

A Novel Movie Recommendation System with Iterated Truncated Singular Value Decomposition (ITSVD)

Nozar Ebrahimi
Lame 

PhD student of Department of Management Information Systems, Qazvin Branch, Islamic Azad University, Qazvin, Iran

Fatemeh Saghafi *

Associate professor of Faculty of Management, University of Tehran, Tehran, Iran.

Majid Gholipour 

Assistant Professor of Faculty of Electrical and Computer Engineering, Islamic Azad University, Qazvin Branch, Qazvin, Iran

Abstract

Recommendation systems are one of the most essential tools for e-commerce intelligence. These systems with different types of data filtering methods are able to offer the best recommendations from a multitude of selectable items. Collaborative Filtering is the most widely used method of filtering data to make recommendations. One of the advanced models for predicting ratings in the Collaborative Filtering is the Singular Value Decomposing (SVD). In this paper, an optimized model of the film recommending system based on the SVD method is developed, which while reducing the dimensions of the matrices and the volume of computations and memory, and with iteration replacement method, has appropriate accuracy compared with other methods. For this research, a set of 100k Movie Lens datasets and Python programming have been used. Evaluation of error rate with root mean square error (RMSE) and mean absolute error (MAE) value shows a good improvement over similar methods in other references.

Keywords: Recommendation System, Collaborative Filtering, Singular Value Decomposition, Ratings Prediction.

* Corresponding Author: : Fatemeh Saghafi, fsaghafi@ut.ac.ir

How to Cite: Ebrahimi Lame, N., Saghafi, F., Gholipour, M. (2022). A Novel Movie Recommendation System with Iterated Truncated Singular Value Decomposition (ITSVD), *Journal of Business Intelligence Management Studies*, 10(38), 173-199.

سیستم توصیه‌گر فیلم ابتكاری با استفاده از روش تجزیه ماتریس به مقادیر منفرد با ابعاد کاهش یافته تکرار شده

دانشجوی دکتری گروه مدیریت سیستم‌های اطلاعاتی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.

نوذر ابراهیمی لامع 

دانشیار گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.

* فاطمه ثقفی 

استادیار دانشکده برق و رایانه، دانشگاه آزاد اسلامی واحد قزوین، قزوین، ایران.

مجید قلی پور 

چکیده

سیستم‌های توصیه‌گر یکی از ضروری ترین ابزارهای هوشمندسازی تجارت الکترونیک است. این سیستم‌ها با انواع مختلف روش‌های فیلتر کردن داده‌ها و داده‌کاوی، قادر به انتخاب و ارایه بهترین پیشنهادات از بین انبوی موارد قابل انتخاب برای مشتریان هستند. در بین روش‌های متنوع سیستم‌های توصیه‌گر، فیلترهای اشتراکی پرکاربردترین روش برای ارایه پیشنهادات است. فیلترهای اشتراکی دامنه وسیعی از الگوریتم‌ها را شامل می‌شود و در این بین، روش تجزیه ماتریس به مقادیر منفرد یکی از مدل‌های پیشرفته در فیلتر اشتراکی است. در این مقاله به ارایه مدلی بهینه شده از سیستم توصیه‌گر فیلم مبتنی بر روش تجزیه مقادیر منفرد پرداخته شده که ضمن کاهش ابعاد ماتریس و کاهش حجم محاسبات و حافظه، با روش تکرار جاگذاری، دارای دقت مناسب نسبت به روش تجزیه ماتریس به مقادیر منفرد ساده و سایر روش‌های دیگر است. برای این پژوهش از مجموعه دیتابست‌های ۱۰۰ هزار امتیازی مولوی لنز و از برنامه نویسی پایتون

مقاله حاضر برگرفته از رساله دکتری رشته مدیریت فناوری اطلاعات گرایش کسب و کار هوشمند دانشگاه آزاد واحد قزوین است.

Fatemeh Saghafi, fsaghafi@ut.ac.ir 

استفاده شده است. ارزیابی میزان خطای جذر میانگین مربعات خطای و میانگین قدر مطلق خطای نشان از بهود مناسب نسبت به روش‌های مشابه در مراجع دیگر دارد.

کلیدواژه‌ها: سیستم‌های توصیه‌گر، فیلتر اشتراکی، تجزیه مقادیر منفرد، پیش‌بینی امتیازات.

