقسیم‌بندی تصادفی، اعتبار نتایج را افزایش می‌دهد و از خوش‌بینی کاذب در ارزیابی جلوگیری می‌کند.

با توجه به اینکه در بسیاری از کاربردهای عملی سیستم‌های توصیه‌گر، هدف اصلی ارائه فهرستی محدود از پیشنهادها به کاربر است،

در این پژوهش تمرکز بر معیارهای Top-K قرار گرفته است. این معیارها میزان موفقیت مدل در قرار دادن اقلام مرتبط در میان K پیشنهاد اول را اندازه‌گیری می‌کنند. پژوهش‌های پیشین نشان داده‌اند که این دسته از معیارها، ارزیابی واقع‌گرایانه‌تری از عملکرد سیستم‌های توصیه‌گر ارائه می‌دهند (He et al, 2017).

معیار دقت، نسبت اقلام مرتبط به کل اقلام پیشنهادی در فهرست Top-K را اندازه‌گیری می‌کند و بیانگر میزان صحت پیشنهادهای ارائه‌شده است. استفاده از این معیار نشان می‌دهد که چه سهمی از پیشنهادهای سیستم، واقعاً مورد توجه یا انتخاب کاربران قرار گرفته‌اند. این معیار به‌طور گسترده در ارزیابی سیستم‌های توصیه‌گر برای سنجش کیفیت پیشنهادهای مورد استفاده قرار می‌گیرد (Koren et al, 2009).

معیار بازخوانی، توانایی مدل در بازیابی اقلام مرتبط از میان کل اقلام بالقوه مورد علاقه کاربر را ارزیابی می‌کند. این معیار نشان می‌دهد که سیستم توصیه‌گر تا چه اندازه موفق بوده است در شناسایی ترجیحات واقعی کاربران و پوشش دادن آن‌ها در فهرست پیشنهادها. پژوهش‌های متعددی بر اهمیت استفاده همزمان از دقت و بازخوانی برای ارزیابی جامع‌تر مدل‌ها تأکید کرده‌اند (Zhang et al, 2019).

برای در نظر گرفتن موقعیت اقلام مرتبط در فهرست پیشنهادها، از معیار $NDCG@K$ استفاده شده است. این معیار علاوه بر مرتبط بودن اقلام، به جایگاه آن‌ها در فهرست رتبه‌بندی نیز توجه می‌کند و اقلامی که در رتبه‌های بالاتر قرار می‌گیرند، وزن بیشتری دریافت می‌کنند. استفاده از $NDCG$ در ارزیابی سیستم‌های توصیه‌گر ترتیبی، رویکردی رایج محسوب می‌شود و به درک دقیق‌تر کیفیت رتبه‌بندی کمک می‌کند (Sun et al, 2019).

به‌منظور تحلیل اثربخشی چارچوب پیشنهادی، نتایج حاصل از معیارهای فوق به‌صورت تحلیلی با نتایج گزارش‌شده برای روش‌های پایه در پژوهش‌های پیشین مقایسه شده‌اند. این مقایسه به‌گونه‌ای انجام شده است که شرایط ارزیابی تا حد امکان یکسان باشد و تفاوت‌های مشاهده‌شده به معماری و رویکرد مدل پیشنهادی نسبت داده شوند. انجام چنین مقایسه‌ای یکی از اصول اساسی در ارزیابی مدل‌های توصیه‌گر محسوب می‌شود و نقش مهمی در تفسیر نتایج ایفا می‌کند (Ricci et al, 2015).

یافته‌ها

در این بخش، نتایج حاصل از اجرای چارچوب پیشنهادی مبتنی بر یادگیری عمیق برای پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر چندوجهی ارائه و تحلیل می‌شود. به‌منظور ارزیابی دقیق عملکرد مدل، نتایج حاصل بر اساس معیارهای رایج ارزیابی سیستم‌های توصیه‌گر گزارش شده و با عملکرد روش‌های پایه مقایسه گردیده است. هدف از این تحلیل، بررسی میزان بهبود چارچوب پیشنهادی در شناسایی ترجیحات کاربران و ارتقای کیفیت توصیه‌ها است.

نتایج به‌دست‌آمده نشان می‌دهد که چارچوب پیشنهادی در تمامی معیارهای ارزیابی مورد استفاده، عملکرد بهتری نسبت به روش‌های پایه از خود نشان داده است. به‌ویژه در معیارهای مبتنی بر Top-K، مدل پیشنهادی توانسته است سهم بیشتری از اقلام مرتبط را در میان پیشنهادهای اولیه به کاربران ارائه دهد. این موضوع بیانگر توانایی بالاتر مدل در یادگیری الگوهای رفتاری پیچیده و وابستگی‌های زمانی کاربران است؛ مسئله‌ای که در پژوهش‌های پیشین نیز به‌عنوان یکی از مزایای اصلی مدل‌های یادگیری عمیق مطرح شده است (He et al, 2017).

