



Improving the performance of collaborative filtering recommender systems using deep features extraction

Nayer Chavoshi¹, Sina Dami²

Abstract

The growing volume of information on the Web and the Internet has made difficult the process of deciding and selecting the information, data, or products needed for many web users. This study proposed a novel method to improve the performance of collaborative filtering recommender systems. The goal is to use deep feature extraction to provide more effective and desirable recommendations to the user. In the preprocessing step, the input data is first entered into the primary processing system and the feature values are normalized. Then, in order to perform more accurate calculations and reduce computation time, the size of the data is reduced using a deep belief network (DBN), while extracting deep features. Afterwards, using the collaborative filtering technique, the recommended items are offered to the user. Finally, according to the system outputs in the recommendation to the user, the accuracy of the proposed items is evaluated. To evaluate the proposed method, a comparison of its performance on the real-world MovieLens dataset with basic methods has been used. Experimental results showed that the proposed method has better performance in terms of coverage and support than other compared methods.

Keywords: *Recommender system, feature engineering, deep learning, collaborative filtering*

1. M.Sc. Student, Department of Computer Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran

2. Assistant Professor, Department of Computer Engineering, West Tehran Branch, Islamic Azad University, Tehran, Iran

Submitted: 2022-07-11

Accepted: 2023-01-31

Corresponding Author: Sina Dami

Email: dami@wtiau.ac.ir



بهبود عملکرد سیستم‌های توصیه‌گر پالایش مشارکتی با استخراج عمیق ویژگی‌ها

نیر چاووشی^۱، سینا دامی^۲

چکیده

حجم فراوان و روبه رشد اطلاعات بر روی وب و اینترنت، فرایند تصمیم‌گیری و انتخاب اطلاعات، داده یا کالاهای موردنیاز را برای بسیاری از کاربران وب دشوار کرده است. سیستم‌های توصیه‌گر با تحلیل رفتار کاربر خود، اقدام به پیشنهاد مناسب‌ترین اقلام داده، اطلاعات یا کالا می‌کنند. در این پژوهش، با بهره‌گیری از تکنیک‌های یادگیری عمیق، روشی برای بهبود عملکرد سیستم‌های توصیه‌گر پالایش مشارکتی ارائه شده است. هدف، استفاده از استخراج عمیق ویژگی‌ها در جهت ارائه پیشنهادهای مؤثرتر و مطلوب‌تر به کاربر سیستم موردنظر است. در بخش پیش‌پردازش، ابتدا داده‌های ورودی در سیستم پردازش اولیه قرار وارد می‌شوند و مقادیر ویژگی‌ها نرمال‌سازی می‌شوند. سپس، برای اینکه محاسبات دقیق‌تر انجام گیرد و زمان محاسبات نیز کاهش پیدا کند، با استفاده از یک شبکه باور عمیق (DBN)، ضمن استخراج عمیق ویژگی‌ها، ابعاد داده‌ها کاهش پیدا می‌کند. سپس، با استفاده از تکنیک پالایش مشارکتی، اقلام پیشنهادی به کاربر ارائه می‌شوند. در پایان، با توجه به خروجی‌های سیستم در توصیه به کاربر، ارزیابی صحت اقلام پیشنهادی صورت می‌گیرد. جهت ارزیابی روش پیشنهادی از مقایسه عملکرد آن بر روی مجموعه داده دنیای واقعی MovieLens با روش‌های پایه استفاده شده است. نتایج تجربی نشان داده است که روش پیشنهادی از نظر پوشش و حمایت نسبت به سایر روش‌های مورد مقایسه، عملکرد بهتری دارد.

کلمات کلیدی: سیستم توصیه‌گر، مهندسی ویژگی‌ها، یادگیری عمیق، فیلترینگ مشارکتی.

۱. استادیار گروه مهندسی کامپیوتر، واحد تهران غرب دانشگاه آزاد اسلامی، تهران، ایران

۲. دانشجو کارشناسی ارشد گروه مهندسی کامپیوتر، واحد تهران غرب دانشگاه آزاد اسلامی، تهران، ایران

تاریخ دریافت مقاله: ۱۴۰۱/۰۴/۲۰

تاریخ پذیرش نهایی مقاله: ۱۴۰۱/۱۱/۱۱

نویسنده مسئول مقاله: سینا دامی

Email: dami@wtiau.ac.ir

مقدمه

اینترنت با سرعت زیادی شروع به رشد کرده و افزایش حجم اطلاعات موجود در وبسایت‌ها، مشکلات متعددی برای کاربران ایجاد کرده است. بسیاری از سایت‌ها دارای حجم زیادی از اقلام هستند که کاربران در بررسی و انتخاب آن‌ها دچار سردرگمی می‌شوند. اخیراً سیستم‌های توصیه‌گر، به دلیل توانایی در تصمیم‌گیری برای کاربران در انتخاب‌های مناسب، در عصر توسعه سریع فناوری اینترنت از اهمیت بیشتری برخوردار شده‌اند. به همین دلیل، ضرورت استفاده از سیستم‌های توصیه‌گر جهت فیلتر کردن و پالایش اطلاعات غیرقابل چشم‌پوشی است. برخی شرکت‌های بزرگ ارائه‌دهنده خدمات، از این نوع سیستم برای یافتن آسان‌تر اقلام مورد علاقه کاربرانشان استفاده می‌کنند. یک سیستم توصیه‌گر می‌تواند با فیلتر کردن و نمایش فهرست اقلامی که مورد علاقه کاربران است، از هدر رفتن زمان آن‌ها و همچنین ایجاد سردرگمی جلوگیری کند و بهره‌وری کاربران در استفاده مؤثر از این نوع سایت‌ها را افزایش دهد.

سیستم‌های توصیه‌گر^۱ بهموزات وب توسعه یافته‌اند. آن‌ها در ابتدا بر اساس فیلترهای جمعیت شناختی آمبیتی بر محتوا^۲ و پالایش مشارکتی^۳ کار می‌کردند (شاؤ، لی و بیان، ۲۰۲۱). امروزه، این سیستم‌ها از انواع اطلاع متناظر با تعاملات کاربران استفاده می‌کنند. پالایش مشارکتی یکی از کاربردی‌ترین روش‌ها در طراحی سیستم‌های توصیه‌گر است. در این روش، اقلام بر اساس سابقه رتبه‌بندی گذشته مانند کاربران هم‌فکر، به کاربر فعل توصیه می‌شود. با وجود این، زمانی که تعداد ویژگی‌ها افزایش پیدا می‌کند، پالایش مشارکتی با کاهش در دقت و مطلوبیت پیشنهادهای به کاربران سیستم همراه است. برای رفع این مشکل، از روش‌هایی سنتی یادگیری ماشین استفاده می‌شود که کارایی مناسبی نیز دارند. روش‌های یادگیری عمیق در پژوهش‌های اخیر کاربردهای فراوانی داشته‌اند و در بسیاری از زمینه‌ها توانسته‌اند از روش‌های سنتی یادگیری مашین بهتر عمل کنند. در این پژوهش، ترکیبی از تکنیک‌های استخراج عمیق و پالایش مشارکتی برای طراحی سیستم توصیه‌گر ارائه شده است.

پیشینه تحقیق

در عصر کلان داده‌ها، سیستم‌های توصیه‌گر نقش اساسی در مدیریت داده‌ها و فیلتر کردن اطلاعات ایفا می‌کنند. در این زمینه، فیلتر مشارکتی (CF) به عنوان یکی از برجسته‌ترین استراتژی‌ها برای مقابله مؤثر با مجموعه داده‌های بزرگ به کار گرفته می‌شود تا محتوا مطلوبی را در قالب توصیه به کاربران، ارائه دهد. با این وجود، مشخص شده است که توصیه‌گرهای CF از پراکندگی داده‌ها، عمدتاً در سناریوهای شروع سرد رنج می‌برند. این حقیقت، کیفیت توصیه‌ها را به‌طور قابل توجهی کاهش می‌دهد. در ادبیات تحقیق در مورد موضوع فوق، راه حل‌های متعددی پیشنهاد شده است که در آن‌ها مشارکت‌های پیشرفته، بهنوعی مشروط یا مرتبط با روش‌های سنتی CF مانند فاکتورسازی ماتریسی (MF) (اویانگ و همکاران، ۲۰۲۲^۴) اعمال شده، یعنی برای مدل‌سازی کاربران و آیتم‌ها در قالب‌های با ابعاد کم، بر بھینه‌سازی خطی تکیه می‌شود. برای غلبه بر چالش‌های ذکر شده، تعداد فزاینده‌ای از مطالعات انجام شده است که تکنیک‌های یادگیری عمیق را در زمینه CF برای مدل‌سازی عامل پنهان بررسی می‌کنند.

