مقاله علمی-ترویجی

مروری بر چالش‌ها و روش‌های فیلترسازی در سیستم‌های توصیه‌گر

دانیال شریف‌رازی/ گروه مهندسی کامپیوتر/ دانشکده فنی و مهندسی/ واحد شیراز/ دانشگاه آزاد اسلامی/ شیراز- ایران/ danial.sharifrazi@gmail.com

محمدامین شایگان* / گروه مهندسی کامپیوتر/ دانشکده فنی و مهندسی/ واحد شیراز/ دانشگاه آزاد اسلامی/شیراز-ایران/ Shayegan@iaushiraz.ac.ir

* نویسنده مسوول

چکیده

با افزایش روز افزون اهمیت اینترنت در زندگی انسان‌ها، وب‌سایت‌ها به یک ابزار بسیار مهم در تجارت الکترونیک جهت انجام معاملات روزانه تبدیل شده‌اند. رشد تصاعدی حجم اطلاعات در سایت‌های اینترنتی، سبب سردرگمی کاربران اینترنت، جهت یافتن اطلاعات مناسب با سلایق ایشان شده است. سیستم‌های توصیه‌گر با استفاده از تکنیک‌های نرم‌افزاری، سعی در ارایه پیشنهادهای متناسب با سلایق کاربران برای ایشان را دارند. این سیستم‌ها سبب صرفه جویی در هزینه و زمان برای کاربران اینترنت می‌شوند. در این مقاله مروری به تعاریف، چالش‌ها و انواع روش‌های فیلترسازی اطلاعات در سیستم‌های توصیه‌گرپرداخته می‌شود. نقاط ضعف و قوت هرکدام به بحث گذاشته شده و در انتها نتیجه‌گیری نهایی از مطالب ذکر شده بیان خواهد شد.

کلمات کلیدی: سیستم‌های توصیه‌گر، فیلترسازی محتوا محور، فیلترسازی مشارکتی، فیلترسازی هیبریدی

A Review of the Challenges and Methods of Filtering in Recommender Systems

Danial Sharifrazi/ Department of Computer Engineering/ School of Technical and Engineering/ Shiraz Branch/ Islamic Azad University/ Shiraz, Iran/Danial.sharifrazi@gmail.com

Mohammad Amin Shayegan*/ Department of Computer Engineering/ School of Technical and Engineering/ Shiraz Branch/ Islamic Azad University/ Shiraz, Iran/ Shayegan@iaushiraz.ac.ir

*corresponding author

Abstract

With the increasing importance of the Internet in the lives of people, websites have become a very important tool in e-commerce for daily transactions. The exponential growth of information on websites has confused Internet users to find suitable information in the line of their tastes. Recommender systems, using software techniques, try to offer suggestions tailored to their users' preferences. These systems, which have become an efficient tool in the field of Computer Science, save time and money for Internet users. In this review article definitions, challenges and types of information filtering methods in recommender systems are discussed. The advantages and disadvantages of each method will be discussed and the final conclusions will be drawn.

Keywords: Recommender Systems, Content-based Filtering, Collaborative Filtering, Hybrid Filtering

۱-مقدمه

در سال‌های اخیر با توسعه سریع فناوری‌های اخذ اطلاعات از راه دور، ذخیره‌سازی اطلاعات و تکنولوژی شبکه، حجم داده‌های موجود به طور فزاینده‌ای افزایش یافته است[۱]. از طرفی رشد سریع اینترنت منجر به در دسترس بودن این حجم عظیم از اطلاعات، در وب‌سایت‌ها شده است[۲]. از سوی دیگر با فراگیر شدن فناوری‌های جدید، تقاضای خرید آنلاین روزبه‌روز در حال افزایش است. از این رو مشتریان نیاز دارند که قبل از تصمیم‌گیری نهایی، تمام بررسی‌های لازم در خصوص آن محصول را انجام دهند[۳]. لیکن افزایش حجم اطلاعات باعث می‌شود تا تصمیم‌گیری برای کاربران دشوارتر شود. این پدیده با عنوان سربار اطلاعاتی در جهان امروز شناخته می‌شود[۴].

در عصر سربار اطلاعاتی، یافتن گزینه مناسب از میان تعداد زیادی از محصولات و سرویس‌ها ممکن است برای کاربران اینترنت دشوار باشد. از این‌رو در این میان نیاز به پیشنهادات شخصی به‌طور کامل احساس می‌شود[۵]. استفاده از تکنیک‌های هوش مصنوعی به‌منظور استفاده از اطلاعات بدست آمده از داده‌های حجیم و تبدیل آن به دانش مفید که به آن داده‌کاوی گفته می‌شود، یکی از مسایل اصلی در تجزیه و تحلیل اطلاعات داده‌های حجیم است[۶]. ایده کلی فراروی فرایند داده‌کاوی، دستیابی به دانش مفید از مجموعه داده‌های عمده و طبیعت آنها به شکل قابل درک برای کاربردهای بیشتر در آینده است.

وب‌کاوی یکی از بخش‌های داده‌کاوی به حساب می‌آید و شامل سه طبقه‌بندی گوناگون است: کاوش ساختار وب، کاوش محتوای وب و کاوش کاربرد وب. کاوش ساختار وب، برای شناخت ارتباط بین اطلاعات مرتبط یا متفاوت به‌صورت مستقیم و یا اطلاعات صفحات وب استفاده شده و یا برای استخراج ارتباطات ناشناخته گذشته بین صفحات وب مورد استفاده قرار می‌گیرد. کاوش محتوای وب، بیشتر برای استخراج اطلاعات مفید و ضروری از محتوای صفحات وب استفاده می‌شود. کاوش کاربرد وب، برای شناخت الگوهای کاربردی جالب توجه از داده‌های در دسترس در وب استفاده می‌شود تا به نحو بهتری بتواند کاربردهای مرتبط با وب را ارایه داده و درک نماید. سیستم‌های توصیه‌گر، بخشی از کاوش کاربرد وب هستند که در آنها، اولویت‌های رده‌بندی، توسط کاربر برای هر محصول یا آیتم، بر مبنای منافع وی حاصل می‌شود[۷].

در این مقاله مروری تلاش شده است تا روش‌های فیلترسازی اطلاعات موجود در وب، جهت استفاده در سیستم‌های توصیه‌گر معرفی شود. از این‌رو بر این اساس، ساختار این مقاله به‌صورت زیر تنظیم شده است.

در بخش ۲، سیستم‌های توصیه‌گر به اختصار معرفی شده است. بخش ۳ به مرور و دسته‌بندی چالش‌های موجود در سیستم‌های توصیه‌گر می‌پردازد. انواع سیستم‌های توصیه‌گر به تفصیل در بخش ۴ معرفی شده و انواع روش‌های فیلترسازی در آنها مورد بررسی قرار گرفته است. در نهایت در بخش ۵، نتیجه‌گیری نهایی از مطالب بیان شده ارایه شده و انواع روش‌های فیلترسازی در سیستم‌های توصیه‌گر مورد مقایسه و بحث قرار گرفته‌اند. ساختار این مقاله مشابه با ساختار سایر مقالات مروری ارایه شده در حوزه سیستم‌های توصیه‌گر مانند منصور و همکاران[۷] و پاتل و همکاران[۸] بوده، لیکن در این پژوهش مباحث به‌صورت کامل‌تر و به‌روزتر به بحث گذاشته خواهند شد.