بررسی معیارهای دقت و بازخوانی نشان می‌دهد که استفاده از چارچوب پیشنهادی منجر به افزایش قابل‌توجه هر دو معیار شده است. افزایش دقت بیانگر آن است که بخش بزرگ‌تری از پیشنهادهای ارائه‌شده، واقعاً با علایق کاربران هم‌خوانی داشته‌اند. از سوی دیگر، بهبود معیار بازخوانی نشان می‌دهد که مدل توانسته است تعداد بیشتری از اقلام مرتبط بالقوه را شناسایی و در فهرست پیشنهادها لحاظ کند. این نتایج با یافته‌های پژوهش‌هایی که بر اهمیت مدل‌سازی توالی رفتار کاربران تأکید دارند، هم‌راستا است.

(Hidasi et al, 2016; Kang and McAuley, 2018).

در ارزیابی کیفیت رتبه‌بندی، معیار $NDCG@K$ نشان می‌دهد که اقلام مرتبط، در موقعیت‌های بالاتری از فهرست پیشنهادها قرار گرفته‌اند. این موضوع از آن جهت حائز اهمیت است که در کاربردهای واقعی، کاربران معمولاً تنها به پیشنهاد‌های ابتدایی توجه می‌کنند. بهبود مقدار $NDCG$ بیانگر آن است که چارچوب پیشنهادی نه تنها اقلام مناسب‌تری را شناسایی کرده، بلکه آن‌ها را با ترتیب بهتری به کاربران ارائه داده است. این نتیجه با نتایج گزارش شده در مطالعات مبتنی بر مدل‌های ترتیبی و توجه‌محور همخوانی دارد (Sun et al, 2019).

یکی از یافته‌های مهم این پژوهش، تأثیر مثبت استفاده از داده‌های چندوجهی در فرآیند پیش‌بینی رفتار کاربران است. نتایج نشان می‌دهد زمانی که ویژگی‌های چندوجهی در کنار تاریخچه تعاملات کاربران مورد استفاده قرار می‌گیرند، دقت پیش‌بینی به‌طور محسوسی افزایش می‌یابد. این یافته مؤید نتایج پژوهش‌هایی است که استفاده از اطلاعات محتوایی را عاملی مؤثر در بهبود عملکرد سیستم‌های توصیه‌گر دانسته‌اند (He and McAuley, 2016; Zhang et al, 2019).

بررسی نتایج در سناریوهای مختلف نشان می‌دهد که چارچوب پیشنهادی از پایداری مناسبی در عملکرد برخوردار است و نسبت به تغییرات در الگوهای رفتاری کاربران حساسیت کمتری دارد. این ویژگی، بیانگر توانایی مدل در تعمیم به شرایط متنوع و نزدیک به محیط‌های واقعی سیستم‌های توصیه‌گر است. چنین پایداری‌ای، یکی از الزامات اصلی برای به‌کارگیری عملی مدل‌های پیش‌بینی رفتار کاربران محسوب می‌شود (Ricci et al, 2015).

بحث و نتیجه‌گیری

در این پژوهش، یک چارچوب هوشمند مبتنی بر یادگیری عمیق برای پیش‌بینی رفتار کاربران در سیستم‌های توصیه‌گر چندوجهی ارائه و ارزیابی شد. نتایج به‌دست‌آمده نشان داد که مدل پیشنهادی، در مقایسه با روش‌های پایه و رویکردهای سنتی، عملکرد بهتری در شناسایی ترجیحات کاربران و بهبود کیفیت توصیه‌ها از خود نشان می‌دهد. این یافته‌ها با نتایج پژوهش‌هایی که بر محدودیت‌های مدل‌های کلاسیک و ایستا در تحلیل رفتار کاربران تأکید کرده‌اند، هم‌راستا است (Koren et al, 2009). به‌ویژه، بهبود مشاهده‌شده در معیارهای مبتنی بر $Top-K$ بیانگر آن است که مدل پیشنهادی توانسته است الگوهای پیچیده‌تر رفتاری و وابستگی‌های زمانی را مؤثرتر از روش‌های پیشین مدل‌سازی کند؛ موضوعی که در مطالعات مرتبط با توصیه‌گرهای ترتیبی نیز گزارش شده است (Hidasi et al, 2016; Kang and McAuley, 2018).

همچنین، نتایج این پژوهش مؤید اهمیت استفاده از داده‌های چندوجهی در کنار تاریخچه تعاملات کاربران است. افزایش دقت و کیفیت رتبه‌بندی در مدل پیشنهادی، با یافته‌های پژوهش‌هایی که بر نقش داده‌های محتوایی و جانبی در ارتقای عملکرد سیستم‌های توصیه‌گر تأکید دارند، همخوانی دارد (He and McAuley, 2016; Zhang et al, 2019). در مقایسه با مدل‌هایی که تنها بر یک بعد از داده‌ها تمرکز دارند، چارچوب پیشنهادی با رویکردی جامع‌تر، توانسته است تصویر دقیق‌تری از رفتار کاربران ارائه دهد. این موضوع نشان می‌دهد که ترکیب تحلیل توالی رفتار و داده‌های چندوجهی، مسیر مؤثری برای توسعه سیستم‌های توصیه‌گر هوشمندتر در محیط‌های پویا محسوب می‌شود.