با پیشرفت‌های مداوم و سریع در فناوری ارتباطات و ذخیره‌سازی داده‌ها، کاربران اینترنت با حجم زیادی از داده در بستر اینترنت مواجه می‌شوند. پدیده کلان داده چه از طریق تجارت الکترونیک (دامی و یاحقی زاده، ۲۰۱۸^۵، شبکه‌های اجتماعی

-
1. Recommender Systems
 2. Demographic filtering
 3. Content-based filtering
 4. Collaborative filtering
 5. Shao, Li & Bian
 6. Ou-Yang et al
 7. Dami & Yahaghizadeh

(فن و مصطفوی، ۲۰۱۹)، یا خدمات استریم، چالش‌های قابل توجهی را در حفظ بازیابی مؤثر و کارآمد اطلاعات به همراه داشته است. از طرفی، این چالش‌ها فرصت‌هایی را برای ظهور راه حل‌های جدید در مدیریت داده‌ها و فیلتر کردن اطلاعات فراهم کرده‌اند (لیو و چونگ، ۲۰۱۸).

با در نظر گرفتن سناریوی کنونی، سیستم‌های توصیه‌گر بدون شک به کاربران کمک کرده‌اند تا با پیشنهاد محتوا یا خدماتی که به خوبی با ترجیحات و علایق خاص کاربران مطابقت دارند، تجربه آنلاین رضایت‌بخش‌تری داشته باشند (کاماجو و همکاران، ۲۰۱۸)؛ بنابراین، سیستم‌های توصیه‌گر خود را به عنوان تکنیک‌های مناسبی برای مدیریت اضافه بار اطلاعات معرفی کردند؛ سیستم‌هایی که محبوبیت کنونی خود را توجیه می‌کنند، به این معنی که بسیاری از خدمات آنلاین در سال‌های گذشته از آن‌ها استفاده کرده‌اند. به عنوان نمونه‌های شاخص، می‌توان شبکه‌های اجتماعی مانند توییتر، اینستاگرام و فیسبوک، اسپاتیفای، یوتیوب، نتفلیکس و آمازون پرایم را به عنوان سرویس‌های استریم و آمازون، نتسویز و گوگل اذر را به عنوان کانون‌هایی که خدمات تجارت الکترونیک را نمایندگی می‌کنند، ذکر کرد.

برای توصیه محتوای بالقوه به یک کاربر، یک سیستم توصیه‌گر به داده‌های کلیدی متکی است. به عنوان مثال داده‌هایی که از نمایه کاربر و اولویت‌های تاریخی استخراج شده‌اند، ارتباطات شبکه‌های اجتماعی و هر نوع تعامل دیگری که می‌تواند الگوی مرور کاربر را نشان دهد. به طور کلی، روشی که یک توصیه مبتنی بر آن انجام می‌شود، طبقه‌بندی‌های اساسی از انواع سیستم‌های توصیه‌گر را تعریف می‌کند که به طور سنتی به عنوان رویکردهای مبتنی بر محتوا (CB)، فیلتر مشارکتی (CF) و رویکردهای ترکیبی طبقه‌بندی می‌شوند. در این میان، CF به عنوان یکی از محبوب‌ترین و موفق‌ترین استراتژی‌ها برای توصیه معرفی می‌شود که در سال‌های گذشته توجه زیادی از بخش‌های آکادمی و صنعت را به خود جلب کرده است.

یک استراتژی CF برای توصیه می‌تواند تحت عنوان، استفاده و دست‌کاری ترجیحات تاریخچه‌ای از رفتار کاربران قبلی، برای پیش‌بینی ترجیحات ناشناخته کاربران جدید، تعریف شود. این تعریف معمولاً بر اساس این فرض بیان می‌شود که اگر دو کاربر با آیتم‌های مشابهی تعامل داشته باشند یا رفتار تعاملی مشابهی از خود نشان دهند، احتمالاً تعاملات آتی آن‌ها نیز مشابه خواهد بود.

در زمینه فوق، داده‌ها به صورت یک ماتریس کاربر \times آیتم‌ها (به عنوان مثال، یک آرایه دو بعدی) هستند که در آن ردیف‌های ماتریس معمولاً کاربران را نشان می‌دهند و ستون‌های آن آیتم‌ها را بیان می‌کنند. مثالی از این مدل در شکل ۱ نشان داده شده است. هنگامی که کاربر i با یک آیتم j تعامل می‌کند، یک مقدار یا وزن قدرت آن تعامل را تعیین می‌کند، وزنی که اساساً به کاربرد دامنه (به عنوان مثال، فیلم، موسیقی، رسانه‌های اجتماعی، اخبار) و نوع توصیه‌ای که باید انجام شود (یعنی پیش‌بینی یا رتبه‌بندی) بستگی دارد. دو شکل اساسی تعامل را می‌توان صریح (یعنی رتبه‌بندی، بررسی یا هر نوع امتیازی که کاربر به صراحت به یک مورد داده است) یا ضمنی (به عنوان مثال، تعداد کلیک‌ها، زمان صرف شده برای تماشای یک ویدیو، گوش دادن به موسیقی یا مرور یک وب‌سایت که از اقدامات کاربر محاسبه می‌شود) دانست.

به طور کلی، تعامل کاربر با تمام آیتم‌های یک پایگاه داده غیرممکن است؛ بنابراین، تنها بخش کوچکی از آیتم‌ها به ازای هر کاربر رتبه‌بندی شده، یا در تعامل هستند. همچنین، با افزایش حجم داده‌ها، رویکردهای مبتنی بر CF از مقیاس‌پذیری، پراکندگی داده‌ها و مسائل شروع سرد رنج می‌برند، مسائلی که باعث کاهش عملکرد مستقیم به علایق توصیه‌ها می‌شود. پراکندگی داده‌ها و شروع سرد، مسائل مرتبط هستند؛ زیرا هر دوی آن‌ها از کمبود داده ناشی می‌شوند. مسئله اول با تعداد کم رتبه‌بندی برای موارد موجود مشخص می‌شود که یافتن رابطه بین کاربران و موارد را دشوار می‌کند. مسئله دوم زمانی اتفاق می‌افتد که فقدان داده‌های کاربر و تاریخچه رتبه‌بندی آیتم، سیستم را از ارائه توصیه‌های قابل اعتماد باز می‌دارد.

1. Fan & Mostafavi

2. Liu & Cheung

3. Camacho et al

		Items							
		i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8
Users	u_1	4		3	1	5			
	u_2		5	3	4		2	3	
	u_3		1		5	4		3	5
	u_4	5			2		4		
	u_5	2					3	1	
	u_6		5	4		1			4

شکل ۱: نمونه‌ای از ماتریس رتبه‌بندی

از زمان پیدایش CF، الگوریتم‌ها، روش‌ها و رویکردهای توصیه‌ای زیادی پیشنهاد شده‌اند. از تکنیک‌های سنتی تا جدیدترین روش‌های همسایگی و مدل‌های عامل پنهان مانند الگوریتم‌های مبتنی بر فاکتورسازی ماتریسی (MF)، در حال حاضر محبوب‌ترین آن‌ها هستند. در حالی که روش اولی یک روش آماری آسان برای پیاده‌سازی است که توصیه‌های منطقی و قابل تفسیر ارائه می‌کند، دومی یک رویکرد مقیاس‌پذیر است که برای دستیابی به نتایج پیش‌بینی سریع و دقیق حتی برای پایگاه‌های داده بزرگ مؤثر است.