مقدمه

در دهه‌های اخیر، با توسعه وب‌سایت‌ها و شبکه‌های اینترنتی، تجارت الکترونیک نیز توسعه فراوانی یافته و تبدیل به بخش مهمی از تجارت جهانی شده‌است (محمدی و همکاران، ۱۳۹۹). تجارت الکترونیک فروشنده‌گان را قادر می‌سازد تا حجم انبوهی از کالا و خدمات را در وب‌سایت‌های خود به مشتریان ارایه نمایند، ولی انتخاب کالا و خدمات مناسب از بین حجم زیادی از موارد عرضه شده، نیازمند سیستم‌های نرم‌افزاری است که بر مبنای مشخصات و سلیقه مشتریان، قادر به پیشنهاد بهترین موارد باشد. در اینصورت در وقت مشتریان صرفه جویی شده و میزان فروش نیز افزایش خواهد یافت. این سیستم‌ها را سیستم‌های توصیه‌گر می‌نامند. سیستم‌های توصیه‌گر، نرم افزارهایی ضروری برای فیلتر کردن داده‌ها و ارایه پیشنهادات متناسب با سلاطیق و علاقه مشتریان هستند. این سیستم‌ها برای اولین بار در اوایل دهه ۱۹۹۰ میلادی مورد استفاده قرار گرفتند (Guan et al., 2014؛ Guan et al., 2021).

وظیفه اصلی سیستم‌های توصیه‌گر، ارایه پیشنهادات متناسب برای هر شخص و بصورت شخصی می‌باشد. به عبارت دیگر، وب‌سایت‌ها برای هر مشتری محصولات مشخصی را نمایش می‌دهند (ویترین شخصی). این روش ارائه پیشنهادات را شخصی‌سازی پیشنهادات می‌نماید. شخصی‌سازی^۱ پیشنهادات باعث افزایش جذب و وفاداری مشتریان و همچنین افزایش فروش وب‌سایتها می‌گردد (Zhang et al., 2020؛ Alamdar et al., 2020؛ Rghuwanshi & Pateriya, 2019؛ Lekakos & Caravelas, 2008، 2019؛ Guan et al., 2017). سایت‌های معتبری مانند آمازون^۲، ای‌بی^۳، نتفلیکس^۴، علی‌باپا^۵ در سطح بین‌المللی و سایت‌هایی مانند دیجی‌کالا، دیوار، باما، نمایا و فیلمیو در سطح کشور از سیستم‌های توصیه‌گر بصورت گسترده‌ای استفاده می‌نمایند.

-
1. Personalization
 2. Amazon
 3. eBay
 4. Netflix
 5. Alibaba

برای تولید سیستم‌های توصیه‌گر، لازم است از مجموعه داده‌های موجود در مورد مشخصات مشتریان، مشخصات کالاها، سابقه کالاها خریداری شده قبلی و همچنین نظر و امتیازات کاربران به کالاها استفاده نمود. این امر به کمک روش‌های مختلف پالایش داده و داده کاوی روی داده‌های کلان^۱ انجام است (Aggarwal, 2016).

پرکاربردترین روش پالایش داده‌ها در سیستم‌های توصیه‌گر، روش فیلتر اشتراکی^۲ است. در این روش از ماتریس امتیازات برای توصیه آیتم‌ها به استفاده می‌شود. فیلترهای اشتراکی دو نوع می‌باشند. فیلتر اشتراکی حافظه محور^۳، که با استفاده از امتیازات کاربران و تشابه بین کاربران یا آیتم‌ها با یکدیگر، کار می‌کنند و سیستم مدل محور^۴، که بر اساس مدل ارایه شده نسبت به پیش‌بینی امتیازات کاربران با استفاده از روش‌های متنوع یادگیری ماشین کار می‌کنند (Guan et al., 2017; Aggarwal, 2016; Ahuja et al., 2019). یکی دیگر از روش‌های پالایش داده‌ها، روش محتوا محور است. در این روش از خصوصیات آیتم‌های مورد علاقه کاربر استفاده می‌شود تا آیتم‌های مشابه به او پیشنهاد شود (Guan et al., 2017). با توجه به اینکه سیستم‌های توصیه‌گر با داده‌های کلان سر و کار دارند و از طرفی حجم امتیازات در مقابل تعداد کاربران و آیتم‌ها بسیار اندک است (ماتریس امتیازات خالی^۵، بنابراین تهیه سیستم توصیه‌گر با دقت مناسب و غلبه بر خالی بودن ماتریس امتیازات، از مشکلات اصلی روش فیلتر اشتراکی است. در سیستم‌های توصیه‌گر فیلتر اشتراکی، استفاده از روش‌های خوشبندی مانند نزدیکترین همسایه‌ها^۶، روش‌های یادگیری ماشین^۷ و تجزیه ماتریس^۸، جهت افزایش دقت پیشنهادات و کاهش حجم محاسبات، از روش‌های پرکاربرد می‌باشند و در این بین، روش تجزیه ماتریس به