در جمع‌بندی می‌توان گفت چارچوب ارائه‌شده در این پژوهش، قابلیت مناسبی برای پیش‌بینی رفتار کاربران و بهبود سطح شخصی‌سازی در سیستم‌های توصیه‌گر دارد. استفاده از داده‌های شبیه‌سازی‌شده، اگرچه امکان کنترل بهتر شرایط آزمایش را فراهم کرده است، اما می‌تواند به‌عنوان یکی از محدودیت‌های پژوهش نیز در نظر گرفته شود. از این‌رو، پیشنهاد می‌شود در پژوهش‌های آینده، مدل پیشنهادی بر روی داده‌های واقعی و مقیاس‌بالاتر مورد ارزیابی قرار گیرد. همچنین بررسی تأثیر معماری‌های پیشرفته‌تر نظیر مدل‌های مبتنی بر توجه و Transformer، و گسترش چارچوب به سناریوهای زمینه‌محور، می‌تواند به بهبود بیشتر دقت

پیش‌بینی و کاربردپذیری مدل در سامانه‌های واقعی منجر شود. نتایج این پژوهش می‌تواند مبنایی برای توسعه نسل جدیدی از سیستم‌های توصیه‌گر هوشمند و تطبیقی در حوزه‌های مختلف کاربردی باشد.

منابع

- مهدوی، عبدالمحمد. (۱۳۸۹). **نظام آموزش کارکنان در عصر اطلاعات**. چاپ اول، تهران: انتشارات نظری.
- فقیهی، ابوالحسن، و موسوی‌کاشی، زهره. (۱۳۸۹). مدل سنجش بهره‌وری (اثربخشی و کارایی) در بخش خدمات دولتی ایران. *مجله مدیریت دولتی*، ۲(۴)، ۱۰۷-۱۲۶.
- نجمی‌نیا، رضا، و صالحی، محمدرضا. (۱۳۹۱). بررسی تأثیر سرمایه فکری در ایجاد مزیت رقابتی شرکت‌های بیمه استان اصفهان. *چهارمین کنفرانس بین‌المللی بازاریابی خدمات بانکی*، مرکز همایش‌های بین‌المللی صدا و سیما.
- فقیهی، ابوالحسن و موسوی کاشی، زهره، مدل سنجش بهره وری (اثربخشی و کارایی) در بخش خدمات دولتی ایران، *مجله مدیریت دولتی*، دوره دوم، شماره چهارم، بهار و تابستان ۱۳۸۹، ۱۰۷-۱۲۶.
- مهدوی، عبدالمحمد، ۱۳۸۹، **نظام آموزش کارکنان در عصر اطلاعات**، چاپ اول، تهران، انتشارات نظری.
- نجمی نیا، رضا، صالحی، محمدرضا، بررسی تاثیر سرمایه فکری در ایجاد مزیت رقابتی شرکتهای بیمه استان اصفهان، *چهارمین کنفرانس بین‌المللی بازاریابی خدمات بانکی در مرکز همایش‌های بین‌المللی صدا و سیما*، مهر ۱۳۹۱.
- Cheng, H. T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., ... Shah, H. (2016). **Wide & deep learning for recommender systems**. Proceedings of the 1st Workshop on Deep Learning for Recommender Systems.
- He, X., & McAuley, J. (2016). VBPR: **Visual Bayesian personalized ranking from implicit feedback**. Proceedings of the AAAI Conference on Artificial Intelligence, 30(1).
- He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T. S. (2017). **Neural collaborative filtering**. Proceedings of the 26th International World Wide Web Conference (WWW), 173-182.
- Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2016). **Session-based recommendations with recurrent neural networks**. International Conference on Learning Representations (ICLR).
- Kang, W. C., & McAuley, J. (2018). **Self-attentive sequential recommendation**. Proceedings of the IEEE International Conference on Data Mining (ICDM), 197-206.
- Koren, Y., Bell, R., & Volinsky, C. (2009). **Matrix factorization techniques for recommender systems**. Computer, 42(8), 30-37.
- Ricci, F., Rokach, L., & Shapira, B. (2015). **Recommender systems handbook**. Springer.
- Sun, F., Liu, J., Wu, J., Pei, C., Lin, X., Ou, W., & Jiang, P. (2019). BERT4Rec: **Sequential recommendation with bidirectional encoder representations from transformer**. Proceedings of the 28th ACM International Conference on Information and Knowledge Management (CIKM), 1441-1450.
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). **Deep learning based recommender system: A survey and new perspectives**. ACM Computing Surveys, 52(1), 1-38.