۲- سیستم‌های توصیه‌گر

در سال‌های اخیر، بحث سیستم‌های توصیه‌گر، یکی از موضوع‌های جذاب در حوزه‌های علوم و صنایع بوده است[۹]. این سیستم‌ها جهت یافتن آیتم‌های مناسب برای کاربران طراحی شده و به‌تازگی به یکی از ابزارهای بسیار محبوب در حوزه تحقیقات هوشمند تبدیل شده‌اند[۱۰]. سیستم‌های توصیه‌گر به خرده‌فروشان کمک می‌کنند تا کالاهای مناسب را بر اساس نیاز مصرف‌کنندگان پیشنهاد کنند[۱۱]. سیستم‌های توصیه‌گر، مجموعه‌ای از ابزارها و تکنیک‌های ارایه پیشنهادات مفید به کاربران هستند که با فیلتر کردن اطلاعات، به کاربران در روند تصمیم‌گیری در جهت انتخاب محصولات و خدمات مناسب کمک می‌کنند[۱۳،۱۲]. سیستم‌های توصیه‌گر به‌طور کلی از روش‌های تشابه مشخصات، رتبه‌بندی محصولات و یا سایر تکنیک‌ها استفاده می‌کنند[۱۴]. به‌عنوان مثال، به‌تازگی این سیستم‌ها از الگوریتم‌های یادگیری ماشین در زمینه هوش مصنوعی استفاده کرده و توانسته‌اند سلایق یک کاربر خاص را بر اساس مشخصات فردی‌اش پیش‌بینی کنند[۱۵،۱۶]. امروزه بحث در خصوص سیستم‌های توصیه‌گر به یک حوزه جدید از تحقیق در یادگیری ماشین تبدیل شده است[۱۷]. با این حال انتخاب یک الگوریتم مناسب برای یک سیستم توصیه‌گربسیار دشوار است[۱۶].

امروزه سیستم‌های توصیه‌گر به‌طور گسترده‌ای در فعالیت‌های تجارت الکترونیک مورد استفاده قرار گرفته‌اند[۱۸]. همچنین این سیستم‌ها در حال حاضر به‌طور گسترده‌ای در حوزه مصارف الکترونیکی و سرگرمی‌ها و همچنین در حوزه تجارت الکترونیک توسط شرکت‌های بزرگ (مانند آمازون) و میلیون‌ها کاربر (مثلاً ۹۳ میلیون برای نتفلیکس) مورد استفاده قرار گرفته اند[۱۹].

در وب‌سایت‌های تجارت الکترونیک، اطلاعات موجود در توصیه‌گرها، به‌طور معمول بر اساس یک ارزیابی کلی توسط مشتریان ایجاد می‌شود[۲۰]. این ارزیابی‌ها می‌توانند به‌صورت بازخوردهای صریح (مانند رتبه‌بندی) یا بازخوردهای تلویحی (مانند کلیک کردن، خرید کردن و چک کردن) باشد[۲۱]. تخمین زده شده است که مشتریان ۳۰٪ از صفحات آمازون و ۸۰٪ از فیلم‌های نتفلیکس را به دنبال توصیه‌های ارایه شده توسط سیستم‌های توصیه‌گر، مشاهده می‌کنند[۲۲].

۳-چالش‌های موجود در سیستم‌های توصیه‌گر

بهبود سطح کیفیت پیشنهادات ارایه شده به کاربران، از چالش‌های مهم حوزه سیستم‌های توصیه‌گر می‌باشد[۲۳]. اما به‌طور کلی می‌توان چالش‌های موجود در سیستم‌های توصیه‌گر را در پنج گروه اصلی دسته‌بندی کرد که عبارتند از: شروع سرد[۳۵-۲۴]، مقیاس‌پذیری[۴۱-۳۶]، پراکندگی[۴۷،۳۴-۴۲]، هم‌نامی[۴۸،۷،۸] و حریم خصوصی[۵۴-۴۹]. در ادامه به معرفی هر کدام از موارد زیر پرداخته می‌شود.

۳ - ۱ شروع سرد

مشکل شروع سرد زمانی رخ می‌دهد که یک کاربر جدید یا آیتم جدید به سیستم اضافه می‌شود. این چالش بیان می‌کند که چگونه می‌توان محصولات را به یک کاربر جدید پیشنهاد داد در حالی‌که علایق وی هنوز مشخص نیست و تاکنون به هیچ آیتمی امتیاز نداده است[۵۵].

۳ - ۲ مقیاس‌پذیری

مقیاس‌پذیری توانایی سیستم را برای کارکرد موثر، هنگامی که اطلاعات در حال افزایش است بیان می‌کند. یک سیستم توصیه‌گر نیاز دارد در زمانی که تعداد کاربران یا آیتم‌ها در حال افزایش است آیتم‌ها را به کاربران بدون هیچ گونه تغییری پیشنهاد دهد. برای

رسیدن به این هدف، محاسبات و هزینه‌های زیادی مورد نیاز خواهد بود[۵۶].

۳-۳-پراکندگی

مشکل پراکندگی داده‌ها، یک مساله بسیار مهم در سیستم‌های توصیه‌گراست. سیستم‌های توصیه‌گربه ماتریس امتیازدهی کاربران برای پیشنهاد آیتم‌ها به سایر کاربران بسیار وابسته هستند. مشکل پراکندگی داده‌ها زمانی رخ می‌دهد که کاربر، یک ماتریس بزرگ از کالاها را در اختیار دارد ولی به بسیاری از آیتم‌های موجود در این ماتریس بزرگ، امتیاز نداده است[۲۸].

۳ - ۴- هم‌نامی

بسیاری از آیتم‌ها یا محصولات مشابه که در ورودی با نام‌های متفاوت ذخیره می‌شوند، تحت عنوان هم‌نام لحاظ می‌شوند. به سختی می‌توان تفاوتهای بین کاربران یا آیتم‌های مشابه را که هنوز توسط سیستم شناسایی نشده‌اند مشخص نمود. در آیتم‌های هم‌نام، هیچ شباهتی بین دو محصول یا آیتم که بتوان شباهت آنها را با استفاده از مقادیر شباهت محاسبه نمود (در فیلترسازی مشارکتی)، وجود ندارد[۷].

۳ - ۵-حریم خصوصی

حریم خصوصی یکی از مسایل بسیار مهم در سیستم‌های توصیه‌گر است. سیستم‌های توصیه‌گر برای ارایه پیشنهاد، نیاز به دانستن اطلاعاتی در مورد کاربران دارند. لیکن کاربران نیاز دارند بدانند که برای دریافت پیشنهاد، چه اطلاعاتی از آنها و چگونه مورد استفاده قرار خواهد گرفت[۷۵].

۴-انواع سیستم‌های توصیه‌گر

سیستم‌های توصیه‌گر، بر مبنای اطلاعات مورد استفاده برای توزیع محصولات یا آیتم‌ها برای کاربران، به گروه‌های مختلفی طبقه‌بندی می‌شوند. سه طبقه‌بندی کلی برای این سیستم‌ها عبارتند از[۵۸]:

- فیلترسازی محتوا محور
- فیلترسازی مشارکتی
- فیلترسازی هیبریدی

شکل (۱) انواع سیستم‌های توصیه‌گر را به اختصار نشان می‌دهد.

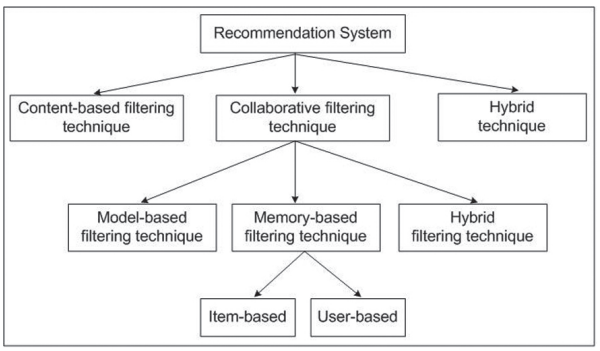

شکل ۱: انواع سیستم‌های توصیه‌گر[۸]

۴-۱-فیلترسازی محتوا محور

الگوریتم‌های فیلترسازی محتوا محور از سلایق کاربران برای پیشنهادات بعدی به وی استفاده می‌کنند. از این‌رو چالش‌های مهم این الگوریتم‌ها در چگونگی پیدا کردن سلایق کاربر بر اساس محتوای آیتم‌ها است. برای حل این مشکل، از بسیاری از روش‌های داده‌کاوی و یادگیری ماشین می‌توان استفاده نمود[۵۹]. در این نوع فیلترسازی، سیستم از محتوای آیتم‌ها استفاده کرده و شباهت میان آنها را پیدا می‌کند. پس از تجزیه و تحلیل تعداد کافی از آیتم‌های مورد علاقه کاربر، آیتم‌های دارای اولویت بیشتر برای آن کاربر خاص، در پروفایل کاربر ذخیره می‌شود. در مرحله بعد، سیستم توصیه‌گر در پایگاه داده‌ها جستجو کرده و موارد مناسب را با توجه به پروفایل کاربر انتخاب می‌کند[۵۸،۶۰]. در این روش، آیتم‌های جدید بر اساس میزان شباهتشان با آیتم‌های موجود در پروفایل کاربر، پیشنهاد می‌شوند[۶۱]. به‌عنوان مثال، اگر کاربر به فیلم‌های ژانر کمدی امتیاز مثبت دهد، سیستم یاد می‌گیرد که سایر فیلم‌های ژانر کمدی را نیز به این کاربر پیشنهاد دهد[۱۸].