1. Big Data
2. Collaborative Filtering
3. Memory Based
4. Model Based
5. Sparse Ratings Matrix
6. K Nearest Neighbors (KNN)
7. Machine Learning Methods
8. Matrix Factorization (MF)

مقدادیر منفرد^۱ نسبت به روش متداول نزدیکترین همسایه‌ها، دارای دقت بیشتری بوده و همچنین با روش‌های کاهش ابعاد ماتریس، امکان کاهش حجم محاسبات نیز وجود دارد (Falk, 2019; Aggarwal, 2016). روش سوم پالایش داده‌ها، استفاده از ترکیب دو روش فیلتر اشتراکی و فیلتر محظوظ محور است که به آن فیلتر ترکیبی^۲ می‌گویند (Guan et al., 2017; Rahul et al., 2020).

طی سه دهه گذشته، روش‌های بسیار زیادی برای سیستم‌های توصیه‌گر توسعه یافته‌اند و یکی از اتفاقات تاثیرگذار در این زمینه، مسابقه یک میلیون دلاری شرکت تولید و توزیع فیلم نتفلیکس^۳ با هدف ارتقاء دقت پیشنهادات با روش فیلتر اشتراکی بود (سایت نتفلیکس^۴).

امروزه سیستم‌های توصیه‌گر تقریباً در تمام شقوق تجارت الکترونیک جایگاه ارزشمندی دارند و در این بین، به جهت گستردگی دامنه مخاطبان و جنبه سرگرمی و تفریحی محصولات رسانه‌ای، استفاده از سیستم‌های توصیه‌گر جهت توصیه محصولات رسانه‌ای مانند کتاب، خبر، موزیک، سرگرمی، مجله و فیلم بسیار پر کاربرد است (Choi, et. al., 2012). به همین دلیل، در این پژوهش بر روی موضوع فیلم که دارای تعدد در فیلم‌ها و کاربران است، کار شده‌است. بررسی علمداری و همکاران^۵ (2020)، بر روی مقالات منتشر شده با جستجوی کلمات کلیدی "سیستم‌های توصیه‌گر"^۶ و "تجارت الکترونیک"^۷ توسط جستجوگر گوگل اسکولار^۸ نشان می‌دهد از بین ۳۵۸ مقاله یافت شده در این موضوعات، ۲۸۹ مورد آن (بیش از ۸۰٪) بین سال‌های ۲۰۰۸ تا ۲۰۱۹ انتشار یافته‌اند که نشانگر فعال بودن موضوع پژوهش است. البته برخلاف چنین سابقه‌ای در دنیا،

1. Singular Value Decomposition (SVD)

2. Hybrid Filtering

3. Netflix

4. Netflix Prize Site

5 Alamdar et al.

6. Recommendation Systems/Recommender System

7. e-commerce

8 Google Scholar

تعداد کارهای پژوهش‌هایی در زمینه سیستم‌های توصیه‌گر در داخل کشور محدود بوده و در زمینه سیستم‌های توصیه‌گر فیلم، نتایج جستجو در گوگل اسکولار، ایران داک^۱ و مگیران^۲ و با کلمات کلیدی "سیستم‌های توصیه‌گر فیلم" و "سیستم‌های پیشنهاد دهنده فیلم"، منجر به یافتن تعداد فقط پنج مقاله به زبان فارسی شد که به عنوان نمونه می‌توان به حیدری و پروین نیا (۱۳۹۶) اشاره نمود. البته شرکت‌های داخلی بسیار زیادی مانند دیجی‌کالا، نماوا و فیلیمو از سیستم‌های توصیه‌گر استفاده می‌کنند ولی در خصوص روش‌های بکارگرفته شده و میزان دقต و کارائی آنها مطالب اندکی ارایه شده‌است. در این خصوص، می‌توان به سیستم توصیه‌گر شرکت فیلیمو به عنوان یکی از کارهای ارزنده و به روز اشاره کرد که حاصل کار تیمی است (واهب، ۱۳۹۹).