علی‌رغم شیوع آن‌ها در ادبیات CF، تکنیک‌های فوق هنوز محدودیت‌های خود را دارند؛ اگرچه روش‌های همسایگی برای پیاده‌سازی و ارائه توصیه‌های معقول ساده هستند؛ اما از مشکلات مقیاس‌پذیری رنج می‌برند، مشکلاتی که طبیعتاً در سناریوهای کلان داده حیاتی تر هستند.

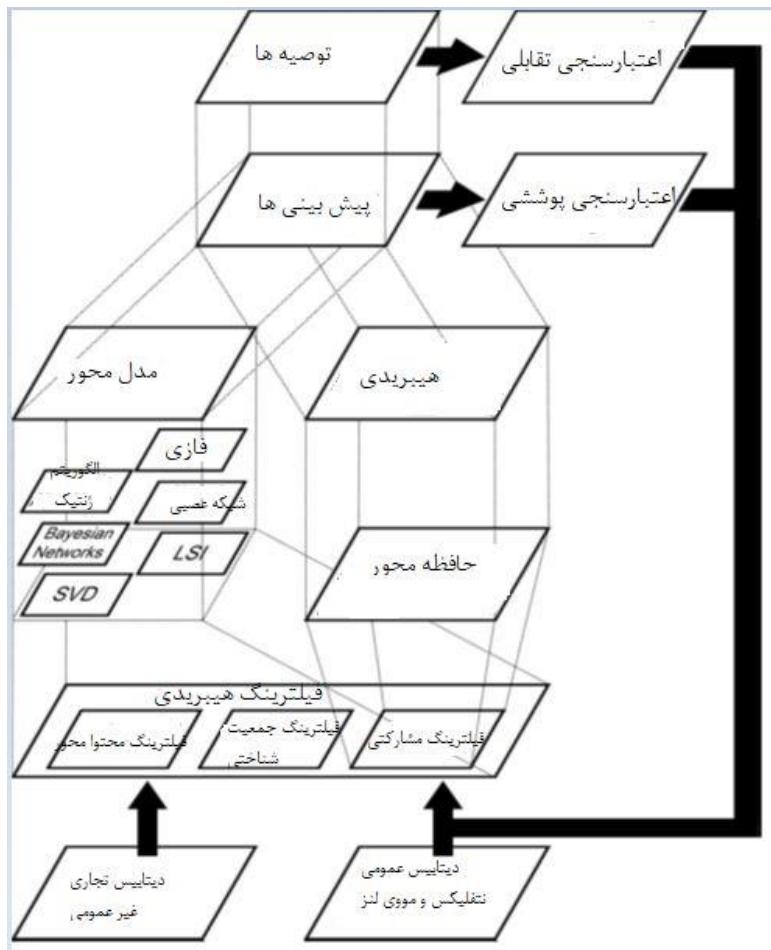
به‌طور کلی، مدل‌های عامل پنهان نشان داده‌اند که توصیه‌های کارآمدی را در شرایط پراکندگی بالا انجام می‌دهند. اساساً، آن‌ها قبل از ارائه توصیه به یک مرحله یادگیری از قبل برای کشف پارامترهای مدل بهینه در فضای ویژگی‌های کم بعدی، هم برای کاربران و هم برای آیتم‌ها نیاز دارند. با این حال، این روش‌های خطی معمولاً تفسیرپذیری نتایج توصیه شده را محدود می‌کنند؛ زیرا توانایی پیش‌بینی آن‌ها به عوامل ابعاد پایین تعداد کاربران و آیتم‌ها بستگی دارد. علاوه بر این، آن‌ها برای یادگیری بازنمایی‌های پنهان پیچیده‌تر و انتزاعی‌تر از داده‌های موجود تلاش می‌کنند و همچنین از نظر محاسباتی گران هستند.

عمدتاً به دلیل چالش‌های ذکر شده، الگوریتم‌های یادگیری عمیق در چند سال گذشته مورد توجه خیلی زیادی قرار گرفته‌اند (هوآ و همکاران، ۲۰۱۹). این روش‌ها برای یادگیری پارامترهای مدل، بر تکنیک‌های بهینه‌سازی غیرخطی تکیه می‌کنند. این تکنیک‌ها، الگوریتم‌ها را برای نمایش داده‌ها، به شکل قابل ملاحظه‌ای قوی تر می‌کند و قدرت تعمیم بالای آن‌ها نیز برخورد کارآمد با داده‌های خام یا غیرساخت‌یافته را تسهیل می‌کند. به این ترتیب، شبکه‌های عصبی عمیق قادر به دستیابی به انتزاعات عمیق‌تر از داده‌ها هستند که به طور مؤثر پیشرفت‌های قابل توجهی را در انواع وظایف مانند تشخیص (دامی، شیرازی و حسینی، ۲۰۱۳) پیش‌بینی (دامی، ۲۰۱۶)، خوش‌بندی (کریمی و همکاران، ۲۰۲۱) و طبقه‌بندی (خلف، ۲۰۲۱) نشان می‌دهند.

-
1. Hua et al
 2. Dami, Shirazi & Hoseini
 3. Dami
 4. Karim et al

تأکید می کنیم که بسیاری از تکنیک های طبقه بندی دیگر را می توان برای مقابله با مشکل CF در نظر گرفت، مانند شبکه های عصبی احتمالی پیشرفته، طبقه بندی دینامیک عصبی و طبقه بندی کننده ماشین بولتزمن محدود (زنگ و همکاران^۱). در نتیجه، مطالعه و توسعه تکنیک های یادگیری عمیق، پیشرفته های مهمی را در بسیاری از زمینه های تحقیقاتی علوم رایانه تسهیل کرده است که از آن ها، تشخیص اشیا، تشخیص گفتار، بینایی رایانه و پردازش زبان طبیعی را نقل می کنیم. از این نظر، مطالعات مربوط به یادگیری عمیق در سیستم های توصیه گر نیز مورد توجه قرار گرفته اند که به راحتی از افزایش تعداد مقالات منتشر شده در سال های گذشته قابل مشاهده است.

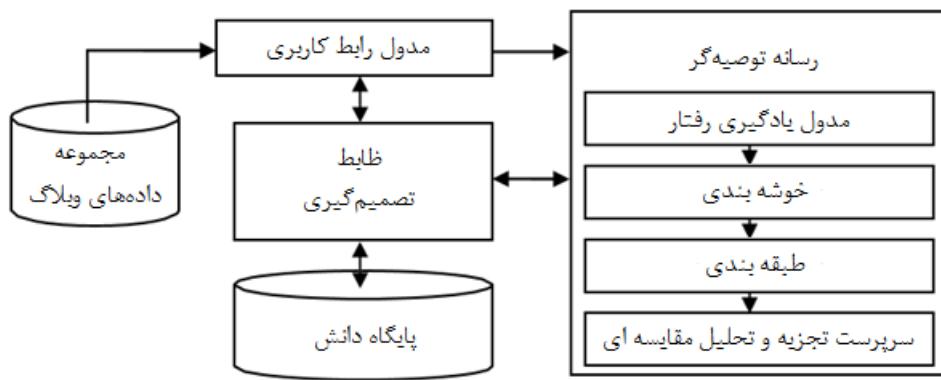
شکل ۲، نمونه هایی از روش های مورد استفاده در سیستم های توصیه گر را نشان می دهد (بابادیلا و همکاران^۲). این شکل، مهم ترین روش های مرسوم، تکنیک ها و الگوریتم های ارائه پیشنهاد و رابطه و گروه بندی های آن ها را ارائه می دهد.