در روش فیلترسازی بر پایه محتوا، پیشنهادات به کاربران تنها توسط رفتار و داده‌های تک کاربر ارایه می‌شود. توصیه آیتم و پروفایل کاربری خاص، نقش بسیار مهمی را در روش فیلترسازی محتوا محور ایفا می‌کنند[۸]. در واقع، سیستم‌های محتوا محور سعی در پیشنهاد آیتم‌های مشابه با آیتم‌هایی را دارند که کاربر در گذشته آنها را دوست داشته است[۶۲].

۴-۲-فیلترسازی مشارکتی

در اواسط دهه ۱۹۹۰، سیستم‌های توصیه‌گر مشارکتی نقش بسیار مهمی در زمینه فیلترسازی مشارکتی را بدست آوردند[۶۳]. این نوع از فیلترسازی، از پرکاربردترین روش‌های فیلترسازی در سیستم‌های توصیه‌گر بوده[۶۴] و در حال حاضر یکی از موفق‌ترین روش‌های فیلترسازی در ارایه پیشنهادات به کاربران نیز محسوب می‌شوند[۶۵]. به‌عنوان مثال، فناوری فیلترسازی مشارکتی در سال‌های اخیر، نتایج بسیار مهمی را در وب‌سایت‌های بزرگی مانند آمازون و فیسبوک در زمینه‌های نظری و عملی بدست آورده است. ایده اصلی سیستم‌های مشارکتی این است که کاربرانی که در گذشته عادت‌های مصرف مشابهی داشته‌اند، تمایل دارند در آینده نیز موارد مشابهی را به اشتراک بگذارند[۶۶].

در این روش، سیستم توصیه‌گر کاربرانی که سلایق مشابه دارند را از طریق رفتارهای گذشته آنها شناسایی می‌کند. به عنوان مثال، آیتم‌هایی که پیش‌تر توسط این کاربران دیده، خریده و یا امتیاز داده شده‌اند شناسایی شده و در مرحله بعد، این آیتم‌ها به کاربران جدیدی که سلایق مشابه با سایر کاربران در گذشته داشته‌اند، پیشنهاد می‌شوند[۱۷،۶۷]. تجربه نشان داده است که استفاده از این سیستم‌ها در وب‌سایت‌ها، نه تنها سودآوری بیشتری را در حوزه تجارت الکترونیک نسبت به سایر روش‌ها به همراه دارد، بلکه سبب افزایش رضایت کاربران نیز می‌شود[۶۸،۶۹].

سیستم‌های مشارکتی به دو نوع اصلی حافظه محور و مدل‌محور تقسیم می‌شوند[۷۰]. با ترکیب این دو روش فیلترسازی، سیستم‌های توصیه‌گرهیبریدی ساخته می‌شود[۸].

۴-۲-۱-فیلترسازی حافظه‌محور

در این روش، سیستم توصیه‌گر پیشنهادات خود را از طریق دیدگاه‌های مشابه سایر کاربران با کاربر فعال ارایه می‌دهد. کاربران با دیدگاه‌ها و امتیازهای مشابه، کاربران همسایه نامیده می‌شوند. هنگامی که همسایگان کاربر فعال مشخص شدند، از الگوریتم‌های متفاوتی جهت ترکیب دیدگاه‌های کاربران همسایه با کاربر فعال و در نتیجه ارایه پیشنهاد نهایی استفاده می‌شود. در الگوریتم‌های بر پایه حافظه، به‌طور معمول از معیار شباهت جهت ارایه توصیه‌ها استفاده می‌شود. شباهت میان کاربران یا آیتم‌ها می‌تواند بر مبنای امتیازدهی کاربران همسایه با کاربر فعال باشد.

روش فیلترسازی حافظه‌محور در دو نوع متفاوت طبقه‌بندی می‌گردد که شامل روش‌های فیلترسازی بر پایه کاربر و بر پایه آیتم می‌باشد[۸].

الف) روش فیلترسازی کاربرمحور

فیلترسازی کاربر محور بر مبنای برخی از آیتم‌های مشترک انجام می‌شود که میزان شباهت با استفاده از فرمول مجموع وزن‌ها محاسبه می‌گردد. فرمول مجموعه وزن‌ها از میانگین امتیازات کاربرانی که در گذشته به آن آیتم امتیاز داده بودند محاسبه می‌گردد. این مقادیر وزنی به‌عنوان شباهت کاربران با آیتم مورد نظر معرفی می‌شود. پیش‌بینی نهایی با استفاده از وزن‌های محاسبه شده در معادله (۱) و جایگذاری در معادله (۲) انجام می‌گردد[۷۱].

الگوریتم سیستم توصیه‌گر مشارکتی کاربرمحور، ساده است. در این نوع فیلترسازی، کاربر هدف بر اساس داده‌های جمع‌آوری شده از کاربران همسایه یافت می‌شود. کاربران همسایه کاربرانی هستند که در گذشته سلایق مشابهی را با کاربران هدف داشته‌اند[۷۲]. وجه تشابه میان دو کاربر در سیستم‌های کاربرمحور، توسط امتیازات داده شده آنها به آیتم‌های مشترک محاسبه می‌شود[۷۳]. وجه تشابه در این سیستم‌ها، توسط ضریب پیرسون محاسبه می‌گردد (معادله ۱) [۷۴].

$$S(a,u) = \frac{\sum_{i=1}^{n}(r_{a,i}-\bar{r}_a)(r_{u,i}-\bar{r}_u)}{\sqrt{\sum_{i=1}^{n}(r_{a,i}-\bar{r}_a)^2}\sqrt{\sum_{i=1}^{n}(r_{u,i}-\bar{r}_u)^2}} \quad (۱)$$ [۷۴]

در این فرمول، S معیار شباهت، a کاربر فعال، u کاربر ورودی، r امتیازات موجود در جدول آیتم-کاربر و به معنای میانگین امتیازات کاربر مورد نظر می‌باشد.

پس از یافتن شباهت‌هایی میان کاربران، مرحله بعدی پیش‌بینی امتیاز کاربر هدف به آیتم مورد نظر می‌باشد. پیش‌بینی مطابق معادله (۲) انجام می‌گردد[۷۲].

$$p(a,i) = \bar{r}_a + \frac{\sum_{i=1}^{n}(r_{u,i}-\bar{r}_u)\times S(a,u)}{\sum_{i=1}^{n} S(a,u)} \quad (۲)$$ [۷۲]

در این معادله، p به معنای امتیاز پیش‌بینی شده می‌باشد.

ب) روش فیلترسازی آیتم‌محور

این روش فیلترسازی با استفاده از شباهت میان آیتم‌ها و شباهت میان کاربران پیش‌بینی‌ها را انجام می‌دهد. از ماتریس آیتم-کاربر می‌توان این مساله را محاسبه کرد که آیتم‌های دریافتی، با آیتم هدف تا چه اندازه مشابه هستند. سپس تعدادی از مشابه‌ترین آیتم‌ها انتخاب و به کاربر توصیه می‌شود[۷۵].