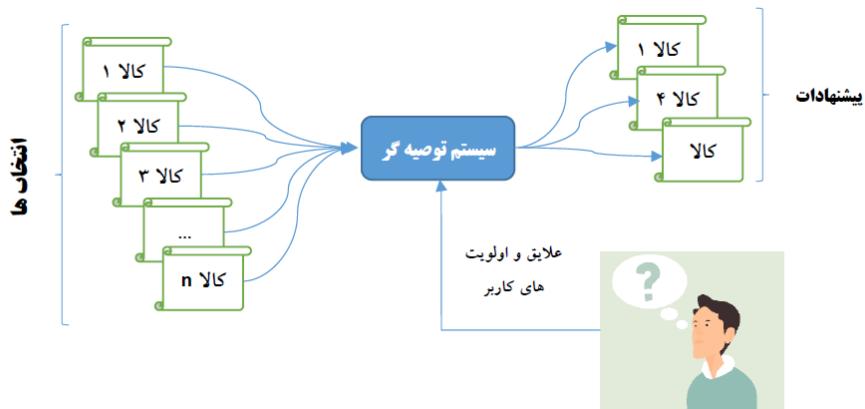
در این مقاله مدل بهینه شده‌ای از سیستم توصیه‌گر فیلم با روش تجزیه ماتریس به مقادیر منفرد ارایه شده‌است که با استفاده از سه روش مختلف، برای حجم محاسبات و خطای امتیازات پیش‌بینی شده کاهاش قابل ملاحظه‌ای حاصل شده‌است و خطای بدست‌آمده نسبت به موارد مشابه دارای دقت بهتری می‌باشد. در ادامه مقاله، به مرور ادبیات و پیشینه پژوهش، ارایه روش پژوهش، یافته‌های پژوهش و بحث در مورد نتایج پژوهش خواهیم پرداخت.

پیشینه پژوهش

وظیفه اصلی سیستم‌های توصیه‌گر پالایش حجم انبوهی از داده‌ها و پیشنهاد محصولات متناسب با علائق و سلایق کاربر است. شکل (۱) سیستم‌های توصیه‌گر را بصورت شماتیک نمایش می‌دهد.

1. Irandoc

2. Magiran



شکل ۱. سیستم توصیه‌گر

در مجموع پنج نوع سیستم توصیه‌گر وجود دارد (Aggarwal, et.al., 2020; Alamdari, et.al., 2016; Choi, et. al., 2012, 2016) که سه نوع آن متدائل و پرکاربرد است. روش اول، سیستم توصیه‌گر فیلتر محتوا محور^۱ است که از تشابه بین ویژگی‌های آیتم‌ها برای ارایه پیشنهاد استفاده می‌کند. این روش سریع است ولی از چالش‌هایی مانند کمبود اطلاعات در مورد آیتم‌ها و دقت پایین رنج می‌برد. روش دوم، سیستم توصیه‌گر فیلتر اشتراکی است که با استفاده از ماتریس امتیازات، از تشابه بین کاربران و یا آیتم‌ها برای ارایه پیشنهاد استفاده می‌کند. چالشهای اصلی روش‌های فیلتر اشتراکی، شروع سرد کاربر^۲ و ماتریس خالی می‌باشد. این روش، پر کاربردترین روش برای ارایه سیستم‌های توصیه‌گر است. روش‌های فیلتر اشتراکی خود به دو دسته فیلتر اشتراکی حافظه محور و فیلتر اشتراکی مدل محور تقسیم می‌شوند. روش سوم، سیستم توصیه‌گر ترکیبی است که برای استفاده از مزایای روش‌های مختلف و کاهش معایب آنها، از ترکیب روش‌های دیگر استفاده می‌کند. دو روش فیلتر جمعیتی محور^۳ و فیلتر دانش محور^۴ با توجه به کاربردهای خاص آنها، جزء

-
1. Content Based Filtering
 2. Cold Start
 3. Demographic Based Filtering
 4. Knowledge Based Filtering

روش‌های متدالول نمی‌باشند (Aggarwal, 2016). جدول (۱) اهداف مفهومی و ورودی های هر یک از روش‌های پایه را بصورت خلاصه نشان می‌دهد. آگاروال (2016) معتقد است اگر چه اصلی ترین هدف از بکارگیری سیستم‌های توصیه‌گر، افزایش فروش محصولات است و این هدف با ارایه پیشنهادات مناسب به کاربران و جلب توجه آنها میسر می‌شود، ولی برای رسیدن به هدف مذکور لازم است در طراحی سیستم‌های توصیه‌گر و ارایه پیشنهادات، موارد و اهداف فنی مهمی دیگری مانند مرتبط بودن^۱، تازگی^۲، پیشنهادات غیرمنتظره^۳ و تنوع^۴ پیشنهادات نیز در نظر گرفته شود (ابراهیمی و همکاران، ۱۳۹۸).