شکل ۲: نمونه های مرسوم توصیه ها و رابطه ای آن ها (بابادیلا و همکاران، ۲۰۱۳)

معماری نهایی سیستم پیشنهادی در شکل ۳ نشان داده شده است. معماری سیستم پیشنهادی، از هفت مؤلفه اصلی مانند مجموعه داده های و بلاگ، مدول رابط کاربری، مدول ویژگی گریزی، چارچوب سیستم توصیه گر و نتایج، تشکیل شده است. چارچوب سیستم توصیه گر از دو مدول به نام های خوش بندی و انتخاب منفی تشکیل شده است.

1. Zhang et al
2. Bobadilla et al



شکل ۳: معماری سیستم پیشنهادی

مجموعه داده های و بلگ، از مجموعه داده استاندارد کاربران شبکه اجتماعی که از سراسر جهان جمع آوری می شود، تشکیل شده است. مدول رابط کاربر، اطلاعات ضروری را از مجموعه داده های استاندارد جمع آوری می کند و آن را به منظور پردازش بیشتر، به سیستم توصیه گر می فرستد. سیستم توصیه گر از چهار مدول فرعی مانند مدول تحلیل رفتار، مدول خوشبندی، مدول طبقه بندی و عامل تحلیل مقایسه های تشکیل شده است. در بین این موارد، مدول تحلیل رفتار، ویژگی های ضروری را از مجموعه داده مورد نظر، بر مبنای عوامل تعیین شده، انتخاب می کند و به منظور پردازش بیشتر، موارد ثبت شده را به مدول طبقه بندی ارسال می کند. مدول طبقه بندی، داده ها را با کمک ضابط تصمیم گیری و پایگاه قوانین، طبقه بندی می کند. در نهایت، عامل تحلیل مقایسه های، با کمک ضابط تصمیم گیری و پایگاه قوانین، تصمیم نهایی را می گیرد و مناسب بودن محصول فعلی را برای جامعه هدف می سنجد. ضابط تصمیم گیری، برای همه کاربران شبکه اجتماعی، بر مبنای این مسئله که چه رفتاری دارند و با استفاده از قوانین و نتایج طبقه بندی، تصمیم گیری می کند. این دانش، تجربه پیشین کاربران شبکه اجتماعی و علایق فعلی نوجوانان در شبکه های اجتماعی را در بر می گیرد و به منظور تصمیم گیری در مورد کاربران، با استفاده از ضابط تصمیم گیری، کارآمد است.

روش پژوهش

روش انجام تحقیق در بخش اول به صورت کتابخانه ای، از طریق مطالعه مقالات و تحقیقات علمی، گزارش های فنی، کتب، پایان نامه ها و پژوهه های تحقیقاتی صورت گرفته و مطالب موجود در سایت های اینترنتی علمی و فنی در زمینه سیستم های توصیه گر و به ویژه سیستم های توصیه گر پالایش مشارکتی بررسی می شوند. در بخش بعدی، به صورت تحلیلی از طریق مقایسه روش های موجود، شناخت مزايا و معایب روش های کنونی و شناسایي خلاهای موجود در این زمینه انجام می گيرد. ارائه روش پیشنهادی برای بهبود سیستم توصیه گر پالایش مشارکتی با استفاده استخراج عمیق ویژگی ها آخرین مرحله تحقیق خواهد بود.

نمودار شکل ۴، مراحل انجام پژوهش را نشان می دهد. در بخش پیش پردازش، ابتدا داده های ورودی به سیستم، مورد پردازش اولیه قرار می گیرند و مقادیر ویژگی ها نرمال سازی می شوند. سپس، برای اینکه محاسبات را دقیق تر کنیم و زمان محاسبات نیز کاهش پیدا کند، اقدام به کاهش تعداد ابعاد داده های ورودی با روش DBN خواهیم. در نهایت تنها ویژگی هایی از داده های ورودی باقی می مانند که در انجام محاسبات مؤثر هستند.

بالاخره، با استفاده از فیلترینگ مشارکتی، اقدام به پیشنهاد اقلام به کاربران صورت می گیرد. در پایان، با توجه به خروجی های سیستم در پیشنهاد دهنده به کاربر، صحت پیشنهاد ارائه شده به کاربر را بازبینی می کنیم. در ادامه این بخش در مورد مراحل فوق، به تفصیل صحبت خواهیم کرد و آن ها را با جزئیات بیشتری بررسی می کنیم.



شکل ۴: فرآیند انجام پژوهش

پیش‌پردازش داده‌ها

تمرکز روش ما بر بهره‌برداری از اطلاعات موجود ماتریس کاربر-آیتم تمرکز دارد که برای بهبود توصیه‌ها مفید است. ماتریس کاربر- کالا، پایه روش پالایش گروهی است که با اطلاعات جانبی همراه با کالا، ویژگی‌هایی مانند برچسب‌ها، سال انتشار، محتوای چندرسانه‌ای و غیره را بررسی می‌کند. برای کاربران، شغل، سن، جنسیت و غیره در نظر گرفته می‌شود. در نهایت، اطلاعات تعاملی مربوط به تعامل کاربر و کالا، مانند قیمت، خرد، کلیک بررسی می‌شوند. در این تحقیق، ما با جمع‌آوری اطلاعات جانبی غنی درباره آیتم‌ها، ماتریس کاربر-آیتم را افزایش دادیم. علاوه، اطلاعات تعاملی را به جای نرخ صریح کاربر از تحلیل بازخورد ضمنی و فعالیت‌های کاربر برای ساخت مشخصات شخصی کاربران به کار گرفتیم.

با این فرض که ویژگی‌های آیتم‌ها، به خصوص ویژگی‌های محتوایی آن مانند برچسب‌ها، یکی از دلایل اصلی برای علاقه‌مندی کاربر به اقلام هستند، اقلام را در ساختاری مناسب و بر اساس ویژگی‌هایی مانند برچسب‌ها و دیگر مشخصات برای استنتاج میزان ترجیحات کاربر در گروهی که آیتم به آن تعلق دارد، دسته‌بندی کردیم.

برچسب‌ها در واقع اقدامات کاربر در تعریف ویژگی‌های محتوایی است تا به طور ضمنی علائق کاربر با اطلاعاتی مهم درک شود. اولاً، برچسب‌های اجتماعی منابع ضمنی ارزشمندی از محتوای ژانر هر آهنگ هستند که بدون پرسش صریح، چیزی که فرد می‌خواهد را به او ارائه می‌دهند، ثانیاً، برچسب‌ها به دلیل درک کاربران از ویژگی‌های محتوا محور اقلام، دیدگاه مشابهی را از آن‌ها استخراج می‌کنند.

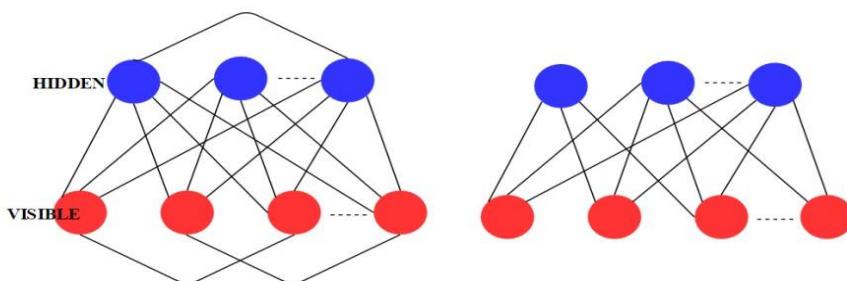
اگر آیتمی هیچ برچسبی نداشته باشد، سیستم توصیه پیشنهاد محتوای توصیفی هر آیتم را بازیابی می‌کند. در اینجا، هیچ رتبه‌بندی صریحی وجود ندارد؛ اما رفتار کاربر به شکل چندتایی ذخیره می‌شود که در آن، آیتم نشانگر چیزی است که کاربر به آن علاقه نشان داده است. برای غلبه بر مشکل پراکندگی و اندازه بزرگ مجموعه داده و پالایش آن برای تولید قوانین انجمنی، ما از ویژگی‌های آهنگ برای مدل‌سازی تعاملات کاربران با اقلام استفاده کردیم تا ترجیحات کاربر را نشان داده و روابط ضمنی بین کاربران را تشخیص دهیم.