در روش فیلترسازی آیتم‌محور، فرض می‌شود که علایق کاربر، با تغییرات بسیار کمی در آینده مواجه خواهد شد. هنگامی که کاربران به آیتم‌ها نظر مثبت می‌دهند، سیستم توصیه‌گر با استفاده از تجزیه و تحلیل امتیازات کاربران به آیتم‌ها در گذشته، می‌تواند آیتم‌های کاندید را جمع‌آوری کند. سپس سیستم توصیه‌گر با خوشه‌بندی آیتم‌های مشابه، کالاهای جدید را پیشنهاد می‌کند[۷۲].

برای محاسبه شباهت میان آیتم‌ها، به‌طور کلی از سه روش ضریب همبستگی پیرسون (معادله ۱)، شباهت کسینوسی و شباهت کسینوسی تنظیم شده استفاده می‌شود[۷]. شباهت کسینوسی مطابق معادله (۳) و شباهت کسینوسی تنظیم شده مطابق معادله (۴) محاسبه می‌گردند[۶۱].

$$Cosine - Similarity(u,v) = \frac{\overrightarrow{R_u}\otimes\overrightarrow{R_v}}{|\overrightarrow{R_u}|\cdot|\overrightarrow{R_v}|} \quad (۳)$$ [۶۱]

$$Adjusted - Cosine - Similarity(u,v) = \frac{\sum_{i\in I}(r_{u,i}-\bar{r}_u)(r_{v,i}-\bar{r}_v)}{\sqrt{\sum_{i\in I}(r_{u,i}-\bar{r}_u)^2}+\sqrt{\sum_{i\in I}(r_{v,i}-\bar{r}_v)^2}} \quad (۴)$$ [۶۱]

در معادله‌های (۳) و (۴)، R به معنای امتیاز در جدول آیتم-کاربر و حروف u و v هر کدام بیانگر یک آیتم هستند.

۴ - ۲ - ۲ روش فیلترسازی مدل‌محور

روش فیلترسازی بر پایه مدل، از ضریب شباهت در مجموعه داده‌ها استفاده نمی‌کند، بلکه به ایجاد یک مدل از مجموعه داده‌ها پرداخته و سپس به ارایه توصیه بر اساس مدل ساخته شده می‌پردازد. این روش می‌تواند از امتیازدهی پیشین کاربران جهت ایجاد مدل استفاده کند. فرایند ساخت مدل را می‌توان با استفاده از روش‌های داده‌کاوی و یا یادگیری ماشین انجام داد. این روش فیلترسازی، می‌تواند مساله پراکندگی داده‌ها در سیستم‌های توصیه‌گر را حل کند[۸].

در ادامه برخی از تکنیک‌های داده‌کاوی و یادگیری ماشین که در سیستم‌های توصیه‌گرمحتوامحور و مدل‌محور مورد استفاده قرار می‌گیرند، معرفی می‌گردند.

الف) رگرسیون

هنگامی که دو یا چند متغیر از طریق یک رابطه خطی با هم در ارتباط هستند، از روش رگرسیون برای بیان ارتباط بین آنها استفاده می‌شود. این روش، برای بررسی وابستگی یا عدم وابستگی بین متغیرها، فرآیندی مناسب است[۷۱].

عملکرد روش رگرسیون، به فرم فرآیند تولید داده‌ها و نحوه استفاده از آن بستگی دارد. زیرا اغلب، روال فرآیند تولید داده‌ها، یک روال بدون نظارت است. تکنیک رگرسیون در بسیاری از موارد به نحوه ساختن فرضیات بستگی دارد. اگر مقدار کافی از داده در دسترس باشد، این فرضیات بیشتر قابل آزمایش هستند. رگرسیون برای عمل پیش‌بینی می‌تواند مفید باشد اگر چه ممکن است روش بهینه‌ای نباشد. رگرسیون در بسیاری از کاربردها به خصوص در زمانی که تعداد داده‌ها کم باشد می‌تواند نتایج گمراه کننده‌ای به بار آورد[۷۶].

ب)طبقه‌بندی‌کننده بیزین

در این روش، پروفایل کاربر بر اساس توزیع احتمال شرطی (معادله ۵) و قضیه بیز مدل‌سازی می‌شود. در این معادله، c کلاس‌ها و x توصیفات کلاس‌ها هستند[۷۷،۷۸].

$$P(c|x) = \frac{P(c)P(x|c)}{P(x)} \quad (۵)$$ [۷۷،۷۸]

در رویکرد طبقه‌بندی بدون نظارت، هدف، یافتن کلاس‌ها از مجموعه‌ای از اشیا غیرطبقه‌بندی شده است. پس از یافتن چنین مجموعه‌ای از کلاس‌ها، آنها می‌توانند مبنای طبقه‌بندی موارد جدید باشند. در رویکرد بدون نظارت طبقه‌بندی بیزین، هدف، یافتن محتمل‌ترین مجموعه از توصیف‌های یک کلاس است[۷۹]. در رویکرد طبقه‌بندی با نظارت، هر ویژگی و برچسب کلاس به‌صورت متغیرهای تصادفی در نظر گرفته می‌شوند.

طبقه‌بندی‌کننده‌های بیزین برای محیط‌هایی که اطلاعات پروفایل کاربر و سلایق کاربر به کندی در حال تغییر باشد مناسب است، زیرا به مدت زمان بیشتری برای ساخت مدل نیاز دارند و از این‌رو این روش برای محیط‌هایی که اطلاعات پروفایل کاربر و سلایق وی به طور مداوم و با سرعت در حال تغییر باشد مناسب نیست[۷۱].

ج)تکنیک تکمیل ماتریس

مشکل پراکندگی در بیشتر موارد باعث ناتوانی یک سیستم توصیه‌گر در پیش‌بینی دقیق و قابل اعتماد آیتم‌ها به کاربران می‌شود[۸۰]. تکنیک تکمیل ماتریس به استنباط ورودی‌های مفقود شده از یک جدول از شماره‌ها اشاره دارد. این موضوع از نظر جبرشناسی مورد مطالعه قرار گرفته و در حوزه سیستم‌های توصیه‌گر، برای رتبه‌بندی محصولات مشتریان بسیار محبوب شده است[۸۱]. تکنیک تکمیل

ماتریس در بسیاری زمینه‌ها مانند فیلترسازی مشارکتی، کاربرد گسترده‌ای دارد[۸۲].

از این تکنیک بیشتر برای پیش‌بینی مقادیر امتیاز داده نشده کاربران در ماتریس آیتم-کاربر استفاده می‌شود. یکی از محبوب‌ترین روش‌های این تکنیک، استفاده از روش نزدیک‌ترین همسایه است که بیشتر در توصیه‌گرهای مشارکتی مورد استفاده قرار می‌گیرد. این روش بسیار به نحوه امتیاز سایر کاربران در گذشته وابسته است. با این وجود در اکثر مواقع، ماتریس آیتم-کاربر بسیار بزرگ بوده و بنابراین دارای مشکل پراکندگی است[۸۳].

د)خوشه‌بندی

تکنیک‌های خوشه‌بندی در حوزه‌های مختلفی مانند شناسایی الگو، پردازش تصویر، آنالیز داده‌ها و... مورد استفاده قرار گرفته است[۱۳]. تکنیک‌های خوشه‌بندی تلاش می‌کنند که مجموعه‌ای از داده‌ها را به زیر خوشه‌هایی تقسیم‌بندی کنند به‌گونه‌ای که روابط معنی‌داری بین خوشه‌ها موجود باشد[۸۴]. یک خوشه می‌تواند از میانگین نظرات کاربران تشکیل شود و برای ارایه پیشنهاد به کاربران دیگر مورد استفاده قرار گیرد. یک الگوریتم خوشه‌بندی خوب، خوشه‌ها را با کیفیت بالا تولید می‌کند که در آن شباهت بین اعضای هر خوشه زیاد است. دو مورد از معروف‌ترین روش‌های خوشه بندی، K-Means و SOM (Map Organizing Self) هستند[۷۱].