جدول ۱. اهداف مفهومی انواع سیستم‌های توصیه‌گر پایه

نوع فیلتر	روش کار	ورودی اصلی	چالش‌های اصلی	مزیت‌ها
محتو雅 محور	تشابه بین آیتم‌ها	امتیاز کاربران و مشخصات آیتم‌ها	دقت پائین	سرعت و سادگی پیاده سازی
اشتراکی	تشابه بین کاربران	امتیازات کاربران	خالی بودن امتیازات و شروع سرد	دقت بالای پیشنهادات
ترکیبی	ترکیب روش‌های مختلف	اطلاعات روش‌های مختلف	زمان زیاد، هزینه بالا، امنیت	دقت بالا و امکان رفع چالش‌های گوناگون

نکته مهمی که در طراحی سیستم‌های توصیه‌گر باید در نظر گرفته شود اینست که هر یک از روش‌های پالایش داده‌ها، دارای چالش‌های مخصوص به خود می‌باشند. مهم ترین چالش‌هایی که معمولاً این سیستم‌ها با آنها مواجه می‌شوند عبارتند از: دشواری استخراج محتو雅، شروع سرد، خالی بودن ماتریس امتیازات، مقیاس پذیری، حفظ حریم خصوصی و کلمات مترادف (Choi, et. al., 2019; Aggarwal, 2016; Rghuwanshi & Pateriya, 2012). از این‌رو لازم است روش‌های انتخابی برای ارایه پیشنهادات، قادر به برطرف

-
1. Relevance
 2. Novelty
 3. Serendipity
 4. Diversity

نمودن چالش های مذکور باشد. همچنین نکته مهمی که در طراحی سیستم های توصیه گر باید در نظر داشت اینست که هیچ یک از روش ها به تنهایی قادر به برطرف نمودن همه چالش های مذکور نمی باشد. لذا برای انتخاب روش مناسب لازم است مواردی مانند مشخصات آیتم ها و کاربران و اطلاعات موجود از آنها در نظر گرفته شود و با بررسی روش های مختلف نسبت به انتخاب روش بهینه با بیشترین دقت و کمترین هزینه از نظر حجم عملیات، حجم حافظه و میزان سخت افزار مورد نیاز اقدام شود (Alamdari, et.al., 2016, 2020).

روش تجزیه ماتریس امتیازات به مقادیر منفرد

روش های بسیار زیادی در زمینه سیستم های توصیه گر فیلتر اشتراکی وجود دارد و همچنان در حال تکامل است. از روش های مرسوم در این زمینه می توان به روش محاسبه همبستگی بین کاربران با روش هایی مانند ضرب همبستگی پیرسون یا کسینوسی، استفاده از خوشه بندی همسایه ها^۱ و میانگین امتیازات آنها^۲، استفاده از شبکه های عصبی و روش تجزیه ماتریس به حاصلضرب چند ماتریس نام برد. روش تجزیه ماتریس به عوامل نهانی^۳ یکی از الگوریتم های فیلتر اشتراکی است که کاربرد آن در سیستم های توصیه گر پس از مسابقه نتفلیکس مورد توجه قرار گرفت و با توجه به دقت مناسب آن در پیش بینی امتیازات و همچنین امکان کاهش ابعاد ماتریس ها، برای سیستم های توصیه گر کاربردهای فراوانی پیدا نمود. این روش، سابقه کاربرد در موارد دیگری را داشته ولی برای اولین بار توسط سیمون فانک^۴ برای سیستم های توصیه گر استفاده شد و مبنایی برای روش های بهبود یافته دیگر گردید (Falk, 2019).

