

کش شخصی در لبه شبکه: یک رویکرد مبتنی سیستم‌های توصیه‌گر

فرزاد مهرابی^{۱*} و سید امین حسینی سنو^۲

^۱دانشگاه فردوسی مشهد؛ farzad.mehrabi@hotmail.com

^۲دانشگاه فردوسی مشهد؛ hosseini@um.ac.ir

چکیده

با افزایش چشمگیر حجم داده‌های تولیدی توسط کاربران، نیاز به بهینه‌سازی شبکه به شدت احساس می‌شود. یکی از فناوری‌هایی که در سالیان همواره برای افزایش کارایی شبکه توسط محققان در حال توسعه بوده، فناوری کش است. رویکردهای سنتی کش با توجه به رشد بی‌سابقه شبکه و تنوع کاربران، دیگر کافی نیستند. پدیده کلان داده و نیاز به استخراج الگوهای قابل درک از حجم عظیم داده‌ها، فراهم‌آوری راهکارهای جدید را ضروری کرده‌است. این پژوهش راهکاری مبتنی بر یادگیری ماشین ارائه می‌دهد که به شناسایی دقیق‌تر درخواست‌های آینده کاربران با در نظر گرفتن الگوهای رفتاری و ترتیبی آنها می‌پردازد. روش پیشنهادی بر پایه سیستم‌های توصیه‌گر بوده که در نظرگیری ترجیحات شخصی هر کاربر را ممکن می‌سازد و با بهره‌گیری از شبکه‌های عصبی کانولوشن و مکانیزم توجه چندگانه، قادر است با استخراج الگوهای مختلف در رفتار کاربران محتوای محبوب کاربر را به صورت شخصی و بدون داشتن دانش قبلی از محتوای محبوب سراسری شناسایی کند. نتایج نشان می‌دهد که این روش به طور موفقیت‌آمیزی الگوهای ترتیبی و عمومی کاربران را درک می‌کند و نسبت به رویکردهای موجود دقیق‌تر بوده و عملکرد بهتری ارائه می‌دهد.

کلمات کلیدی: شبکه عصبی کانولوشن، یادگیری ماشین، الگوهای متوالی، کش شخصی، مکانیزم توجه

Personalized caching at the network edge: A recommender system based approach

Farzad Mehrabi^{۱*}, Seyed Amin Hosseini Seno^۲

^۱Ferdowsi University of Mashhad, Mashhad, Iran; farzad.mehrabi@hotmail.com

^۲Ferdowsi University of Mashhad, Mashhad, Iran; hosseini@um.ac.ir

Abstract

With the significant increase in the volume of data generated by users, there is a pressing need for network optimization. One of the technologies that has been continuously developed by researchers over the years to enhance network efficiency is caching technology. However, traditional caching approaches are no longer sufficient due to the unprecedented growth of the network and the diversity of users. The emergence of big data and the necessity to extract comprehensible patterns from massive data volumes have made it essential to develop new solutions. This research proposes a machine learning-based solution that more accurately predicts future user requests by considering their sequential behavioral patterns. The proposed method is based on recommender systems, allowing for the consideration of each user's personal preferences. Utilizing convolutional neural networks and multi-head attention mechanisms, it can identify the popular content for each user personally without prior knowledge of globally popular content by extracting various patterns in user behavior. The results demonstrate that this method successfully understands both sequential and general patterns in users behaviors, while being more accurate and providing better performance than existing approaches.

Keywords: convolutional neural networks, machine learning, sequential patterns, personalized caching, attention mechanism

۱- مقدمه

با پیشرفت‌های چشمگیر در تکنولوژی‌های هوشمند و ارتباطات بی‌سیم، شاهد رشد چشمگیر محتوای چندرسانه‌ای هستیم. فناوری‌های جدیدی مانند نسل پنجم شبکه‌های موبایل (۵G)، اینترنت اشیا (IoT) و اینترنت وسایل نقلیه (IoV) به ما کارکردهای تازه‌ای مثل واقعیت مجازی، واقعیت افزوده، ویدئو به هنگام و سیستم‌های هوشمند نظارت بر سلامت را ارائه داده‌اند. کارکردهای چندرسانه‌ای، ترافیک عظیمی را تولید می‌کنند که بر اساس گزارشات شرکت سیسکو، پیش‌بینی می‌شود ترافیک داده‌های موبایل از سال ۲۰۱۷ تا ۲۰۲۲، هفت برابر افزایش یافته و به ۷۷.۵ اگزابایت در ماه برسد [۱]. این افزایش قابل توجه در ترافیک موبایل، فشار زیادی را بر روی پیوندهای بک‌هال که اینترنت را به ایستگاه‌های پایه محلی متصل می‌کنند، وارد می‌کند و منجر به کاهش کیفیت سرویس برای کاربران می‌شود. ترافیک سنگین ناشی از این فناوری‌های جدید و برنامه‌های کاربردی به پهنای باند بیشتری نیاز دارد و برای حفظ کیفیت سرویس شبکه، باید تغییرات زیادی در شبکه حاضر ایجاد شود، که یک چالش بزرگ برای شبکه‌های بی‌سیم سنتی به شمار می‌رود.

کش محتوا در لبه شبکه به عنوان یک فناوری امید بخش مورد مطالعه قرار گرفته است، فناوری نوینی که با افزودن قابلیت‌های پردازشی و حافظه به لبه شبکه، می‌تواند به پاسخگویی در برابر افزایش چشمگیر ترافیک و تامین انتظارات دقیق برنامه‌ها کمک کند [۲، ۳، ۴]. این استراتژی، لبه شبکه را به سرورهایی

مجهز می‌سازد تا محتوایی که احتمالاً به طور مکرر توسط کاربران درخواست می‌شود، ذخیره‌سازی کنند. این امکان به کاربران اجازه می‌دهد که به جای استفاده از سرورهای دور دست در ابر، مستقیماً محتوا را از سرورهای لبه بگیرند. این رویکرد می‌تواند تأخیر در دسترسی به محتوای درخواستی و بار ترافیکی شبکه را به طور قابل توجهی کاهش دهد. استفاده از حافظه کش در لبه شبکه به نام کش لبه شناخته می‌شود [۵].

کش در شبکه‌های گوناگون به اجرا درآمده است [۶, ۷]، به ویژه در نسل پنجم تلفن‌های همراه، امکان ذخیره‌سازی محتوای پرطرفدار در ایستگاه‌های پایه خاصی مانند ایستگاه‌های پایه کوچک یا ایستگاه‌های پایه بزرگ وجود دارد. همچنین، در شبکه خودروپی، می‌توان محتوا را در واحدهای کنار جاده و در خود وسایل نقلیه نگهداری کرد. با این حال، با توجه به محدودیت ظرفیت حافظه کش در لبه شبکه، طراحی یک استراتژی کش مناسب برای استفاده بهینه از این فضای محدود امری ضروری است. استراتژی‌های کش موجود عموماً به دو دسته واکنشی و پیشگیرانه تقسیم می‌شوند [۸, ۵]. استراتژی واکنشی با استفاده از الگوهای درخواست کاربران برای انتخاب محتوای مناسب برای ذخیره در حافظه عمل می‌کند، یعنی عمل کش پس از درخواست محتوا توسط کاربر صورت می‌پذیرد، در حالی که استراتژی پیشگیرانه از تحلیل سابقه درخواست‌ها، الگوهای دسترسی، اطلاعات اجتماعی و جغرافیایی برای پیش‌بینی محبوبیت محتوا قبل از رسیدن درخواست‌ها بهره می‌برد [۹, ۱۰]. اخیراً و با پیشرفت‌های چشمگیر در حوزه یادگیری ماشین، رویکردهایی مانند یادگیری تقویتی، یادگیری انتقالی و یادگیری مشارکتی به طور گسترده برای پیش‌بینی محبوبیت محتوا در استراتژی‌های پیشگیرانه به کار گرفته شده‌اند. این رویکردهای جدید به دلیل توانایی بالایشان در کنترل حجم عظیم داده‌ها و شناسایی دقیق الگوها از داده‌های پیچیده، مورد استفاده قرار گرفته‌اند [۱۱, ۱۲, ۱۳].