و) درخت تصمیم

درخت تصمیم بر اساس روش‌های گراف درختی، که بر اساس تجزیه و تحلیل مجموعه از نمونه‌های آموزشی دارای برچسب کلاس هستند، ساخته می‌شود. سپس از این داده‌ها برای طبقه‌بندی نمونه‌های دیده نشده استفاده می‌شود. اگر آموزش داده‌ها با دقت بالا انجام گیرد، درخت تصمیم توانایی پیش‌بینی با دقت بالایی را خواهد داشت[۷۱]. درخت تصمیم مجموعه‌ای از ویژگی‌ها را به‌صورت یک نتیجه (یک کلاس) طبقه‌بندی می‌کند. در درخت تصمیم، هر گره یک آزمایش روی یک صفت، هر شاخه نتیجه آن تست و در انتها برگها نشان دهنده کلاس نتیجه هستند[۸۵]. ایده اصلی درخت تصمیم، تجزیه یک تصمیم پیچیده به چندین تصمیم ساده‌تر است[۸۶]. درخت تصمیم به‌عنوان یک درخت ریشه‌دار در نظر گرفته می‌شود. به این معنا که گره بدون یال ورودی ریشه نامیده می‌شود. سایر گره‌ها یک یا دو ورودی دارند. گره‌های با یال خروجی، گره داخلی یا تست نامیده می‌شوند. سایر گره‌ها، گره‌های تصمیم یا برگ نامیده می‌شوند. در یک درخت تصمیم، هر گره داخلی، فضای نمونه را به دو یا چندین زیرمجموعه تقسیم می‌کند. هر برگ به یک کلاس اختصاص داده می‌شود که مناسب ترین مقدار هدف را نشان می‌دهد. مسیرها با پیمایش از ریشه به سمت برگ‌ها طبقه‌بندی می‌شوند[۸۷].

و) قانون انجمن

با معرفی قانون انجمن در سال ۱۹۹۳ برای نخستین بار، این روش بسیار مورد توجه قرار گرفت و هنوز هم یکی از محبوب‌ترین روش‌های علم داده‌کاوی محسوب می‌شود[۸۸،۸۹]. قانون انجمن به کشف و استخراج الگوهای پرتکرار، ارتباطات و همبستگی‌های میان داده‌ها و اشیای موجود در یک پایگاه‌داده می‌پردازد[۹۰]. این روش می‌تواند روابط یک آیتم را زمانی که آیتم‌های دیگر در یک تراکنش موجود هستند را پیش‌بینی کند[۹۱]. در واقع این روش بر شناسایی رفتار انسان‌ها تمرکز دارد که به‌راحتی قابل تفسیر هستند. شکل (۲) نمونه‌ای از این الگوها را نمایش می‌دهد[۹۲].

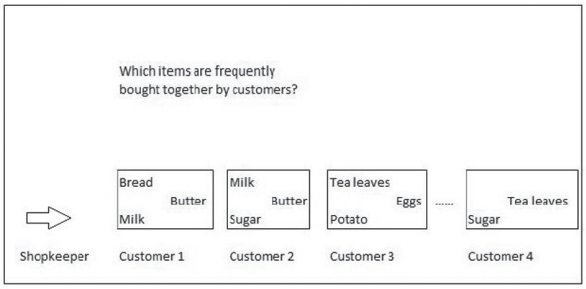

شکل ۲: قانون انجمن[۹۲].

ز)شبکه‌های عصبی مصنوعی

طبقه‌بندی، یکی از متداول‌ترین کارهای تصمیم‌گیری فعالیت‌های انسان است. طبقه‌بندی هنگامی رخ می‌دهد که نیاز است یک شیء در یک گروه یا کلاس از پیش تعریف شده قرار بگیرد[۹۳]. رشد سریع و موفقیت‌آمیز برنامه‌هایی که از تکنیک شبکه‌های عصبی استفاده می‌کنند، در زمینه‌های متنوعی مانند تجارت، علم، صنعت و پزشکی، گواه روشنی بر توانایی شبکه‌های عصبی هستند[۹۴]. از شبکه‌های عصبی برای تجزیه و تحلیل داده‌ها از قبیل پیش‌بینی، طبقه‌بندی و خوشه‌بندی استفاده می‌شود. این شبکه‌ها قادر به تشخیص و تکثیر هر الگوی غیرخطی پیچیده می‌باشند که از سلول‌های مغز انسان الهام گرفته شده است[۹۵].

برخی مزایا جهت استفاده از شبکه‌های عصبی نسبت به سایر روش‌ها وجود دارد. به‌عنوان مثال، این شبکه‌ها دارای نورون‌های زیادی با اتصالات وزنی بوده و بنابراین در مقابل داده‌های نویزی و اشتباه در پایگاه‌داده‌ها، مقاوم هستند[۷۱].

ح)یادگیری عمیق

یادگیری عمیق نوعی روش یادگیری ماشین است که باعث می‌شود کامپیوترها، از دانش بدون فرآیند برنامه‌نویسی صریح یاد بگیرند و الگوهای مفیدی را از داده‌های خام استخراج کنند. یادگیری عمیق با ساخت چندین ویژگی ساده، برای نمایش دادن یک مفهوم پیچیده، مسایل بازنمایی را حل می‌کند[۹۶].

شبکه‌های عصبی عمیق از شبکه‌های عصبی مصنوعی ایجاد شده‌اند. شبکه‌های عصبی مصنوعی به طور معمول حاوی تعداد کمی لایه (کم عمق) هستند. در حالی‌که شبکه‌های عصبی عمیق، حاوی تعداد بیشتری لایه پنهان (عمیق) هستند. با وجود لایه‌های بیشتر، شبکه‌های عصبی عمیق توانایی یادگیری دانش موجود در داده‌های بزرگ را دارند[۹۷]. یادگیری عمیق توسط چندین لایه پردازش غیرخطی انجام شده که سعی در بازنمایی سلسله مراتبی داده‌ها را دارند. ساختارهای متفاوتی برای طراحی شبکه‌های عصبی عمیق وجود دارد که از جمله مهم‌ترین آنها می‌توان به شبکه‌های عصبی بازگشتی، ماشین بولتزمن محدود، باور عمیق، خودرمزنگار و کانولوشن اشاره نمود[۹۸].

۴-۳-روش فیلترسازی هیبریدی

روش فیلترسازی هیبریدی، از روش‌های فیلترسازی متفاوت برای بهینه‌سازی بیشتر سیستم و اجتناب از برخی از محدودیت‌ها و مشکلات هر یک استفاده می‌کند. ایده فیلترسازی هیبریدی، ترکیب چند روش است که می‌تواند توصیه‌های بهتر و کارآمدتری را نسبت به تک الگوریتم‌های قبلی ارایه دهد، زیرا عیب یک الگوریتم توسط الگوریتم‌های دیگر برطرف می‌شود. یک روش توصیه هیبریدی، بهترین ویژگی دو یا بیشتر از دو روش را در یک روش واحد تلفیق

می‌نماید. رویکرد معمول در روش‌های توصیه هیبرید موجود، ادغام روش محتوا محور با روش‌های توصیه‌کننده دیگر است تا از مشکلاتی همچون شروع سرد، پراکندگی و مساله مقیاس‌پذیری اجتناب گردد[۴۷]. در بیشتر سیستم‌های هیبریدی، از ترکیب دو مدل محتوامحور و مشارکتی استفاده می‌شود[۱۴،۴۷].

برای مقابله با چالش‌های موجود در سیستم‌های توصیه‌گر، از سیستم‌های توصیه‌گر هیبریدی، که روش فیلترسازی محتوامحور و مشارکتی را ترکیب می‌کنند، استفاده می‌شود. این روش‌ها همچنین می‌توانند از الگوریتم‌های یادگیری ماشین (مانند یادگیری عمیق) برای یادگیری ویژگی‌های آیتم و کاربر و ترکیب این ویژگی‌ها با مدل مشارکتی استفاده کنند[۳۱].