استخراج ویژگی‌ها با استفاده از شبکه باور عمیق

شبکه باور عمیق (DBN)، یک مدل شبکه عصبی عمیق است که با انباسته سازی ماشین‌های بولتزمن محدود (RBM) شکل گرفته است. خروجی هر RBM قبلی، ورودی RBM بعدی است. داده‌ها از طریق RBM پایینی به شبکه وارد می‌شوند، دو لایه

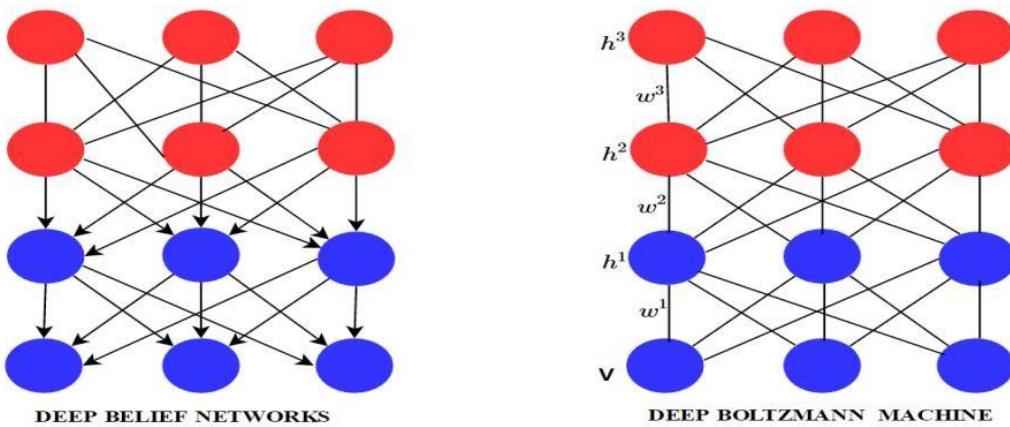
بالا یک اتصال دوتایی دارند، در بقیه لایه ها، اتصال یک جهته است. توجه دارید که DBM یک مدل گرافیکی بدون جهت است. در حال حاضر هیچ ارتباطی بین واحدهای یک لایه وجود ندارد؛ ولی بین واحدهای ورودی و واحدهای نهان ارتباط تعریف شده است. DBM در هنگامی که با منبع بزرگی از داده های بدون برچسب آموزش می بینند و با داده های برچسب دار تنظیم می شود به عنوان یک دسته بندی کننده، خوب عمل می کند.

ساختار این ماشین، از ماشین بولتزمن (BM) عمومی الهام گرفته است که عبارت است از شبکه ای از واحدهای مبتنی بر تصمیمات احتمالی جهت تعیین حالت های فعال و غیرفعال آنها. آموزش الگوریتم BM آسان است، ولی در فرایند کند نمایش داده می شود. کاهش تعداد لایه های نهان یک DBM به یک ماشین بولتزمن محدود (RBM) را ایجاد می کند. DBM در هنگامی که با منبع داده بزرگ بدون برچسب آموزش داده می شود و با داده های برچسب دار خوب عمل می شود به عنوان یک دسته بندی کننده خوب عمل می کند. آموزش پشت هایی از RBM ها و لایه های نهان بسیار، با استفاده از فعال سازی ویژگی روی یک RBM به عنوان ورودی برای لایه بعدی منجر به تشکیل شبکه باور عمیق (DBN) می شود. شکل ۵، ساختار یک RBM را نشان می دهد.



شکل ۵: چپ) یک ماشین بولتزمن با ویژگی های نهان روشن و خاموش و لایه متغیر نشان دهنده بردار احتمالی حالت های روشن و خاموش است؛ راست) یک RBM با واحدهای آشکار و غیر آشکار متصل و واحدهای نهان و غیر نهان متصل.

شکل ۶ یک DBN را نشان می دهد که از پشت هایی از ماشین های بولتزمن محدود (RBM) و یک لایه اضافی برای عمل تفکیک تشکیل شده است. RBM ها مدل های تولیدی احتمالی هستند که توزیع احتمال مشترک داده های مشاهده شده (آموزشی) را بدون استفاده از برچسب داده ها یاد می گیرند. هنگامی که ساختار یک DBN مشخص شد، هدف آموزش یادگیری وزن W بین لایه ها است. هر گره از گره دیگر در همان لایه مستقل است و با در نظر داشتن این خاصیت برای تمامی گره ها می توان وزن های تولیدی هر RBM را آموزش داد. این الگوریتم پس از آن به سراغ الگوریتم یادگیری لایه به لایه حریصانه می رود که هر پشت لایه RBM را در هر دفعه یاد بگیرد. در شکل زیر در سمت چپ، لایه بالا به رنگ قرمز یک RBM و لایه پایین به رنگ آبی شبکه باور حلقوی جهت دار را شکل می دهد.



شکل ۶: شبکه باور عمیق (DBN) سه لایه و ماشین بولتزمن عمیق سه لایه

توصیه به کاربر با استفاده از فیلترینگ مشارکتی

سیستم‌های توصیه‌گر با تحلیل و بررسی داده‌های متعلق به کاربران، یک سری آیتم‌های خاص را بر مبنای علایق به کاربران پیشنهاد می‌کنند. هدف از آنالیز داده‌های مربوط به کاربران، استخراج الگوهای هر کاربر به منظور پیش‌بینی آیتم‌ها است. یکی از مهم‌ترین روش‌ها در سیستم‌های توصیه‌گر، روش فیلترینگ مشارکتی است. در سیستم‌های توصیه‌گر مبتنی بر فیلترینگ مشارکتی از معیارهای شباهت جهت کشف کردن کاربران مشابه با کاربر جدید برای ارائه پیشنهاد استفاده می‌شود. از چالش‌های سیستم‌های توصیه‌گر مبتنی بر فیلترینگ مشارکتی می‌توان به فاکتورهای شباهت و تشخیص همسایگی اشاره کرد. فیلترینگ مشارکتی، شباهه بین کاربر و گزینه را به صورت همزمان در نظر می‌گیرد. مدل‌های فیلترینگ مشارکتی می‌توانند گزینه‌ای به کاربر الف پیشنهاد دهد که بر اساس شباهت‌های بین کاربر الف و کاربر ب است. برای مثال کاربر الف وارد سایت نمایش فیلم می‌شود، مدل فیلترینگ مشارکتی باید هم فیلم‌هایی مشابه فیلم‌هایی که کاربر الف در گذشته نگاه کرده است را پیشنهاد دهد و هم فیلم‌هایی که کاربران مشابه به کاربر الف تماشا کرده‌اند.

فیلتر مشارکتی روشی برای پیش‌بینی خودکار (فیلتر کردن) در مورد علایق یک کاربر با جمع‌آوری اولویت‌ها یا اطلاعات سلیقه از بسیاری از کاربران (همکاری) است. فرض اساسی رویکرد فیلترینگ مشارکتی این است که اگر یک فرد A نظر یکسانی با شخص B در مورد یک موضوع داشته باشد، احتمال دارد که A نظر B را در مورد موضوعی متفاوت نسبت به نظر شخصی که به طور تصادفی انتخاب شده است داشته باشد. به عنوان مثال، یک سیستم توصیه فیلتر مشترک برای ترجیحات در تلویزیون برنامه‌نویسی می‌تواند پیش‌بینی کند که کاربر کدام برنامه تلویزیونی را دوست دارد، با توجه به فهرستی جزئی از سلایق آن کاربر (دوست داشتن یا دوست نداشتن). باید توجه داشت که این پیش‌بینی‌ها مختص کاربر است؛ اما از اطلاعات جمع‌آوری شده از بسیاری از کاربران استفاده می‌شود. این با رویکرد ساده‌تر یعنی دادن میانگین امتیاز (غیراختصاصی) برای هر آیتم موردعلاعه، به عنوان مثال بر اساس تعداد آرا قابل انجام است.