کش همواره به عنوان راهکاری برای بهبود عملکرد شبکه مورد مطالعه و تحقیق بوده اما علی‌رغم پژوهش‌های فراوانی که تا کنون برای حل چالش‌های این حوزه انجام شده، همچنان محدودیت‌هایی باقی مانده‌اند که فرصت‌های ارزشمندی را برای مطالعه بیشتر فراهم می‌کنند. پژوهش حاضر دو نقص در ادبیات موجود را شناسایی کرده که بسیاری از مدل‌های کش با آن روبرو هستند. نخست، این مدل‌ها معمولاً بدون در نظر گرفتن ترتیب و رفتار متوالی کاربران کار می‌کنند، در حالی که درک ترتیب و پیشرفت تعاملات کاربر در زمان می‌تواند درکی عمیق‌تر از علائق فعلی و آینده آنها فراهم کند. این امر در موقعیت‌هایی که ارتباط یک محتوا به فعالیت‌های اخیر کاربران وابسته است، اهمیت بیشتری می‌یابد. ادغام این رفتار متوالی می‌تواند به روش‌های پیشنهادی اجازه دهد تا محتوای بعدی که کاربر احتمالاً با آن تعامل خواهد داشت را دقیق‌تر پیش‌بینی کنند [۱۴]. دوم، بسیاری از مطالعات بر این فرض استوار هستند که توزیع ترجیحات کاربران یکنواخت است [۱۵]. این دسته از تحقیقات به ندرت ترجیحات شخصی کاربران را هنگام برآورد محبوبیت محتوا در نظر می‌گیرند، که نشان دهنده کاستی قابل توجه در استراتژی‌های کش محتوای فعلی است و به کاهش کارایی کش منجر می‌شود. اخیراً، برخی پژوهش‌ها شروع به در نظر گرفتن ترجیحات کاربر در تحلیل‌های خود کرده‌اند و نشان می‌دهند این اطلاعات در طراحی استراتژی‌های کش محتوا مفید هستند [۱۶, ۱۷]. علاوه بر این، ماهیت پویای درخواست‌های کاربر به این معناست که محبوبیت محتوا مدام در حال تغییر است و محبوبیت یک محتوای خاص برای یک کاربر در زمان‌های مختلف متفاوت است. بنا به دلایل عنوان شده، پژوهش‌هایی که بر درک الگوهای توالی و ترجیحات شخصی کاربران متمرکز نیستند، با چالش درک درست تغییرات و ترجیحات پویای کاربران روبرو هستند که می‌تواند به کاهش کیفیت محتوای کش شده منجر شود. همچنین، اگرچه تمرکز زیادی بر استفاده از الگوریتم‌های یادگیری تقویتی عمیق شده است [۱۸, ۹]، این رویکردها به دلیل پیچیدگی بالا و نیاز به منابع محاسباتی گسترده، برای استفاده در گره‌های لبه با منابع محدود کمتر مناسب هستند [۱۹]. این موضوع، به ویژه مشکلاتی را در پیاده‌سازی مدل‌ها در محیط‌هایی با منابع محدود به وجود می‌آورد و نشان می‌دهد که نیاز به راهکارهای جدیدی است که قادر به کاهش پیچیدگی محاسباتی باشد.

با توجه به پیچیدگی‌های فزاینده در شبکه و افزایش محتوای چندرسانه‌ای، مدل‌های کش سنتی دیگر نمی‌توانند پاسخگوی نیازهای مداوم باشند [۴, ۸]. اما رشد فناوری‌های یادگیری ماشین فرصت‌های جدیدی را برای بهبود این مدل‌ها فراهم آورده است. مقالات اخیر تمایل دارند که از تکنیک‌های یادگیری ماشین، به ویژه یادگیری تقویتی عمیق، برای حل چالش‌های مرتبط با کش محتوا استفاده کنند، که در نتیجه بسیاری از این مطالعات با سربار محاسباتی بالا در لبه شبکه مواجه هستند [۹, ۱۳, ۱۹]. همچنین این مطالعات به ندرت به طور مستقیم به موضوع رفتارهای توالی‌مند کاربران پرداخته‌اند. پژوهش حاضر سعی دارد تا با ارائه روشی جدید و سبک وزن که قادر به شناسایی ترجیحات شخصی و ترتیبی کاربران است، این خلاء را پر کند و چالش‌های موجود را برطرف سازد. دستاوردهای این تحقیق را می‌توان به شرح زیر بیان کرد:

- ارائه روشی پیشرفته برای کش پیشگیرانه که بر پایه مدل یادگیری عمیق معرفی شده در مطالعه [۱۴] استوار است.
- در تضاد با بسیاری از تحقیقات که محبوبیت محتوا را به شکل سراسری بررسی می‌کنند، روش پیشنهادی به دنبال شناسایی محبوبیت محتوا به طور شخصی است، این رویکرد از ویژگی‌های سیستم‌های توصیه‌گر برای انجام تجزیه و تحلیل دقیق بر روی هر کاربر بهره می‌برد و به بررسی الگوهای کلی و تمایلات فردی کاربران می‌پردازد.
- به منظور شناسایی انواع روابط ترتیبی در توالی‌ها، با الهام از مدل ترانسفورمر در پردازش زبان طبیعی، این روش از مکانیزم توجه چندگانه برای تشخیص الگوهای ترتیبی استفاده می‌کند. علاوه بر این، برای شناسایی الگوهای ترتیبی و روابط کلی بین درخواست‌ها، از فیلترهای کانولوشن افقی بهره گرفته می‌شود.
- رویکردی مبتنی بر جلسه اتخاذ شده است. به این معنا که شناسایی محتوای محبوب شخصی بر اساس یک بازه زمانی مشخص از درخواست‌ها انجام می‌گیرد.

در ادامه، به بررسی کارهای موجود در زمینه مورد پژوهش خواهیم پرداخت، سپس در بخش ۳ روش پیشنهادی ارائه شده و ارزیابی می‌شود. در نهایت در بخش ۴ نتایج حاصل شرح داده می‌شود.

۲- مرور ادبیات

در این بخش به بررسی ادبیات موجود پرداختیم، کارهای مرتبط را می‌توان بر اساس در نظرگیری ترجیحات کاربران به دو دسته مقالات با در نظرگیری محتوای محبوب شخصی و مقالات با در نظرگیری محبوبیت سراسری دسته‌بندی کرد.

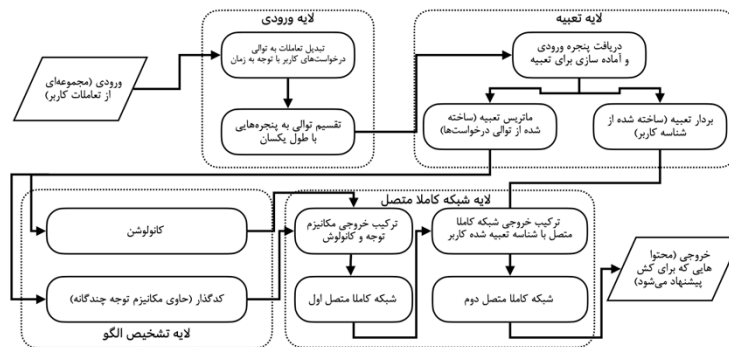
۲-۱- مقالات با در نظرگیری محتوای محبوب شخصی