۵- نتیجه‌گیری و بحث

با مقایسه روش‌های فیلترسازی مختلف در سیستم‌های توصیه‌گر و بررسی چالش‌های موجود در هر یک از روش‌ها، می‌توان دریافت که سیستم‌های توصیه‌گر محتوامحور به صورت تک کاربره و با استفاده از روش‌های یادگیری ماشین به ارایه پیشنهادات خود می‌پردازند. این نوع از فیلترسازی سبب استقلال کاربر فعال از سایر کاربران شده و البته موجب از دست رفتن بسیاری اطلاعات مفید سایر کاربران نیز می‌شود. برخلاف روش‌های محتوامحور، فیلترسازی مشارکتی بر مبنای سلایق مشابه کاربران به ارایه پیشنهادات خود می‌پردازد.

به این منظور، این نوع از سیستم‌ها از فرمول‌های ضریب شباهت در ساختار خود استفاده می‌کنند. وابستگی این نوع از روش‌های فیلترسازی به سایر کاربران، سبب ایجاد مشکلاتی نظیر شروع سرد، پراکندگی، مقیاس‌پذیری و هم‌نامی می‌شود.

تمامی نقاط ضعف و قوتی که برای روش‌های فیلترسازی مشارکتی بیان شد، در فیلترسازی مشارکتی حافظه‌محور نیز وجود دارند. حال آن‌که روش‌های مشارکتی مدل‌محور می‌توانند با ایجاد مدل از سلایق کاربر، تا حدی کاستی‌های فیلترسازی مشارکتی را بهبود داده و البته سبب ایجاد کاستی‌های مشابه با فیلترسازی محتوامحور شوند.

سیستم‌های توصیه‌گر هیبریدی می‌توانند از ترکیب روش‌های فیلترسازی محتوامحور و مشارکتی و یا روش‌های مشارکتی حافظه‌محور و مدل‌محور در ساختار خود استفاده کنند. این موضوع سبب می‌شود بخش قابل توجهی از مشکلات موجود در روش‌های فیلترسازی، پوشش داده شود. هرچند برطرف شدن بسیاری از مشکلات پیشین ممکن است سبب افزایش پیچیدگی سیستم و هزینه بالا در اجرا نیز شود.

خلاصه نتایج حاصل از مطالب ذکر شده، در جداول (۱) و (۲) درج شده است. در جدول (۱) به مقایسه و بررسی مزایا و معایب سیستم‌های توصیه‌گر محتوامحور، مشارکتی و هیبریدی پرداخته شده است. همچنین در جدول (۲) نتایج حاصل از مقایسه و بررسی هر یک از روش‌های فیلترسازی در سیستم‌های توصیه‌گر مشارکتی

جدول۱: مقایسه انواع روش‌های فیلترسازی در سیستم‌های توصیه‌گر

	محتوامحور	مشارکتی	هیبریدی
روش ارایه پیشنهاد	روش‌های یادگیری ماشین [۹۹-۱۰۳]	استفاده از ضریب شباهت[۷،۱۷،۴۲،۴۹،۷۵]	ترکیبی از روش‌های مشارکتی و محتوامحور [۲،۱۵،۲۴،۳۰،۳۲]
تعداد کاربران	تک کاربره	تعداد زیادی کاربر با سلایق مشابه	ترکیبی از روش‌های مشارکتی و محتوامحور
نقاط قوت	عدم وابستگی کاربر هدف به سایر کاربران	بهبود کارایی سیستم پیشنهادات با استفاده از اطلاعات مفید سایر کاربران	حل مشکل شروع سرد و پراکندگی داده‌ها
کاستی‌ها	محدودیت در تجزیه و تحلیل اطلاعات مفید سایر کاربران	شروع سرد، پراکندگی داده‌ها، مقیاس‌پذیری، هم‌نامی	افزایش پیچیدگی سیستم، هزینه بالا در اجرا

جدول۲: مقایسه انواع روش‌های فیلترسازی در سیستم‌های توصیه‌گرمشارکتی

	حافظه‌محور		مدل‌محور	هیبریدی
	آیتم‌محور	کاربرمحور		
روش ارایه پیشنهاد	شباهت میان آیتم‌ها [۸،۱۴،۱۷]	شباهت میان کاربران [۳۱،۶۱،۱۰۹]	روش‌های یادگیری ماشین [۱۰۴-۱۰۸]	ترکیبی از روش‌های مدل‌محور و حافظه محور[۷،۸،۷۰،۱۰۹]
نقاط قوت	توصیه‌های خوب غیرمنتظره برای کاربران	توصیه‌های خوب غیرمنتظره برای کاربران	بهبود مشکل مقیاس‌پذیری و پراکندگی داده‌ها، صرف زمان و هزینه پردازش کم برای داده	حل مشکل پراکندگی داده‌ها
کاستی‌ها	عدم توانایی در پیشنهاد آیتم جدید، صرف زمان و هزینه پردازش زیاد برای میلیون‌ها داده	عدم توانایی در پیشنهاد آیتم‌ها به کاربر جدید، پراکندگی داده‌ها، مقیاس‌پذیری	محدودیت در تجزیه و تحلیل اطلاعات مفید سایر کاربران	افزایش پیچیدگی سیستم، هزینه بالا در اجرا

را می‌توان مشاهده نمود.

بـا مقایســه نتایج بدســت آمده می‌تــوان دریافت کــه بهترین روش فیلترسازی در سیســتم‌های توصیه‌گر، وجود نداشته و استفاده از هر کــدام از روش‌ها، دارای مزایا و معایب خاص خود بوده و اســتفاده یا عــدم اســتفاده از هر کــدام از روش‌ها، با توجه به شــرایط خاص هر سیستم می‌تواند متفاوت باشد.

هــر چند پژوهش‌های زیادی در زمینه افزایش کارایی سیســتم‌های توصیه‌گرانجام گرفته اســت، لیکن الگوریتم‌های پیشنهادی هنوز به هدف نهایی یافتن و توســعه اطلاعات متناسب با درخواست کاربر در میان حجم عظیم داده‌ها در وب‌سایت‌ها به طور کامل دست نیافته اند و هنوز هم نیاز به انجام پژوهش‌های بیشــتر و بکارگیری تکنیک‌های نوین احساس می‌شود.

مراجع

[1] Marz, N., & Warren, J. (2015). Big Data: Principles and best practices of scalable real-time data systems. New York; Manning Publications Co.

[2] Tarus, J. K., Niu, Z., & Kalui, D. (2018). A hybrid recommender system for e-learning based on context awareness and sequential pattern mining. Soft Computing, 22(8), 2449-2461.

[3] Roul, R.K. & Arora, K. Soft Comput (2019). https://doi.org/10.1007/s00500-019-03861-3

[4] Mu, R. (2018). A survey of recommender systems based on deep learning. IEEE Access, 6, 69009-69022.

[5] Alharthi, H., Inkpen, D., & Szpakowicz, S. (2018). A survey of book recommender systems. Journal of Intelligent Information Systems, 51(1), 139-160.

[6] Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. IEEE Transactions on Knowledge & Data Engineering, (6), 734-749.

[7] Mansur, F., Patel, V., & Patel, M. (2017, March). A review on recommender systems. In 2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS) (pp. 1-6). IEEE.

[8] Patel, B., Desai, P., & Panchal, U. (2017, March). Methods of recommender system: a review. In 2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS) (pp. 1-4). IEEE.

[9] Wang, X., Nie, X., Wang, X., & Ding, Z. (2016, May). A new recommender system framework for TV video. In 2016 Sixth International Conference on Information Science and Technology (ICIST) (pp. 147-152). IEEE.

[10] Peška, L., Tashu, T. M., & Horváth, T. (2019). Swarm intelligence techniques in recommender systems-A review of recent research. Swarm and Evolutionary Computation, 48, 201-219.

[11] Del Corso, G. M., & Romani, F. (2019). Adaptive nonnegative matrix factorization and measure comparisons for recommender systems. Applied Mathematics and Computation, 354, 164-179.

[12] Batmaz, Z., Yurekli, A., Bilge, A., & Kaleli, C. (2019). A review on deep learning for recommender systems: challenges and remedies. Artificial Intelligence Review, 52(1), 1-37.

[13] Raza, S., & Ding, C. (2019). Progress in context-aware recommender systems—an overview. Computer Science Review, 31, 84-97.