در مفهوم کلی‌تر، فیلتر مشترک روند فیلتر برای اطلاعات و یا الگوهای استفاده از تکنیک‌های مربوط به همکاری میان عوامل متعدد، نظرات، منابع داده و غیره است. کاربردهای فیلتر مشارکتی معمولاً شامل مجموعه داده‌های بسیار بزرگی است. روش‌های فیلتر مشترک برای انواع مختلفی از داده‌ها از جمله: داده‌های سنجش و پایش، مانند اکتشاف مواد معدنی، سنجش محیطی در مناطق بزرگی احتمالی متفاوت به کار گرفته شده‌اند.

داده‌های مالی، مانند مؤسسات خدمات مالی که بسیاری از منابع مالی را ادغام می‌کنند یا در تجارت الکترونیک و برنامه‌های کاربردی وب که تمرکز بر روی داده‌های کاربر و غیره است. این بخش بر فیلتر کردن مشترک برای داده‌های کاربر متمرکز است، اگرچه برخی از روش‌ها و رویکردهای ممکن است برای سایر برنامه‌های کاربردی اصلی نیز کاربرد داشته باشد.

در روش فیلترینگ مشارکتی بر اساس شباهت رفتاری و الگوهای عملکردی کاربرانی که شباهت‌های رفتاری و الگوهای مشابه با کاربر فعلی در گذشته داشته‌اند، پیشنهادهای ارائه می‌شود. شاید تعریف آن کمی پیچیده باشد؛ ولی به طور ساده روش فیلترینگ مشارکتی بر این فرض استوار است که کاربرانی که یک سری نظرهای مشابه درباره یک آیتم منظور از آیتم، فیلم، عکس، موزیک یا هر چیز دیگری است که پیشنهاد می‌شود دارند، درباره آیتم‌های دیگر هم نظرات مشابه دارند.

تجزیه و تحلیل یافته‌ها

مجموعه داده‌ها

در این مقاله، جهت ارزیابی مدل پیشنهادی از مجموعه داده دنیای واقعی MovieLens استفاده شده است. این مجموعه داده‌ها حاوی رأی‌هایی هستند که کاربران به فیلم‌های مختلف داده‌اند. اولویت‌دهی در مجموعه داده‌های MovieLens با افزایش یک ستاره، توسط مقیاس ۵ ستاره در نظر گرفته می‌شود که هر کاربر می‌تواند به هر فیلم رأی‌دهی کند. سه نسخه از این مجموعه داده‌ها به شرح زیر استفاده شده است که همگی این مجموعه داده‌ها آز آدرس <https://grouplens.org/datasets/movielens/> قابل دسترسی هستند.

- (۱) مجموعه داده‌های MovieLens Small شامل ۱۲ هزار رأی کاربران است که در آن به تعداد ۱۳۰۰ کاربر در مورد ۲۳۰۰ فیلم رأی‌دهی کرده‌اند.
- (۲) مجموعه داده‌های MovieLens Medium شامل حدود ۲ میلیون اولویت ناشناس است و اولویت‌دهی ۷۰۰۰ فیلم توسط ۱۱۰۰۰ کاربر را شامل می‌شود که هر کاربر حداقل ۱۸ مورد را رتبه‌بندی کرده است.
- (۳) مجموعه داده‌های MovieLens Large شامل ۱۸ میلیون رأی‌دهی است که ۱۶۸۰۰۰ کاربر در مورد ۱۹۰۰۰ فیلم انجام داده‌اند.

شبیه‌سازی روش پیشنهادی

برای شبیه‌سازی روش پیشنهادی از جعبه‌ابزار یادگیری عمیق در ابزار MATLAB بهره گرفته شده است. این نرم‌افزار بسیار مناسب انجام محاسبات عددی و یک زبان برنامه‌نویسی نسل چهارم است که دارای کاربری‌های اثبات شده حوزه پژوهش جاری و بسیاری از زمینه‌های دیگر مربوط به هوش مصنوعی و یادگیری ماشین و یادگیری عمیق است. جعبه‌ابزار یادگیری عمیق MATLAB، یک چارچوب یکپارچه و منسجم را برای طراحی و بهینه‌سازی انواع الگوریتم‌های یادگیری عمیق تهیه و ارائه کرده است. می‌توان از شبکه‌ها به انواع شبکه‌های برای آماده‌سازی و بهبودبخشی فرآیندهای رده‌بندی و رگرسیون اطلاعات، سری‌های زمانی و نوشتاری استفاده کرد و کاربردهای بسیار وسیعی در سایر حوزه‌های هوش مصنوعی و یادگیری ماشینی دارا است. برنامه‌های کاربردی و نمودارها در بصری‌سازی فعالیت‌ها، طراحی ساختارهای مرتبط با الگوریتم‌ها و نمایش آموزش در این جعبه‌ابزار موجود و قابل استفاده است.

معیارهای ارزیابی

بعد از بررسی در مراجع مختلفی که در زمینه کیفیت‌سنجی قوانین انجمنی وجود دارند ۲ متریک مورد انتخاب واقع شدند که در مورد آن‌ها، شرح ذکر می‌شود. قبل از ورود به بحث متریک‌های مذکور، یک سری پیش‌نیازها بیان می‌شود که در تمامی روش‌های سنجش کیفیت قواعد انجمنی، استفاده می‌شود. قواعد انجمنی به صورت $B \leftarrow H$ بیان می‌شوند و به این معنی است که اگر H در یک مجموعه آیتم ظاهر شود، آنگاه B نیز در آن مجموعه آیتم حضور پیدا می‌کند. شکل ۷ حالات حضور بخش مقدم و تالی قواعد را نشان می‌دهد.

	B	\bar{B}	
H	$n(HB)$	$n(\bar{HB})$	$n(H)$
\bar{H}	$n(\bar{HB})$	$n(HB)$	$n(\bar{H})$
	$n(B)$	$n(\bar{B})$	N

شکل ۷: حالات حضور بخش مقدم و تالی قواعد انجمنی

که در آن B شامل مواردی است که مقدم قانون، ظهور پیدا می‌کند؛ H شامل مواردی است که تالی قانون، ظهور پیدا می‌کند؛ \bar{B} شامل مواردی است که مقدم قانون، ظهور پیدا نمی‌کند و \bar{H} شامل مواردی است که تالی قانون، ظهور پیدا نمی‌کند. (X) تعداد اعضای موجود در مجموعه X را نشان می‌دهد و N نیز بیان گر تعداد کل داده‌های موجود در مجموعه داده‌ها است. بر این اساس، متريک‌های پوشش^۱ و حمایت^۲ به صورت زیر تعریف می‌شوند.

▪ پوشش

این متريک می‌سنجد که چه تعدادی از نمونه‌های ورودی به سистем که برای کشف قواعد در نظر گرفته شده‌اند، توسط تالی قانون پوشش داده می‌شوند. به عبارت دیگر با اين روش سنجدیده می‌شود که قانون موردنظر تا چه حد دارای عمومیت است. بیان رياضي اين روش به صورت رابطه (۱) تعریف می‌شود.

$$Cov(H \leftarrow B) = p(B) \quad (1)$$

▪ حمایت

این متريک، تعداد حضور و نرخ آن را برای مقدم و تالی قانون را با هم و به عنوان یک آيتم ست در مجموعه داده‌های ورودی می‌سنجد. در واقع اين روش مشخص می‌کند که اين قانون چقدر از مجموعه آيتم ست‌ها را حمایت می‌کند. بیان رياضي اين روش به شرح زير است. نكته مهم اين رابطه نسبت به مقدم و تالی قانون حالت تقارن دارد یا به عبارت دیگر Support یک قانون با معکوس آن مساوي است.