یاسر و همکارانش [۱۶] چارچوب نوآورانه‌ای برای ذخیره‌سازی محتوا در محیط محاسبات لبه‌ای موبایل (MEC) معرفی کردند. اصلی‌ترین چالشی که نویسندگان به آن پرداختند، ذخیره‌سازی مؤثر محتوا با در نظر گرفتن هم محبوبیت محتوا و هم ترجیحات کاربران است. استراتژی‌های سنتی ذخیره‌سازی محتوا عمدتاً بر بهبود نرخ اصابت در کش متمرکز هستند اما اغلب ترجیحات کاربران را که برای ارتقاء کیفیت تجربه (QoE) و کارایی تحویل محتوا حیاتی هستند، نادیده می‌گیرند. برای پر کردن این شکاف، نویسندگان مدل CoPUP را پیشنهاد می‌کنند، طرحی که از روش پالایش گروهی مبتنی بر محتوا و شبکه عصبی کانولوشنی برای پیش‌بینی ترجیحات کاربران و محبوبیت محتوا استفاده می‌کند. این چارچوب به منظور بهبود قابل توجه عملکرد کش با افزایش نسبت بازدید کش و کاهش زمان پاسخگویی طراحی شده است. ارزیابی روش پیشنهادی از طریق شبیه‌سازی بر اساس داده‌های واقعی از MovieLens و مقایسه عملکرد CoPUP با سه تکنیک سنتی کمترین استفاده شده، کمترین اخیراً استفاده شده، FIFO و مقالات مرتبط صورت پذیرفته است. نتایج نشان می‌دهد که CoPUP نسب اصابت کش بالاتر و زمان پاسخگویی سریع‌تری را به دست آورده و اثربخشی در نظرگیری ترجیحات کاربران در استراتژی‌های ذخیره‌سازی محتوا در محیط‌های MEC را تأیید می‌کند. لی و همکارانش [۱۵] به بررسی طراحی سیاست‌های کش در شبکه‌های بی‌سیم دستگاه به دستگاه (D2D) می‌پردازند. در این پژوهش تمرکز بر چگونگی تأثیر ترجیحات فردی کاربران بر افزایش کارایی و بهره‌وری شبکه است. رویکردهای سنتی ذخیره‌سازی فرض می‌کنند که محبوبیت محتوا در بین همه کاربران یکسان است، اما این مقاله سناریوی واقعی را که در آن ترجیحات کاربران متفاوت است، برجسته می‌کند. با ادغام اطلاعات در مورد ترجیحات فردی در طراحی سیاست ذخیره‌سازی، این مطالعه نشان می‌دهد که شبکه‌ها می‌توانند بهبودهایی در پهنای باند، کارایی انرژی، هزینه و بهینه‌سازی نرخ بازخورد داشته باشند. پژوهشگران مسئله بهینه‌سازی سودمندی را فرموله می‌کنند که توزیع کاربر و اثرات محوشدگی کانال را در بر می‌گیرد و راه‌حلی ارائه می‌دهد که هم سیاست‌های کش شخصی و هم منفعت شبکه را در نظر می‌گیرد. در نهایت پس از ارزیابی رویکرد آنها نشان می‌دهد که پذیرش تفاوت‌های موجود در ترجیحات کاربران در طراحی کش اجازه می‌دهد تا بهبودهای قابل توجهی در عملکرد شبکه‌های D2D ایجاد شود. گوان و همکاران [۲۰]، یک سیاست ذخیره‌سازی لبه‌ای نوآورانه برای توزیع ویدئو برای شبکه‌های سلولی نسل پنجم و چهارم را معرفی کردند. استراتژی‌های کش سنتی با محدودیت‌های حجم کش در لبه شبکه و الگوهای درخواست نامنظم دست و پنجه نرم می‌کنند که منجر به عملکرد غیر بهینه می‌شود. روش پیشنهادی با یادگیری ترجیحات ویدئویی کاربران به صورت زنده، به چالش‌ها پاسخ می‌دهد و امکان تصمیم‌گیری هوشمندانه‌تری برای پذیرش محتوا در کش را فراهم می‌آورد. این روش به طور نوآورانه اطلاعات مرتبط با ترجیحات را بدون نیاز به ایجاد تغییرات ساختاری در سمت مشتری یا ارائه‌دهنده جمع‌آوری می‌کند. این شیوه از یک ساختار درختی برای یادگیری مؤثر ترجیحات استفاده می‌کند، و از روش کاوش و بهره‌برداری برای پذیرش پویا در کش بهره می‌گیرد. نتایج آزمایش‌ها نشان می‌دهند که در مقایسه با کارهای موجود روش پیشنهادی نرخ اصابت را تا ۱۲ درصد بهبود می‌بخشد در حالی که سربار حافظه و پردازنده مرکزی را به ترتیب تا ۹۲٪ و ۹۸٪ کاهش می‌دهد. ژانگ و همکاران [۲۱] برای حل چالش‌های فعلی در کش محتوا در لبه شبکه، روشی را معرفی کردند، که از تکنیک‌های یادگیری عمیق استفاده می‌کند. آنها یک استراتژی پیشگیرانه ذخیره محتوای آگاه از توالی را پیشنهاد می‌کنند که شامل دو بخش مدل‌های PSAC-gen و PSAC-seq است. مدل اول برای کش محتوای عمومی ساخته شده، و مبتنی بر شبکه‌های عصبی کانولوشن و مکانیزم توجه است. چارچوب PSAC-gen شامل ورودی، تعبیه، ثبت الگو و یک لایه کاملاً متصل است. مدل دوم برای محتوای متوالی مبتنی بر شبکه‌های عصبی عمیق و مکانیزم توجه است. چارچوب PSAC-seq شامل ورودی، لایه غیرخطی و لایه توجه به خود است. نتایج ارزیابی نشان می‌دهد که روش‌های پیشنهادی بار ترافیک شبکه، کیفیت تجربه و مصرف منابع را بهبود می‌بخشد.

۲-۲- مقالات با در نظرگیری محتوای محبوب سراسری

ژانگ و همکارانش [۱۸] روشی نوینی برای پایین آوردن تأخیر در انتقال داده‌ها و کم کردن هزینه‌های مربوط به جایگزینی محتوای کش در بلند مدت درون شبکه‌های سلولی دارای دو لایه ارائه داده‌اند. این مدل از کدگذاری کش برای فرستادن بخش‌های متفاوت یک فایل به نقاط مختلف شبکه استفاده می‌کند تا از نیاز به استفاده از حافظه‌های کش بزرگ پیشگیری کند. این روش ابتدا به بررسی تاریخچه درخواست‌های کاربران برای پیش‌بینی نیازهای آینده آنها می‌پردازد و پس از آن، از یک مدل مبتنی بر SDDPG برای حل مسئله کدگذاری کش استفاده می‌کند. به منظور افزایش سرعت یادگیری، از یادگیری با نظارت برای پیش آموزش شبکه‌های عصبی بهره گرفته می‌شود. تحقیقات نشان داده‌اند که راهکار مورد نظر در کاهش هزینه‌های کلی شبکه برای مدت طولانی مؤثر است، حتی اگر کارایی آن در مقایسه با حالاتی که تعداد درخواست‌ها از پیش معلوم است، کمی کاهش یابد. پژوهشگران مقاله [۲۲]، به روز