[14] Sadeghian, M., & Khansari, M. (2018, December). A Recommender Systems Based on Similarity Networks: MovieLens Case Study. In 2018 9th International Symposium on Telecommunications (IST) (pp. 705-709). IEEE.

[15] Troussas, C., Krouska, A., & Virvou, M. (2018, November). Multi-algorithmic techniques and a hybrid model for increasing the efficiency of recommender systems. In 2018 IEEE 30th International Conference on Tools with Artificial Intelligence (ICTAI) (pp. 184-188). IEEE.

[16] Portugal, I., Alencar, P., & Cowan, D. (2018). The use of machine learning algorithms in recommender systems: A systematic review. Expert Systems with Applications, 97, 205-227.

[17] Mohamed, M. H., Khafagy, M. H., & Ibrahim, M. H. (2019, February). Recommender Systems Challenges and Solutions Survey. In 2019 International Conference on Innovative Trends in Computer Engineering (ITCE) (pp. 149-155). IEEE.

[18] Fellmann, M., Metzger, D., Jannaber, S., Zarvic, N., & Thomas, O. (2018). Process Modeling Recommender Systems. Business & Information Systems Engineering, 60(1), 21-38.

[19] Bouzekri, E., Canny, A., Fayollas, C., Martinie, C., Palanque, P., Barboni, E., ... & Gris, C. (2019). Engineering issues related to the development of a recommender system in a critical context: application to interactive cockpits. International Journal of Human-Computer Studies, 121, 122-141.

[20] Poirson, E., & Da Cunha, C. (2018). A recommender approach based on customer emotions. Expert Systems with Applications, 122, 281-288

[21] Sun, Z., Wu, B., Wu, Y., & Ye, Y. (2019). APL: Adversarial Pairwise Learning for Recommender Systems. Expert Systems with Applications, 118, 573-584.

[22] Bag, S., Ghadge, A., & Tiwari, M. K. (2019). An integrated recommender system for improved accuracy and aggregate diversity. Computers & Industrial Engineering, 130, 187-197.

[23] Anandhan, A., Shuib, L., Ismail, M. A., & Mujtaba, G. (2018). Social media recommender systems: review and open research issues. IEEE Access, 6, 15608-15628.

[24] Yao, L., Xu, Z., Zhou, X., & Lev, B. (2019). Synergies between Association Rules and Collaborative Filtering in Recommender System: An Application to Auto Industry. In Data Science and Digital Business (pp. 65-80). Springer, Cham.

[25] Herce-Zelaya, J., Porcel, C., Bernabé-Moreno, J., Tejeda-Lorente, A., & Herrera-Viedma, E. (2020). New technique to alleviate the cold start problem in recommender systems using information from social media and random decision forests. Information Sciences.

[26] Chen, H. H., & Chen, P. (2019). Differentiating Regularization Weights--A Simple Mechanism to Alleviate Cold Start in Recommender Systems. ACM Transactions on Knowledge Discovery from Data (TKDD), 13(1), 8.

[27] Kiran, R., Kumar, P., & Bhasker, B. (2020). DNNRec: A novel deep learning based hybrid recommender system. Expert Systems with Applications, 144, 113054.

[28] Han, D., Li, J., Li, W., Liu, R., & Chen, H. (2019). An app usage recommender system: improving prediction accuracy for both warm and cold start users. Multimedia Systems, 1-14.

[29] Jin, Y., Dong, S., Cai, Y., & Hu, J. (2020). RACRec: Review Aware Cross-Domain Recommendation for Fully-Cold-Start User. IEEE Access, 8, 55032-55041.

[30] Do, H. Q., Le, T. H., & Yoon, B. (2020, February). Dynamic Weighted Hybrid Recommender Systems. In 2020 22nd International Conference on Advanced Communication Technology (ICACT) (pp. 644-650). IEEE.

[31] Zhang, Z., Dong, M., Ota, K., & Kudo, Y. (2020). Alleviating new user cold-start in user-based collaborative filtering via bipartite network. IEEE Transactions on Computational Social Systems.

[32] Dong, B., Zhu, Y., Li, L., & Wu, X. (2020). Hybrid Collaborative Recommendation via Dual-Autoencoder. IEEE Access, 8, 46030-46040.

[33] Tang, Z., Zhang, X., & Niu, J. (2020, January). LDA Model and Network Embedding-Based Collaborative Filtering Recommendation. In 2019 6th International Conference on Dependable Systems and Their Applications (DSA) (pp. 283-289). IEEE.

[34] Osadchiy, T., Poliakov, I., Olivier, P., Rowland, M., & Foster, E. (2019). Recommender system based on pairwise association rules. Expert Systems with Applications, 115, 535-542.

[35] Dara, S., Chowdary, C. R., & Kumar, C. (2019). A survey on group recommender systems. Journal of Intelligent Information Systems, 1-25.

[36] Meng, S., Qi, L., Li, Q., Lin, W., Xu, X., & Wan, S. (2019). Privacy-preserving and sparsity-aware location-based prediction method for collaborative recommender systems. Future Generation Computer Systems, 96, 324-335.

[37] Verma, C., Hart, M., Bhatkar, S., Parker-Wood, A., & Dey, S. (2015). Improving scalability of personalized recommendation systems for enterprise knowledge workers. IEEE Access, 4, 204-215.

[38] Shou-Qiang, L., Ming, Q., & Qing-Zhen, X. (2016, December). Research and design of hybrid collaborative filtering algorithm scalability reform based on genetic algorithm optimization. In 2016 6th International Conference on Digital Home (ICDH)(pp. 175-179). IEEE.

[39] Singh, A. K. (2017, September). Scalable recommender system based on MapReduce framework. In 2017 IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI) (pp. 2892-2895). IEEE.

[40] Parvin, H., Moradi, P., Esmaeili, S., & Qader, N. N. (2019). A scalable and robust trust-based nonnegative matrix factorization recommender using the alternating direction method. Knowledge-Based Systems, 166, 92-107.

[41] Banda, L., & Bharadwaj, K. K. (2012). Improving scalability issues in collaborative filtering based on collaborative tagging using genre interestingness measure. Fourth International Conference on Advances in Recent Technologies in Communication and Computing

ادامه از صفحه۲۶

پی‌نوشت‌ها

1 Continue Passive Motion
2 Genetic Algorithm
3 Manipulator
4 Multi Layer Perceptron
5 Feedback
6 Adaptive Control
7 Multi population
8 Extension
9 Flexion

مراجع

[۱] موسوی محمدی، سید علی، اکبرزاده، توتونچی، برزنونی، رضا، دهقان فیض آباد، جواد، سالیار علی (۱۳۹۴)،«طراحی و ساخت ربات ربات فیزیوتراپی زانو». کنفرانس بین‌المللی مهندسی صنایع و سیستم‌ها دانشگاه فردوسی، مشهد، ایران.