$$Sup(H \leftarrow B) = p(HB) \quad (2)$$

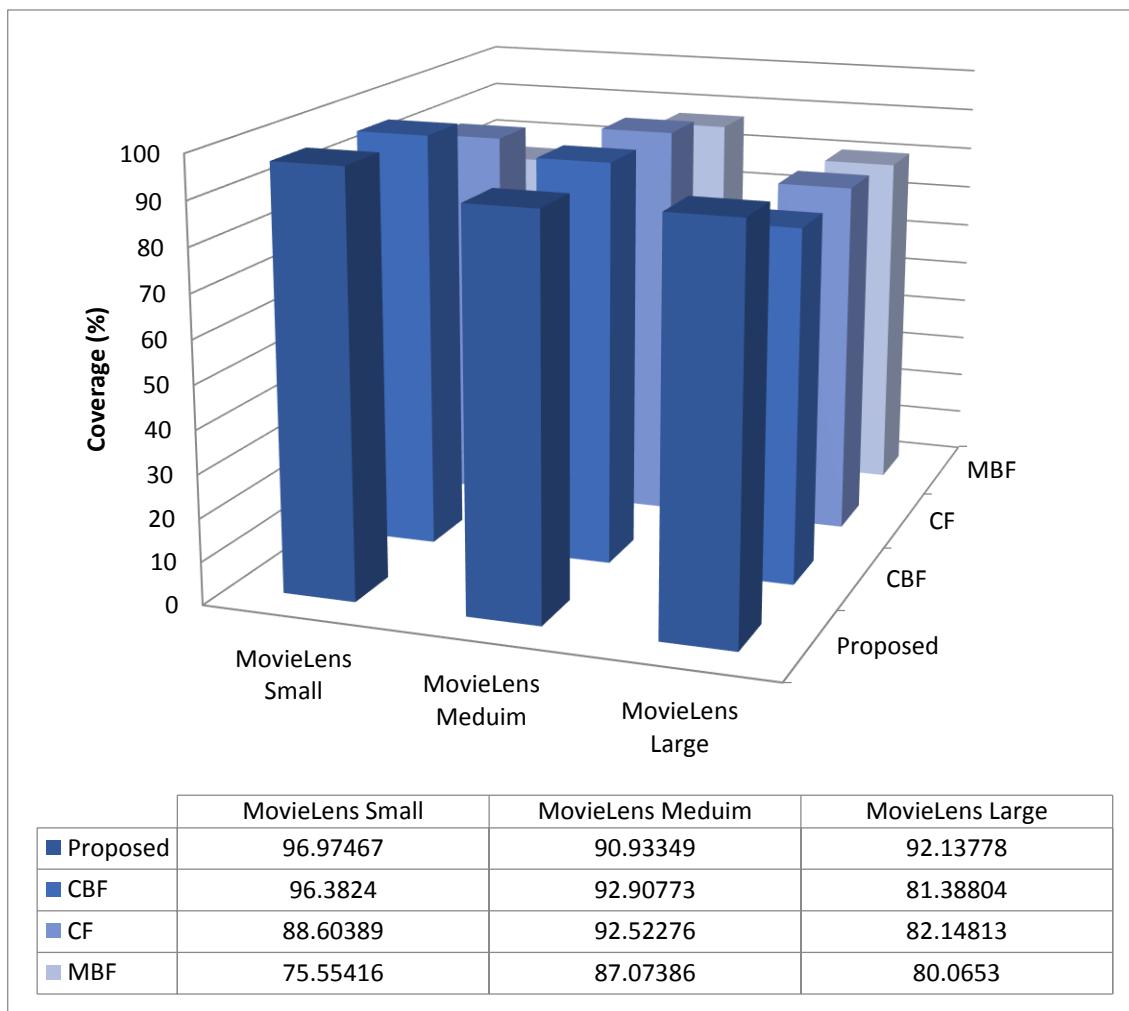
نتایج ارزیابی

برای سنجش نتایج حاصله از مقایسه روش پیشنهادی (Proposed) با سه روش فیلترینگ مبتنی بر محتوى (CFB)، فیلترینگ مبتنی بر حافظه (MBF) و فیلترینگ مشارکتی (CF) استفاده شده است. شکل ۸، مقایسه متريک پوشش نتایج به دست آمده از روش پیشنهادی نسبت به سایر روش‌های مورد مقایسه را به ازای هر مجموعه داده نشان می‌دهد. همان‌طور که قابل مشاهده است، روش پیشنهادی از نظر پوشش نسبت به سایر روش‌های مورد مقایسه، عملکرد بهتری را به نمایش گذاشته است. البته در بعضی در حالات نیز، سایر روش‌های مورد مقایسه تا حدی بهتر عمل کرده‌اند. در مجموعه داده‌های MovieLens Small روش پیشنهادی به همراه CBF بهترین عملکرد را داشته‌اند. در مجموعه داده‌های MovieLens Medium و CF روش‌های CF و CBF عملکرد بهتری داشته‌اند و روش MBF کمی ضعیفتر عمل کرده است. در مجموعه داده‌های MovieLens Large روش پیشنهادی با فاصله از سایر روش‌های مورد مقایسه بهتر عمل کرده و کارایی بهتری داشته و سایر روش‌های مورد مقایسه به میزان قابل توجهی عقب‌تر از روش پیشنهادی هستند.

1. Coverage

2. Support

3. Generality



شکل ۸: مقایسه متريک پوشش روش پيشنهادی با روش های مورد مقایسه

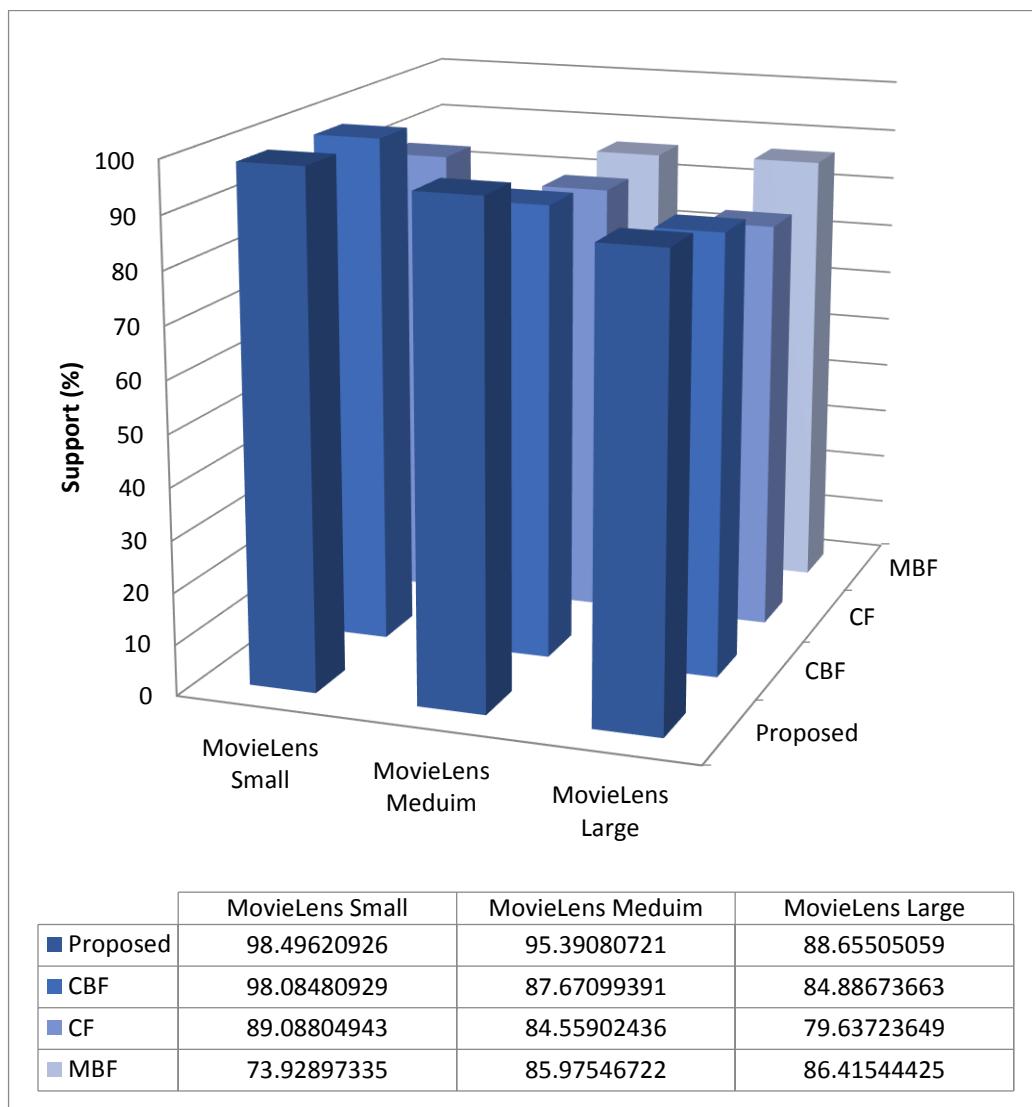
جدول ۱، ميانگين پوشش را برای روش های مختلف نشان می دهد و همان طور که مشهود است، روش پيشنهادی دارای ميانگين پوشش بهتری بوده است؛ روش CBF در رد بعدی عملکرد از نظر متريک پوشش قرار می گيرد و ساير روش ها نيز پس از اين دو قرار گرفته اند.