رسانی کش در ایستگاه‌های پایه را بدون اطلاعات قبلی درباره محبوبیت محتوا بررسی کرده‌اند. آنها این چالش را به صورت یک فرآیند تصمیم‌گیری مارکوف مدل‌سازی کرده‌اند، به طوری که وضعیت‌های کش در ایستگاه پایه و درخواست‌های کاربر به عنوان فضاهای حالت و تصمیمات مربوط به نگهداری یا تغییر محتوا به عنوان فضاهای عمل در نظر گرفته شده‌اند. در این مدل، از یک شبکه LSTM به همراه یک الگوریتم توسعه یافته بر اساس EMRQN به منظور بهبود نرخ پاسخ‌گویی استفاده شده است. بررسی‌ها و مقایسه نهایی نتایج با روش‌های سنتی کش مانند FIFO، LRU و همچنین با دیگر مطالعات نشان داد که مدل مبتنی بر EMRQN به طور قابل توجهی عملکرد بهتری دارد. ژونگ و همکاران [۲۳] با هدف افزایش دقت پاسخ‌گویی و بهینه‌سازی توزیع بار داده، روشی نوین در حوزه یادگیری تقویتی عمیق ارائه داده‌اند که بر پایه الگوریتم DDPG و سیاست Wolpertinger استوار است. این رویکرد از سه قسمت کلیدی تشکیل شده است: اولین قسمت، تابع بازیگر است که وضعیت کش و درخواست‌های محتوا را به عنوان ورودی دریافت می‌کند و مجموعه‌ای از اقدامات مجاز را تعیین می‌کند. دومین بخش، از الگوریتم نزدیک‌ترین همسایه استفاده می‌کند تا تعداد اقدامات مجاز شناسایی شده توسط بازیگر اولیه را گسترش دهد، سومین و آخرین بخش، تابع منتقد است که اقدامات بازیگر را بر اساس ارزش کیو بهینه‌سازی می‌کند، به گونه‌ای که اقدام با بیشترین ارزش کیو انتخاب شود. ارزیابی عملکرد این روش نشان داده است که نسبت به روش‌های سنتی مانند LRU، LFU و FIFO می‌تواند نرخ پاسخ‌گویی را در کوتاه مدت بهبود بخشد و در طولانی مدت از نوسان در نرخ پاسخ‌گویی جلوگیری کند. در تحقیق ارائه شده توسط دای [۱۳]، تاکید شده است که کش لبه در زمینه اینترنت وسایل نقلیه نقش بسیار مهمی در بهینه‌سازی پردازش درخواست‌ها و کاهش فشار بر پیوندهای بک‌هال ایفا می‌کند. این پژوهش با در نظر گرفتن تغییرپذیری محبوبیت محتوا در زمان، به دنبال ارائه یک رویکرد تعاونی برای پیش‌بینی محتوای محبوب است. برای این منظور، یک روند سه مرحله‌ای پیشنهاد شده است: در ابتدا، وسایل نقلیه با استفاده از الگوریتم K-means به خوشه‌ها تقسیم می‌شوند تا توزیع و درخواست محتوا ساده‌تر شود؛ سپس، با استفاده از تاریخچه‌ی درخواست‌های کاربران و از طریق LSTM، پیش‌بینی درخواست‌های محتوا انجام می‌گیرد. در گام نهایی، از یادگیری تقویتی برای تعیین بهترین سیاست تصمیم‌گیری استفاده می‌شود، هرچند که تاثیر تحرک کاربران بر سیاست تصمیم‌گیری به طور کامل مورد بررسی قرار نگرفته است. بر اساس نتایج ارزیابی، مدل معرفی شده در مقایسه با روش‌های LRU و LFU به ترتیب تاخیر را ۱۰ و ۸ درصد کاهش داده و نرخ اصابت را به ترتیب ۷ و ۵ درصد افزایش داده است.



شکل ۱- نمای کلی از روش پیشنهادی این روش مبتنی بر [۱۴] بوده و از مکانیزم توجه چندگانه [۲۴] برای استخراج ویژگی استفاده می‌کند.

۳- روش پیشنهادی

در این بخش ابتدا به معرفی ساختار روش پیشنهادی پرداخته شده است، سپس در بخش‌های بعدی محیط شبیه سازی و پارامترهای آموزش و مجموعه داده به کار رفته شرح داده شده، و معیارهای ارزیابی را معرفی می‌کنیم. در نهایت بررسی عملکرد روش با استفاده از معیارهای یاد شده و مقایسه با کارهای مرتبط صورت می‌پذیرد.

۳-۱- ساختار روش پیشنهادی

برای غلبه بر محدودیت‌های مشاهده شده در پژوهش‌های پیشین، ما یک روش جدید بر پایه یادگیری عمیق را پیشنهاد می‌کنیم که به طور خاص، این روش نسخه‌ای بهبودیافته از مدل Caser است که در پژوهش [۱۴] معرفی شده است. روش پیشنهادی ترکیبی از شبکه‌های عصبی پیچشی و همچنین مکانیزم توجه چندگانه [۲۴] را به کار می‌گیرد. این روش همانند یک سیستم توصیه‌گر عمل می‌کند و هدف آن انتخاب N مورد محتوای برجسته‌ای است که احتمال تقاضای آن توسط کاربر بیشتر است. در این روش، ابتدا داده‌های ورودی به شکل یک ماتریس درآمده و به عنوان یک تصویر در نظر گرفته می‌شود. پس از آن، الگوهای ترتیبی و عمومی به عنوان ویژگی‌های محلی این تصویر از طریق استفاده از فیلترهای کانولوشنی مختلف و مکانیزم توجه استخراج می‌شوند. روش پیشنهادی ما، که در شکل ۱ نمایش داده شده است، شامل چهار بخش اصلی لایه ورودی، لایه تعبیه، لایه تشخیص الگو و شبکه عصبی کاملاً متصل است. در ادامه، توضیحات بیشتری درباره این روش ارائه خواهیم داد، ضمناً باید تاکید کنیم که نوآوری این تحقیق، در لایه تشخیص الگو نهفته است، در حالی که لایه‌های تعبیه و ورودی بدون تغییر از مقاله پایه [۲۴] آورده شده‌اند.

لایه ورودی: برای به کارگیری داده‌ها در چارچوب مدل، ضروری است که ورودی‌ها را به نحوی آماده سازیم تا با ساختار آن همخوانی داشته باشند. در این رویکرد، اولین قدم تفکیک کاربران و محتوای مورد درخواست آنها به دسته‌های مجزا است. در مرحله بعد، دنباله‌های درخواستی محتوا توسط هر کاربر به شکل مجموعه‌ای منظم و بر اساس ترتیب زمانی ذخیره می‌شود. بعد از تعریف دنباله‌های محتوای درخواست شده توسط کاربر در گذشته، L مورد محتوا از این دنباله برای پیش‌بینی T مورد بعدی در نظر گرفته می‌شود. این عملیات با جابجایی یک پنجره به اندازه $L + T$ روی دنباله صورت می‌گیرد، که در هر بار جابجایی، یک نمونه آموزشی جدید برای کاربر ایجاد می‌شود.

لایه تعبیه: این لایه به نگاشت هر کاربر و قطعات محتوای مختلف به فضای برداری مرتبط می‌پردازد تا بردارهای متراکمی با d بعد به دست آید. هر قطعه از محتوا توسط یک بردار متراکم با d بعد نمایانگر می‌شود. سپس، L قطعه محتوا گردهم آورده می‌شوند تا یک ماتریس یا تصویر تشکیل دهند.

لایه تشخیص الگوها: این لایه در مقاله پایه شامل دو قسمت کانولوشن افقی و عمودی است [۱۴] اما با وجود اینکه CNNها به توانایی بالا در تشخیص ویژگی‌های محلی شناخته شده‌اند، مدل‌های دیگری برای شناسایی روابط ترتیبی وجود دارند که کارآمدتر هستند. در روش پیشنهادی ما، لایه افقی موجود در مقاله پایه حفظ شده و لایه کانولوشن عمودی را با یک مکانیزم توجه چندگانه جایگزین کرده‌ایم، این مکانیزم که خود بخشی از معماری ترانسفورمر است، به ویژه در پردازش زبان طبیعی و تجزیه و تحلیل الگوهای توالی کاربرد فراوان دارد، همچنین کارایی آن در LLMها برای محققین کاملاً مشهود است. توضیحات بیشتر در مورد نحوه پیاده‌سازی لایه‌های کانولوشن افقی و مکانیزم توجه چندگانه در ادامه، با استناد به مقالات پایه ارائه خواهد شد.