[2] Neptune, Richard R., S. A. Kautz, and F. E. Zajac. “Contributions of the individual ankle plantar flexors to support, forward progression and swing initiation during walking.” Journal of biomechanics 34, no. 11 (2001): 1387-1398.
[3] Palmer, Michael Lars. “Sagittal plane characterization of normal human ankle function across a range of walking gait speeds.” PhD diss., Massachusetts Institute of Technology, 2002.
[4] Lunenburger, Lars, Gery Colombo, Robert Riener, and Volker Dietz. “Clinical assessments performed during robotic rehabilitation by the gait training robot Lokomat.” In 9th International Conference on Rehabilitation Robotics, 2005. ICORR 2005., pp. 345-348. IEEE, 2005.
[5] Banala, Sai K., Suni K. Agrawal, and John P. Scholz. “Active Leg Exoskeleton (ALEX) for gait rehabilitation of motor-impaired patients.” In 2007 IEEE 10th International Conference on Rehabilitation Robotics, pp. 401-407. IEEE, 2007.
[6] Veneman, Jan F., Rik Kruidhof, Edsko EG Hekman, Ralf Ekkelenkamp, Edwin HF Van Asseldonk, and Herman Van Der Kooij. “Design and evaluation of the LOPES exoskeleton robot for interactive gait rehabilitation.” IEEE Transactions on Neural Systems and Rehabilitation Engineering 15, no. 3 (2007): 379-386.
[7] Tsoi, Yun Ho, and Shane Q. Xie. “Impedance control of ankle rehabilitation robot.” In 2008 IEEE International Conference on Robotics and Biomimetics, pp. 840-845. IEEE, 2009.
[8] Akdoğan, Erhan, and Mehmet Arif Adli. “The design and control of a therapeutic exercise robot for lower limb rehabilitation: Physiotherabot.” Mechatronics 21, no. 3 (2011): 509-522.
[9] Liu, Qiong, Shuzhi Sam Ge, Yan Li, Mingye Yang, Hao Xu, and Keng Peng Tee. “A Simpler Adaptive Neural Network Tracking Control of Robot Manipulators by Output Feedback.” In 2020 6th International Conference on Control, Automation and Robotics (ICCAR), pp. 96-100. IEEE, 2020.
[10] Riener, Robert. “Robot-aided Gait Training.” The Encyclopedia of Medical Robotics 4 (2018).
[11] Yihun, Yimesker, Visharath Adhikari, Amirhossein Majidirad, and Jaydip Desai. “Task-Based Knee Rehabilitation With Assist-as-Needed Control Strategy and Recovery Tracking System.” Journal of Engineering and Science in Medical Diagnostics and Therapy 3, no. 2 (2020).
[12] Laschowski, Brock, John McPhee, and Jan Andrysek. “Lower-limb prostheses and exoskeletons with energy regeneration: Mechatronic design and optimization review.” Journal of Mechanisms and Robotics 11, no. 4 (2019).
[13] Yoshikawa, Tsuneo. Foundations of robotics: analysis and control. MIT press, 1990.
[14] Hogan, Neville. “Impedance control of industrial robots.” Robotics and Computer-Integrated Manufacturing 1, no. 1 (1984): 97-113.
[15] Hogan, Neville. “Impedance control: An approach to manipulation: Part I—Theory.” (1985): 1-7.
[16] Koceska, Natasa, Saso Koceski, Pierluigi Beomonte Zobel, and Francesco Durante. “Control architecture for a lower limbs rehabilitation robot system.” In 2008 IEEE International Conference on Robotics and Biomimetics, pp. 971-976. Ieee, 2009.
[17] Azar, Wahab Amini, F. Najafi, and M. A. Nekooi. “Rehabilitation of lower limbs using an optimized intelligent control law.” Majlesi Journal of Mechatronic Systems 1, no. 3 (2012).
[18] Huang, Vincent S., and John W. Krakauer. “Robotic neurorehabilitation: a computational motor learning perspective.” Journal of neuroengineering and rehabilitation 6, no. 1 (2009): 5.
[19] Reinkensmeyer, David J., and Sarah J. Housman. “” If I can’t do it once, why do it a hundred times?”: Connecting volition to movement success in a virtual environment motivates people to exercise the arm after stroke.” In 2007 Virtual Rehabilitation, pp. 44-48. IEEE, 2007.
[20] Ogata, Katsuhiko, and Yanjuan Yang. Modern control engineering. Vol. 5. Upper Saddle River, NJ: Prentice hall, 2010.

***

(ARTCom2012), 2012 p. 240 – 243
[42] Natarajan, S., Vairavasundaram, S., Natarajan, S., & Gandomi, A. H. (2020). Resolving data sparsity and cold start problem in collaborative filtering recommender system using linked open data. Expert Systems with Applications, 149, 113248.
[43] Rupasingha, R. A., & Paik, I. (2019). Alleviating sparsity by specificity□aware ontology□based clustering for improving web service recommendation. IEEJ Transactions on Electrical and Electronic Engineering, 14(10), 1507-1517.
[44] Reddy, M. M., Kanmani, R. S., & Surendiran, B. (2020, February). Analysis of Movie Recommendation Systems; with and without considering the low rated movies. In 2020 International Conference on Emerging Trends in Information Technology and Engineering (icETITE) (pp. 1-4). IEEE.
[45] Bag, S., Kumar, S., Awasthi, A., & Tiwari, M. K. (2019). A noise correction-based approach to support a recommender system in a highly sparse rating environment. Decision Support Systems, 118, 46-57.
[46] Wang, Y., Feng, C., Guo, C., Chu, Y., & Hwang, J. N. (2019, January). Solving the Sparsity Problem in Recommendations via Cross-Domain Item Embedding Based on Co-Clustering. In Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining (pp. 717-725). ACM.
[47] Cheng, J., & Zhang, L. (2019, April). Jaccard Coefficient-Based Biclustering and Fusion Recommender System for Solving Data Sparsity. In Pacific-Asia Conference on Knowledge Discovery and Data Mining (pp. 369-380). Springer, Cham.
[48] Raghuwanshi, S. K., & Pateriya, R. K. (2019). Recommendation Systems: Techniques, Challenges, Application, and Evaluation. In Soft Computing for Problem Solving (pp. 151-164). Springer, Singapore.
[49] Zhang, F., Lee, V. E., Jin, R., Garg, S., Choo, K. K. R., Maasberg, M., ... & Cheng, C. (2019). Privacy-aware smart city: A case study in collaborative filtering recommender systems. Journal of Parallel and Distributed Computing, 127, 145-159.
[50] Qi, L., Wang, R., Hu, C., Li, S., He, Q., & Xu, X. (2019). Time-aware distributed service recommendation with privacy-preservation. Information Sciences, 480, 354-364.
[51] Wang, W., Liu, A., Li, Z., Zhang, X., Li, Q., & Zhou, X. (2019). Protecting multi-party privacy in location-aware social point-of-interest recommendation. World Wide Web, 22(2), 863-883.
[52] Cena, Federica & Pensa, Ruggero & Rapp, Amon. (2019). Privacy Issues in Holistic Recommendations. 263-265. 10.1145/3314183.3323461.
[53] Valdez, A. C., & Ziefle, M. (2019). The users’ perspective on the privacy-utility trade-offs in health recommender systems. International Journal of Human-Computer Studies, 121, 108-121.
[54] Mazeh, I., & Shmueli, E. (2020). A personal data store approach for recommender systems: enhancing privacy without sacrificing accuracy. Expert Systems with Applications, 139, 112858.
[55] Sharma, L., & Gera, A. (2013). A survey of recommendation system: Research challenges. International Journal of Engineering Trends and Technology (IJETT), 4(5), 1989-1992.
[56] Lakshmi, S. S., & Lakshmi, T. A. (2014). Recommendation Systems: Issues and challenges. IJCSIT) International Journal of Computer Science and Information Technologies, 5(4), 5771-5772.
[57] Mahmoud, H., Hegazy, A., & Khafagy, M. H. (2018, February). An approach for big data security based on Hadoop distributed file system. In 2018 International Conference on Innovative Trends in Computer Engineering (ITCE) (pp. 109-114). IEEE.
[58] Çano, E., & Morisio, M. (2017). Hybrid recommender systems: A systematic literature review. Intelligent Data Analysis, 21(6), 1487-1524.
[59] Ricci, F., Rokach, L., & Shapira, B. (2011). Introduction to recommender systems handbook. In Recommender systems handbook (pp. 1-35). Springer, Boston, MA.
[60] Schafer, J. B., Konstan, J., & Riedl, J. (1999, November). Recommender systems in e-commerce. In Proceedings of the 1st ACM conference on Electronic commerce (pp. 158-166). ACM.
[61] Agarwal, A., & Chauhan, M. (2017). Similarity measures used in recommender systems: a study. International Journal of Engineering Technology Science and Research IJETSR, ISSN, 2394-3386.
[62] Kużelewska, U. (2011, January). Advantages of information granulation in clustering algorithms. In International Conference on Agents and Artificial Intelligence (pp. 131-145). Springer, Berlin, Heidelberg.
[63] Najafabadi, M. K., Mohamed, A. H., & Mahrin, M. N. R. (2019). A survey on data mining techniques in recommender systems. Soft Computing, 23(2), 627-654.

منابع [64] -[109]در دفتر نشریه موجود است.

***