جدول ۱: مقایسه ميانگين پوشش روش پيشنهادی با ساير روش های مورد مقایسه

Proposed	CBF	CF	MBF
93.34864667	90.22605667	87.75826	80.89777333

شکل ۹، مقایسه متريک حمایت نتایج حاصله از روش پيشنهادی را نسبت به ساير روش های مورد مقایسه به ازاي هر مجموعه داده نشان می دهد. در مجموعه داده های MovieLens Small روش پيشنهادی به همراه CBF بهترین عملکرد را داشته اند و دو روش دیگر با فاصله پسا زاین دو قرار گرفته اند در مجموعه داده های MovieLens Medium روش پيشنهادی با فاصله از ساير روش های مورد مقایسه بهتر عمل کرده است. هر سه روش دیگر به ميزان قابل توجهی عقب تر از روش پيشنهادی هستند. در

مجموعه داده‌های MovieLens Large روش پیشنهادی عملکرد بهتری را نشان داده و با فاصله کمی از آن، روش MBF قرار دارد و دو روش دیگر نیز در رتبه‌های بعدی قرار می‌گیرند.



شکل ۹: مقایسه متریک حمایت روش پیشنهادی با روش‌های مورد مقایسه

جدول ۲، میانگین متریک حمایت را برای هریک از روش‌ها نمایش می‌دهد و همان‌طور که واضح است روش پیشنهادی نسبت به سایر روش‌ها عملکرد بهتری داشته است؛ پس از آن روش CBF و در رتبه‌های بعدی روش‌های CF و MBF عملکرد ضعیفتری داشته‌اند.

جدول ۲: مقایسه میانگین حمایت روش پیشنهادی با سایر روش‌های مورد مقایسه

Proposed	CBF	CF	MBF
94.18068902	90.21417994	84.42810343	82.10662827

نتیجه‌گیری و پیشنهادها

امروزه زندگی انسان در جوامع مختلف با انواع سیستم‌های تحت وب پیوند خورده است و بسیاری از امور روزمره مردم در تعامل با این سیستم‌ها شکل می‌گیرد. واضح است که حجم بسیار زیادی از اطلاعات در این سیستم‌ها موجود هستند که هر کاربر بسته به نیاز خود صرفاً به بخش مشخص و گزینش شده‌ای از این اطلاعات نیاز دارد تا امور روزمره خود را به انجام برساند. درواقع نیاز به بهبود روش پالایش مشارکتی به‌وضوح احساس می‌شود؛ بنابراین در این پژوهش با بهره‌گیری از تکنیک‌های یادگیری عمیق، روشی برای بهبود سیستم توصیه گر پالایش مشارکتی، با استفاده از استخراج عمیق ویژگی‌ها، ارائه شد تا بتواند پیشنهادهای مؤثرتر و مطلوب‌تری را به کاربر سیستم ارائه دهد. در این پژوهش، جهت ارزیابی مدل پیشنهادی از مجموعه داده دنیای واقعی MovieLens استفاده شده است. این مجموعه داده‌ها حاوی رأی‌هایی هستند که کاربران به فیلم‌های مختلف داده‌اند. اولویت‌دهی در مجموعه داده‌های MovieLens با افزایش یک ستاره، توسط مقیاس ۵ ستاره در نظر گرفته می‌شود که هر کاربر می‌تواند به هر فیلم رأی‌دهی کند. سه نسخه از این مجموعه داده‌ها استفاده شده است. برای سنجش نتایج حاصله، از مقایسه روش پیشنهادی با سه روش دیگر CBF، CF و MBF استفاده شده است. روش پیشنهادی از هر دو منظر پوشش و حمایت نسبت به سایر روش‌های مورد مقایسه، عملکرد بهتری را به نمایش گذاشته است. یکی از پژوهش‌های مرتبط که به عنوان پیشنهاد برای کارهای آتی این پژوهش می‌تواند مطرح باشد این است که در فیلترینگ تعاملی به صورت ترکیبی (هیبرید) با روش‌های دیگر استفاده شود. همچنین توسعه روش پیشنهادی جهت کاربرد در سیستم‌های موازی و توزیع شده نیز می‌تواند به عنوان نقاط گسترش روش پیشنهادی باشد.

منابع

- Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-based systems*, 46, 109-132.
- Camacho, L. A. G., & Alves-Souza, S. N. (2018). Social network data to alleviate cold-start in recommender system: A systematic review. *Information Processing & Management*, 54(4), 529-544.
- Dami, S., & Yahaghizadeh, M. (2018, February). Efficient event prediction in an IOT environment based on LDA model and support vector machine. In 2018 6th Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS) (pp. 135-138). IEEE.
- Dami, S., Shirazi, H., & Hoseini, M. (2013). A Data Mining Model for Anomaly Detection of Satellite Launch Vehicle. *journal of Advanced Defense Science and Technology*, 4(1), 51-63.
- Dami, S. (2016). News Events Prediction Based on Casual Inference in First-Order Logic (FOL). *Journal of Soft Computing and Information Technology*, 5(4), 11-25.
- Fan, C., & Mostafavi, A. (2019). A graph-based method for social sensing of infrastructure disruptions in disasters. *Computer-Aided Civil and Infrastructure Engineering*, 34(12), 1055-1070.
- Hua, C., Wang, H., Wang, H., Lu, S., Liu, C., & Khalid, S. M. (2019). A novel method of building functional brain network using deep learning algorithm with application in proficiency detection. *International journal of neural systems*, 29(01), 1850015.
- Karim, M. R., Beyan, O., Zappa, A., Costa, I. G., Rebholz-Schuhmann, D., Cochez, M., & Decker, S. (2021). Deep learning-based clustering approaches for bioinformatics. *Briefings in Bioinformatics*, 22(1), 393-415.
- Khalla, R., & Khalla, M. (2021). Classification and analysis of deep learning applications in construction: A systematic literature review. *Automation in construction*, 129, 103760.
- Koren, Y., Rendle, S., & Bell, R. (2022). Advances in collaborative filtering. *Recommender systems handbook*, 91-142.
- Liu, X., & Cheung, Y. M. (2018). On incremental collaborative appearance model and regional particle filtering for lip region tracking. *Integrated Computer-Aided Engineering*, 25(1), 63-80.
- Ou-Yang, L., Lu, F., Zhang, Z. C., & Wu, M. (2022). Matrix factorization for biomedical link prediction and scRNA-seq data imputation: an empirical survey. *Briefings in Bioinformatics*, 23(1), bbab479.
- Sethi, R., & Mehrotra, M. (2021). Cold start in recommender systems—a survey from domain perspective. In *Intelligent Data Communication Technologies and Internet of Things* (pp. 223-232). Springer, Singapore.
- Shao, B., Li, X., & Bian, G. (2021). A survey of research hotspots and frontier trends of recommendation systems from the perspective of knowledge graph. *Expert Systems with Applications*, 165, 113764.

Zhang, N, Ding, S, Zhang, J, & Xue, Y. (2018). An overview on restricted Boltzmann machines. Neurocomputing, 275, 1186-1199.