لایه کانولوشن افقی: مقاله پایه با الهام ایده استفاده از CNN در طبقه‌بندی متن [۲۵]، ورودی‌ها را از طریق یک لایه تعبیه به صورت تصویری از درخواست‌های متوالی کاربر تبدیل می‌کند. این رویکرد به مدل امکان می‌دهد تا با ورودی‌ها همانند با یک تصویر رفتار کند، به این صورت که فیلترهای کانولوشنی می‌توانند با حرکت بر سطح تصویر، ویژگی‌های محلی آن را شناسایی و استخراج کنند. در این لایه، چندین فیلتر کانولوشنی افقی با ارتفاع‌های متنوع تعبیه شده است. این فیلترها از بالا به پایین بر سطوح ماتریس ورودی حرکت کرده، با تمام ابعاد افقی تعامل نموده و فرآیند کانولوشن را اجرا می‌کنند. سپس، یک تابع فعال‌ساز بر روی نتایج حاصل از کانولوشن اعمال می‌گردد. در مرحله بعدی، تکنیک حداکثر تجمع به کار گرفته می‌شود تا از میان تمام مقادیر به دست آمده، بیشترین مقدار استخراج شود. در واقع فرآیند حداکثر تجمع، بارزترین ویژگی استخراج شده توسط فیلتر را ضبط می‌کند و آن را به عنوان خروجی ارائه می‌دهد. (برای اثبات روابط موجود بین قسمت‌های مختلف به مقاله پایه [۱۴] مراجعه شود).

لایه توجه چندگانه: مکانیزم توجه چندگانه [۲۴]، که به عنوان بخشی اصلی از معماری ترانسفورمرها شناخته می‌شود، از زمان معرفی‌اش نه تنها در زمینه پردازش زبان طبیعی بلکه تقریباً در هر حوزه‌ای که نیاز به درک روابط ترتیبی دارد، مورد اهمیت است. این مکانیزم به مدل امکان می‌دهد تا به طور همزمان به قسمت‌های مختلف یک دنباله ورودی توجه کند و وابستگی‌های پیچیده را به صورت موازی درک کند. استفاده از چند سر در این مکانیزم، توانایی مدل را در تشخیص انواع مختلف روابط بین ورودی‌ها افزایش می‌دهد. در مدل ارائه شده، ابتدا یک رابطه خطی ساده بر روی دنباله‌های موجود در ماتریسی که از لایه تعبیه به دست آمده‌اند، اعمال می‌شود. سپس، مکانیزم توجه چندگانه پیاده‌سازی می‌شود و در نهایت، نتایج به یک شبکه پیش‌خور با فعال‌ساز Relu فرستاده می‌شوند (برای مطالعه بیشتر به [۲۴] مراجعه شود).

لایه شبکه متصل قوی: در این بخش خروجی‌های دو بخش کانولوشن و توجه چندگانه را با هم ترکیب می‌کنیم و آن‌ها را به عنوان ورودی به یک لایه شبکه عصبی کاملاً متصل می‌دهیم تا ویژگی‌های بالاتر و انتزاعی‌تری به دست آوریم، در نهایت خروجی این لایه انواع ویژگی‌هایی است که از L محتوای قبلی استخراج می‌شود. همچنین برای تشخیص ترجیحات کلی کاربر، از بردار تعبیه کاربر استفاده کرده و با خروجی لایه قبل با هم ترکیب می‌کنیم و آن‌ها را به یک لایه خروجی نسبت می‌دهیم. خروجی این قسمت احتمال درخواست هر محتوا توسط کاربر است.

۲-۳- شبیه‌سازی و آموزش

تابع هزینه: به عنوان تابع هزینه از تابع معرفی شده در مقاله پایه استفاده می‌شود [۱۴]، فرمول کلی این تابع به صورت زیر می‌باشد (در صورت نیاز به اثبات کلی تابع، به مقاله پایه مراجعه گردد):

$$loss = \sum_u \sum_{t \in step_u} \sum_{i \in D_t^u} -\log(\sigma(y_i^{(u,t)})) + \sum_{j \neq i} -\log(1 - \sigma(y_j^{(u,t)})) \quad (1)$$

در فرمول بالا نماد σ نشانگر تابع سیگموید $\sigma(x) = \frac{1}{1+e^{-x}}$ بوده، $step^u$ مجموعه‌ای از گام‌های زمانی است که می‌خواهیم برای کاربر u پیش‌بینی کنیم و D_t^u مجموعه T محتوای هدفی است که می‌خواهیم پیش‌بینی نماییم و همچنین $y_j^{(u,t)}$ نشانگر خروجی شبکه متصل قوی است که امتیاز هر محتوا را نشان می‌دهد.

تنظیم فرآیند آموزش: برای شبیه‌سازی هر مدل، ابتدا ضروری بود تا فرآیندها را به درستی تنظیم کنیم. در این راستا، ما از روش جستجوی شبکه‌ای استفاده کردیم تا با کمک داده‌های اعتبارسنجی، بهترین تنظیمات برای فرآیندها را بیابیم. برخی از این فرآیندها و مقادیری که برای آن‌ها آزمایش شده، در جدول ۱ نمایش داده شده‌اند.

جدول ۱- فرآیندها و مقادیر آزموده شده برای آن در روش پیشنهادی

مقدار برگزیده شده	مقادیر آزموده شده	فرآیندها
۵۰	۵, ۱۰, ۲۰, ۳۰, ۵۰, ۱۰۰	ابعاد در لایه تعبیه
۰.۰۰۰۰۰۱	۰.۰۰۰۰۰۱ - ۰.۰۰۱	تنظیم L ₂
۰.۰۰۰۰۳	۰.۰۰۰۰۱ - ۱	نرخ یادگیری
۵	۱-۹	درجه مارکوف L
۱۶	۴, ۸, ۱۶, ۳۲, ۶۴	تعداد فیلترهای افقی
۳	۱, ۲, ۳	تعداد هدف T
Relu	Tanh, Sigmoid, Relu	توابع فعال‌سازی
۴	۱, ۲, ۳, ۴, ۵, ۶, ۷	تعداد سرها در توجه چندگانه

آموزش: پارامترهای مدل (θ) با کمینه‌سازی تابع هدف در فاز آموزش بهینه می‌شوند. برای افزایش سرعت همگرایی، از یک روش بهینه‌سازی مبتنی بر گرادینت تصادفی به نام Adam، با اندازه بسته ۱۲۸ استفاده می‌کنیم. علاوه بر این، برای جلوگیری از پیچیدگی بیش از حد مدل و مقابله با بیش‌برازش، دو استراتژی تنظیم را به کار می‌بریم: ابتدا، تنظیم L₂ که بر تمام پارامترهای مدل اعمال می‌شود و دوم، استفاده از تکنیک Dropout با نسبت حذف ۵۰ درصد که بر روی لایه‌های کاملاً متصل اعمال می‌گردد. مدل با استفاده از Python نسخه ۳.۱۰.۱۲ و کتابخانه‌های PyTorch نسخه ۲.۰، Pandas نسخه ۱.۵.۳، NumPy نسخه ۱.۲۳.۵ و SciPy نسخه ۱.۸ پیاده‌سازی شده است. در نهایت، آموزش مدل بر روی یک CPU هسته‌ای Intel-i5@13400F با ۱۶ گیگابایت RAM انجام گرفته است.

مجموعه داده‌های مورد استفاده: توسعه یک مدل که بر الگوهای ترتیبی متمرکز است، فقط در صورتی ارزشمند خواهد بود که مجموعه داده مورد استفاده شامل الگوهای ترتیبی معناداری باشد. در این راستا، مقاله [۱۴] با بررسی و کاوش قوانین ارتباطی ترتیبی بر روی چند مجموعه داده عمومی، شدت ترتیبی بودن داده‌ها را با استفاده از پارامتری به نام SI محاسبه کرده و از این معیار برای ارزیابی میزان سیگنال‌های ترتیبی در مجموعه داده‌ها بهره برده است. در پژوهش حاضر نیز، با الهام از تحقیق انجام شده در مقاله مذکور، از شدت ترتیبی بودن دو مجموعه داده معتبر MovieLens و Gowalla استفاده شده است و سپس عمل آموزش و ارزیابی مدل بر روی این دو مجموعه داده صورت پذیرفته است. جزئیات عمومی این دو مجموعه داده در جدول ۲ ارائه شده است.

جدول ۲- مشخصات و ویژگی‌های مجموعه داده‌های مورد استفاده [۱۴]

مجموعه داده	تنگی (Sparsity)	متوسط تعاملات هر کاربر	تعداد اقلام	تعداد کاربران	Sequential Intensity (SI)
MovieLens	۹۵.۱۶%	۱۶۵.۵	۶۰۴۰	۳۴۱۴	۰.۳۲۶۵
Gowalla	۹۹.۷۱%	۴۰.۷۴	~۱۴۰۰۰	~۱۳۱۰۰	۰.۰۷۴۸

۳-۳- پارامترهای ارزیابی:

در این بخش، ما ابتدا پارامترهای ارزیابی را بر اساس معیارهای تعیین شده در منبع [۱۴] معرفی می‌کنیم. سپس روش پیشنهادی و مدل‌های ارائه شده در کارهای مرتبط [۲۶, ۱۴, ۲۱] را با اجرای مدل‌ها روی دو مجموعه داده MovieLens و Gowalla می‌سنجیم. دلیل انتخاب دو مجموعه داده متفاوت به خاطر وجود تفاوت‌های SI در آن‌ها است. این امر به ما اجازه می‌دهد تا با آموزش و ارزیابی مدل‌ها بر روی این دو مجموعه داده مقایسه بهتری برای عملکرد مدل‌های ارائه شده در سناریوهای با الگوهای ترتیبی زیاد و کم خواهیم داشت، در نهایت، نتایج نشان خواهد داد که روش پیشنهادی ما در هر دو سناریو نسبت به مدل‌های مقایسه‌ای عملکرد برتری دارد. این پژوهش با استفاده از سه معیار اصلی مدل‌ها را ارزیابی می‌کند در فرمول ریاضیاتی این معیارها هر نماد به صورت زیر تعریف می‌شود:

N تعداد محتوایی که مدل برای کش در حافظه پیشنهاد می‌کند، $P_{1:N}$ مجموعه N محتوای برتری که مدل برای کش در حافظه پیشنهاد می‌کند، R مجموعه محتوایی که کاربر در واقعیت درخواست خواهد داد، $|R|$ اندازه مجموعه که کاربر در واقعیت درخواست خواهد داد، $|R \cap P_{1:N}|$ شمارشی از اشتراک تعداد محتوای پیشنهاد شده توسط مدل و محتوایی که کاربر واقعا درخواست داده است. و در نهایت $\#users$ تعداد کاربران را نشان می‌دهد.

دقت یا Precision@N: این معیار میزان دقت مدل در پیش‌بینی محتوای مورد نظر کاربر را نشان می‌دهد، نسبتی از تعداد محتوای‌های پیشنهادی که به درستی برای کش پیشنهاد شدند به کل تعداد پیشنهاد‌های مدل است. در واقع این معیار نشان دهنده کیفیت نرخ اصابت در کش است، دقت بالا نشانگر آن است که محتوایی که از حافظه کش واکنشی می‌شود مورد درخواست کاربر است و برای افزایش کارایی و کاهش داده‌های نامربوط در حافظه به ما کمک می‌کند.

$$Prec@N = \frac{|R \cap P_{1:N}|}{N} \quad (2)$$

یادآوری یا Recall@N: این معیار توانایی مدل در فراهم آوردن تمام محتوایی است که مورد درخواست کاربر قرار خواهد گرفت و نسبتی از تعداد محتوای های پیشنهادی که به درستی برای کش پیشنهاد شدند به کل محتوایی است که مورد درخواست کاربر هستند.

$$Recall@N = \frac{|R \cap P_{1:N}|}{|R|} \quad (3)$$

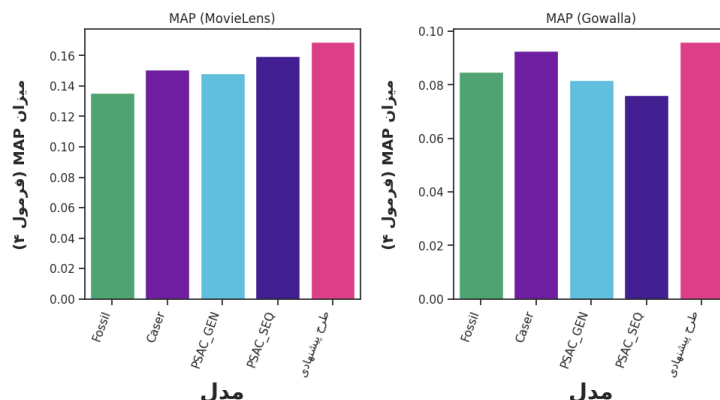
متوسط دقت میانه یا MAP: یک معیار کلی است که جنبه‌هایی از دقت و یادآوری را ترکیب می‌کند، و یک ارزیابی کلی از کیفیت مدل ارائه شده را فراهم می‌آورد. این معیار دقت میانگین را در هر موقعیت در فهرست پیشنهادی محتواهای مورد کش به صورت رتبه‌بندی شده محاسبه می‌کند. این رتبه‌بندی با در نظر گرفتن ترتیبی که محتواهای مورد درخواست کاربر در لیست پیشنهادی ظاهر می‌شوند. محاسبه می‌گردد. این معیار مدلهایی را ارزشمندتر می‌شناسد که درخواست واقعی کاربر برای محتوا را در بالاترین رتبه‌های فهرست پیشنهادی قرار دهند، و در نهایت با متوسط گرفتن این معیار برای هر کاربر، و سپس محاسبه آن برای همه کاربران ارزیابی جامعی را از عملکرد مدل ارائه می‌دهد.

$$MAP = \frac{\sum_{i=1}^{\#users} AP}{\#users} \quad (4)$$

$$AP = \frac{\sum_{N=1}^{|P|} PrecN \times rel(N)}{|P|} \quad (5)$$

۳-۴- عملکرد روش پیشنهادی

معیارهای تعریف شده در بخش قبل، چارچوبی قوی برای سنجش کارایی مدل فراهم می‌کنند. پس از آموزش و آزمون مدل‌ها بر روی دو مجموعه داده، به تجزیه و تحلیل این معیارها در مقایسه با مدل‌های مطرح شده در مطالعات [۱۴، ۲۱، ۲۶] پرداخته شده است. بر اساس نتایج به دست آمده که در جدول ۳ قابل مشاهده است، روش ارائه شده در تقریباً تمامی معیارها و به خصوص معیارهای دقت@۱۰، یادآوری@۱۰، و MAP عملکرد بهتری نسبت به سایر مدل‌های مورد مقایسه داشته است. این بهبود عملکرد برای مجموعه داده MovieLens به ترتیب ۳.۲٪، ۲.۳٪، و ۵.۹٪ و برای مجموعه داده Gowalla به ترتیب ۵.۱٪، ۷.۱٪، و ۳.۴٪ بوده است، که نشان دهنده پیشرفت قابل توجهی در مقایسه با مدل‌های قبلی است (درصد بهبود در هر معیار با مقایسه روش پیشنهادی با مدل پیشینی صورت گرفته است که بهترین نتیجه را در شبیه‌سازی داشته). شکل ۲ نتایج ارزیابی معیار MAP را نشان می‌دهد و به وضوح برتری روش پیشنهادی را هم در مواقعی که الگوهای ترتیبی در مجموعه داده مانند MovieLens زیاد هستند و هم در مجموعه داده Gowalla که الگوهای ترتیبی کمتری دارد، اثبات می‌کند. این بهبود نشان دهنده کارایی بالای مکانیزم توجه چندگانه در لایه شناسایی الگوها است، که با بررسی همزمان الگوهای مختلف، درک عمیقی از الگوهای ترتیبی و کلی را از دنباله ورودی استخراج می‌کند و برای آموزش شبکه‌های عصبی کاملاً متصل حیاتی است. همچنین، با گنجاندن مکانیزم تعبیه در آموزش شبکه عصبی و بهبود مدل، توانستیم با استفاده از ترجیحات کلی کاربران، به نتایج بهتری دست یابیم، که ارزیابی روی مجموعه داده Gowalla کارایی بالای روش ما را تأیید می‌کند.



شکل ۲- ارزیابی پارامتر MAP بر روی دو مجموعه داده Gowalla در سمت راست و MovieLens در سمت چپ

جدول ۳- نتایج مقایسه پارامترهای ارزیابی معرفی شده برای هر مدل، ستون آخر میزان بهبودی هر پارامتر را با مقایسه میزان آن در روش پیشنهادی و بهترین مدل در کارهای پیشین که در جدول پررنگ شده نشان می‌دهد.

مجموعه داده	پارامتر ارزیابی	Fossil	Caser	PSAC_gen	Psac_seq	روش پیشنهادی	بهبودی
Gowalla	Prec@1	۰,۱۷۳۶	۰,۱۹۶۱	۰,۱۶۴۸	۰,۱۵۱۹	۰,۱۹۳۷	-۲,۳٪
	Prec@5	۰,۱۰۴۵	۰,۱۱۲۹	۰,۰۹۸۹	۰,۰۹۲۸	۰,۱۱۶۶	۳,۳٪
	Prec@10	۰,۰۷۸۲	۰,۰۸۳۳	۰,۰۷۵۸	۰,۰۷۱۵	۰,۰۸۷۶	۵,۱٪
	Recall@1	۰,۰۲۷۷	۰,۰۳۱۰	۰,۰۲۶۲	۰,۰۲۳۷	۰,۰۳۰۶	-۱,۳٪
	Recall@5	۰,۰۷۹۳	۰,۰۸۴۵	۰,۰۷۴۲	۰,۰۶۸۵	۰,۰۸۹۲	۵,۵٪
	Recall@10	۰,۱۱۶۶	۰,۱۲۲۳	۰,۱۱۱۷	۰,۱۰۳۸	۰,۱۳۱۱	۷,۱٪
	MAP	۰,۰۸۴۸	۰,۰۹۲۸	۰,۰۸۱۹	۰,۰۷۶۱	۰,۰۹۶	۳,۴٪
MovieLens	Prec@1	۰,۲۳۰۶	۰,۲۵۰۲	۰,۲۵۳۵	۰,۲۶۶۶	۰,۲۸۳۱	۶,۱٪
	Prec@5	۰,۲۰۰۰	۰,۲۱۷۵	۰,۲۱۶۷	۰,۲۲۹۹	۰,۲۴۷۳	۲,۱٪
	Prec@10	۰,۱۸۰۶	۰,۱۹۹۱	۰,۱۹۳۰	۰,۲۰۶۵	۰,۲۱۹۸	۳,۳٪
	Recall@1	۰,۰۱۴۴	۰,۰۱۴۸	۰,۰۱۶۷	۰,۰۱۷۷	۰,۰۱۷۵	-۱,۱٪
	Recall@5	۰,۰۶۰۲	۰,۰۶۳۲	۰,۰۶۸۰	۰,۰۷۲۸	۰,۰۷۴۷	۲,۵٪
	Recall@10	۰,۱۰۶۱	۰,۱۱۲۱	۰,۱۱۵۶	۰,۱۲۴۷	۰,۱۲۸۹	۲,۳٪
	MAP	۰,۱۳۵۴	۰,۱۵۰۷	۰,۱۴۸۲	۰,۱۵۹۴	۰,۱۶۸۹	۵,۹٪

۴- نتیجه گیری

با گسترش و پیچیده شدن شبکه، نیاز به بهینه سازی آن بیش از پیش حس می‌شود. کش در شبکه به عنوان یکی از فناوری‌های کاربردی برای افزایش کارایی شبکه شناخته شده و مورد تحقیق و گسترش بوده است. با قدرتمندتر شدن تکنیک‌های یادگیری ماشین و پردازش داده ابزارهای مناسب‌تری برای پاسخ به محدودیت‌های موجود در این حوزه فراهم است. هدف از این مقاله ارائه روشی مبتنی بر سیستم‌های توصیه گر و یادگیری عمیق برای پاسخگویی به دو چالش عدم توجه به رفتار متوالی و ترجیحات کاربران بود. در نهایت با به کارگیری مکانیزم توجه چندگانه مدلی توسعه یافته ارائه دادیم و با ارزیابی آن نشان دادیم که روش پیشنهادی نه تنها بر روی مجموعه داده‌های با خاصیت ترتیبی بالا بلکه روی مجموعه داده‌های با خاصیت ترتیبی کم نیز کارکرد بهتری را نسبت به کارهای مشابه دارد.

مراجع

- [۱] "Cisco Visual Networking Index: Global Mobile Data Traffic Forecast Update, ۲۰۱۷-۲۰۲۲," Cisco, ۲۰۱۹.
- [۲] Sami Kekki, Walter Featherstone, Yonggang Fang, Pekka Kuure, Alice Li, Anurag Ranjan, Debashish Purkayastha, Feng Jiangping, Danny Frydman, Gianluca Verin, Kuo-Wei Wen, Kwihoon Kim, Rohit Arora, Andy Odgers, Luis M. Contreras, Salvatore Scarpina, "Mec in 5G Networks [white paper]," ETSI, Sophia Antipolis CEDEX, First edition - June ۲۰۱۸.
- [۳] Fabio Giust, Gianluca Verin, Kiril Antevski, Joey Chou, Yonggang Fang, Walter Featherstone, Francisco Fontes, Danny Frydman, Alice Li, Antonio Manzalini, Debashish Purkayastha, Dario Sabella, Christof Wehner, Kuo-Wei Wen, Zheng Zhou, "MEC Deployments in 4G and Evolution Towards 5G [white paper]," ETSI, Sophia Antipolis, February ۲۰۱۸.
- [۴] Yun Chao Hu, Milan Patel, Dario Sabella, Nurit Sprecher and Valerie Young, "Mobile Edge Computing A key technology towards 5G," ETSI, Sophia Antipolis, ۲۰۱۵.
- [۵] J. Yao, T. Han, and N. Ansari, 'On Mobile Edge Caching', IEEE Commun. Surv. Tutorials, vol. ۲۱, no. ۳, pp. ۲۵۲۵-۲۵۵۳, ۲۰۱۹, doi: ۱۰.۱۱۰۹/COMST.۲۰۱۹.۲۹۰۸۲۸۰.
- [۶] L. Li, G. Zhao, and R. S. Blum, 'A Survey of Caching Techniques in Cellular Networks: Research Issues and Challenges in Content Placement and Delivery Strategies', IEEE Commun. Surv. Tutorials, vol. ۲۰, no. ۳, pp. ۱۷۱۰-۱۷۳۲, ۲۰۱۸, doi: ۱۰.۱۱۰۹/CSUT.۲۰۱۸.۲۸۲۰۰۲۱.
- [۷] Y.-J. Chen, K.-M. Liao, M.-L. Ku, F. P. Tso, and G.-Y. Chen, 'Multi-Agent Reinforcement Learning Based 3D Trajectory Design in Aerial-Terrestrial Wireless Caching Networks', IEEE Trans. Veh. Technol., vol. ۷۰, no. ۸, pp. ۸۲۰۱-۸۲۱۵, Aug. ۲۰۲۱, doi: ۱۰.۱۱۰۹/TVT.۲۰۲۱.۳۰۹۴۲۷۳.
- [۸] Y. Zhao, W. Zhang, L. Zhou, and W. Cao, 'A Survey on Caching in Mobile Edge Computing', Wireless Communications and Mobile Computing, vol. ۲۰۲۱, pp. ۱-۲۱, Nov. ۲۰۲۱, doi: ۱۰.۱۱۵۵/۲۰۲۱/۵۵۶۵۶۴۸.
- [۹] K. Guo and C. Yang, 'Temporal-Spatial Recommendation for Caching at Base Stations via Deep Reinforcement Learning', IEEE Access, vol. ۷, pp. ۵۸۵۱۹-۵۸۵۳۲, ۲۰۱۹, doi: ۱۰.۱۱۰۹/ACCESS.۲۰۱۹.۲۹۱۴۵۰۰.
- [۱۰] A. Malik, J. Kim, K. S. Kim, and W.-Y. Shin, 'A Personalized Preference Learning Framework for Caching in Mobile

- Networks', IEEE Trans. on Mobile Comput., vol. ۲۰, no. ۶, pp. ۲۱۲۴–۲۱۳۹, Jun. ۲۰۲۱, doi: ۱۰.۱۱۰۹/TMC.۲۰۲۰.۲۹۷۵۷۸۶.
- [۱۱] H. Wu, A. Nasehzadeh, and P. Wang, 'A Deep Reinforcement Learning-Based Caching Strategy for IoT Networks with Transient Data', IEEE Trans. Veh. Technol., pp. ۱–۱۰, ۲۰۲۲, doi: ۱۰.۱۱۰۹/TVT.۲۰۲۲.۳۱۹۹۶۷۷.
- [۱۲] X. Wang, R. Li, C. Wang, X. Li, T. Taleb, and V. C. M. Leung, 'Attention-Weighted Federated Deep Reinforcement Learning for Device-to-Device Assisted Heterogeneous Collaborative Edge Caching', IEEE J. Select. Areas Commun., vol. ۳۹, no. ۱, pp. ۱۵۴–۱۶۹, Jan. ۲۰۲۱, doi: ۱۰.۱۱۰۹/JSAC.۲۰۲۰.۳۰۳۶۹۴۶.
- [۱۳] Y. Dai, D. Xu, Y. Lu, S. Maharjan, and Y. Zhang, 'Deep Reinforcement Learning for Edge Caching and Content Delivery in Internet of Vehicles', in ۲۰۱۹ IEEE/CIC International Conference on Communications in China (ICCC), Changchun, China, Aug. ۲۰۱۹, pp. ۱۳۴–۱۳۹. doi: ۱۰.۱۱۰۹/ICCCChina.۲۰۱۹.۸۸۵۵۹۵۱.
- [۱۴] Tang, J., & Wang, K. (۲۰۱۸). Personalized Top-N sequential recommendation via convolutional sequence embedding. arXiv (Cornell University). <https://doi.org/۱۰.۴۸۵۵۰/arxiv.۱۸۰۹.۰۷۴۲۶>
- [۱۵] M.-C. Lee and A. F. Molisch, 'Individual Preference Aware Caching Policy Design in Wireless D2D Networks', IEEE Trans. Wireless Commun., vol. ۱۹, no. ۸, pp. ۵۵۸۹–۵۶۰۴, Aug. ۲۰۲۰, doi: ۱۰.۱۱۰۹/TWC.۲۰۲۰.۲۹۹۴۵۸۱.
- [۱۶] Yasir, M., uz Zaman, S.K., Maqsood, T. et al. CoPUP: content popularity and user preferences aware content caching framework in mobile edge computing. Cluster Comput ۲۶, ۲۶۷–۲۸۱ (۲۰۲۳). <https://doi.org/۱۰.۱۰۰۷/s۱۰۵۸۶-۰۲۲-۰۳۶۲۴-۰>
- [۱۷] Y. Jiang, M. Ma, M. Bennis, F.-C. Zheng, and X. You, 'User Preference Learning-Based Edge Caching for Fog Radio Access Network', IEEE Trans. Commun., vol. ۶۷, no. ۲, pp. ۱۲۶۸–۱۲۸۳, Feb. ۲۰۱۹, doi: ۱۰.۱۱۰۹/TCOMM.۲۰۱۸.۲۸۸۰۴۸۲.
- [۱۸] Z. Zhang and M. Tao, 'Accelerated Deep Reinforcement Learning for Wireless Coded Caching', in ۲۰۱۹ IEEE/CIC International Conference on Communications in China (ICCC), Changchun, China, Aug. ۲۰۱۹, pp. ۲۴۹–۲۵۴. doi: ۱۰.۱۱۰۹/ICCCChina.۲۰۱۹.۸۸۵۵۹۱۵.
- [۱۹] Arulkumaran, Kai, et al. "Deep Reinforcement Learning: A Brief Survey." IEEE Signal Processing Magazine, vol. ۳۴, no. ۶, Nov. ۲۰۱۷, pp. ۲۶–۳۸. DOI.org (Crossref), <https://doi.org/۱۰.۱۱۰۹/MSP.۲۰۱۷.۲۷۴۳۲۴۰>.
- [۲۰] H. S. Goian, O. Y. Al-Jarrah, S. Muhaidat, Y. Al-Hammadi, P. Yoo, and M. Dianati, 'Popularity-Based Video Caching Techniques for Cache-Enabled Networks: A Survey', IEEE Access, vol. ۷, pp. ۲۷۶۹۹–۲۷۷۱۹, ۲۰۱۹, doi: ۱۰.۱۱۰۹/ACCESS.۲۰۱۹.۲۸۹۸۷۳۴.
- [۲۱] Zhang, Y., Li, Y., Wang, R., Lu, J., Ma, X., & Qiu, M. (۲۰۲۰). PSAC: Proactive Sequence-Aware content caching via deep learning at the network edge. IEEE Transactions on Network Science and Engineering, ۷(۴), ۲۱۴۵–۲۱۵۴. <https://doi.org/۱۰.۱۱۰۹/tnse.۲۰۲۰.۲۹۹۰۹۶۳>
- [۲۲] P. Wu, J. Li, L. Shi, M. Ding, K. Cai, and F. Yang, 'Dynamic Content Update for Wireless Edge Caching via Deep Reinforcement Learning', IEEE Commun. Lett., vol. ۲۳, no. ۱۰, pp. ۱۷۷۳–۱۷۷۷, Oct. ۲۰۱۹, doi: ۱۰.۱۱۰۹/LCOMM.۲۰۱۹.۲۹۳۱۶۸۸.
- [۲۳] C. Zhong, M. C. Gursoy, and S. Velipasalar, 'Deep Reinforcement Learning-Based Edge Caching in Wireless Networks', IEEE Trans. Cogn. Commun. Netw., vol. ۶, no. ۱, pp. ۴۸–۶۱, Mar. ۲۰۲۰, doi: ۱۰.۱۱۰۹/TCCN.۲۰۲۰.۲۹۶۸۳۲۶.
- [۲۴] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (۲۰۱۷). Attention is All you Need. arXiv (Cornell University), ۳۰, ۵۹۹۸–۶۰۰۸. <https://arxiv.org/pdf/۱۷۰۶.۰۳۷۶۲۷۰>
- [۲۵] Yoon Kim. ۲۰۱۴. Convolutional Neural Networks for Sentence Classification. In Conference on Empirical Methods on Natural Language Processing. ACL, ۱۷۵۶–۱۷۵۱.
- [۲۶] R. He and J. McAuley, 'Fusing Similarity Models with Markov Chains for Sparse Sequential Recommendation', in ۲۰۱۶ IEEE ۱۶th International Conference on Data Mining (ICDM), Barcelona, Spain: IEEE, Dec. ۲۰۱۶, pp. ۱۹۱–۲۰۰. doi: ۱۰.۱۱۰۹/ICDM.۲۰۱۶.۰۰۳۰.