بر مبنای آگاروال (2016)، فالک (2019) و آندریاس (2017)، در روش تجزیه ماتریس، یک ماتریس با ابعاد بزرگ به حاصلضرب چند ماتریس با ابعاد کوچکتر تبدیل

1. K Nearest Neighbors (KNN)

2. K_Means

3. Latent Factors

4. Simon Funk

می‌شود. روش‌های مختلفی برای تجزیه یک ماتریس وجود دارد که از بین آنها روش تجزیه ماتریس به سه ماتریس (تجزیه به مقادیر منفرد)، تجزیه به دو ماتریس^۱، تجزیه و تحلیل عوامل^۲ و تجزیه و تحلیل عوامل اصلی^۳ جزئ روش‌های پرکاربرد می‌باشند (Andreas, 2017). در این پژوهش به جهت قابلیت‌های مهم روش تجزیه به مقادیر منفرد از جهت امکان کاهش ابعاد ماتریس‌های سه گانه و تقریب مناسب و جدید بودن، از این روش استفاده شده است.

مبانی روش تجزیه ماتریس

اگر R ، ماتریس امتیازات کاربران به فیلم‌ها با ابعاد $m \times n$ باشد که در آن m تعداد کاربران (سطرهای) و n تعداد فیلم‌ها (ستون‌ها) باشد شکل (۲)، در اینصورت هدف از تجزیه ماتریس R ، پیداکردن دو ماتریس U و V به چگونه‌ای است که حاصل ضرب دو ماتریس در هم ماتریس R را با تقریب مناسبی بازسازی نماید. یعنی:

$$R_{m \times n} \approx U_{m \times k} V^T_{k \times n} \quad (1)$$

بنابراین برای بدست آوردن مقدار امتیاز کاربر i به آیتم j می‌توان از رابطه زیر استفاده نمود:

$$r_{ij}^* = u_i v_j^T = \sum_{k=1}^k u_{ik} v_{kj} \quad (2)$$

شکل (۲) نشان می‌دهد چگونه ماتریس امتیازات R به دو ماتریس U و V^T تجزیه شده است. لازم به ذکر است اگر ماتریس دارای مقادیر نامعلوم باشد، حاصل ضرب دو ماتریس تقریبی از ماتریس R را خواهد داد.

-
1. QR Decomposition
 2. Factor Analysis (FA)
 3. Principal Component Analysis (PCA)

$$\begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1} & r_{m2} & \cdots & r_{mn} \end{bmatrix} = \begin{bmatrix} u_{11} & u_{12} & \cdots & u_{1k} \\ u_{21} & u_{22} & \cdots & u_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ u_{m1} & u_{m2} & \cdots & u_{mk} \end{bmatrix} \times \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1n} \\ v_{21} & v_{22} & \cdots & v_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ v_{k1} & v_{k2} & \cdots & v_{kn} \end{bmatrix}^T$$

R **U** **V**

شکل ۲. تجزیه ماتریس به دو ماتریس

برای بدست آوردن مقادیر ماتریس های U و V ابتدا مقادیر اولیه تصادفی ای برای سلول های آنها تعیین می شود و پس از حاصلضرب دو ماتریس، اختلاف بین مقادیر حاصل ضرب و مقادیر واقعی در ماتریس R محاسبه می شود. سپس با روش گرادیان کاهشی^۱ نسبت به حداقل نمودن خطا اقدام می گردد. در روش گرادیان کاهشی هدف حداقل نمودن مقدار خطا است. برای اینکار، لازم است مجذور تفاضل مقادیر واقعی و پیش بینی حداقل گردد. در اینحالتتابع گرادیان کاهشی بصورت زیر خواهد شد:

$$\min J = \frac{1}{2} \left(\sum_{(i,j) \in R}^n (r_{i,j} - u_i v_j^T)^2 + \lambda (\|u_i\|^2 + \|v_j\|^2) \right) \quad (3)$$

در رابطه فوق:

$r_{i,j}$: مقدار واقعی، $u_i v_j^T$: مقدار تقریبی، $\|u_i\|^2$ و $\|v_j\|^2$: مقدار اندازه بردارهای u و v و λ : مقدار پارامتر تنظیم است.

از طرفی، برای ارزیابی میزان دقت حاصل از تجزیه ماتریس برای پیش بینی مقادیر نامعلوم و جلوگیری از بیش برازش مدل، لازم است ماتریس امتیازات به دو ماتریس آموزش و تست با نسبت مناسب تقسیم شود. سپس، نسبت به تجزیه ماتریس آموزش و تعیین مقادیر نامعلوم اقدام می شود. در مرحله بعد، با استفاده از مقادیر تقریبی بدست آمده از تجزیه ماتریس امتیازات، مقادیر واقعی داده های تست و مقادیر تقریبی بدست آمده با

1. Decent Gradient

هم مقایسه می‌شوند و با استفاده از روش‌های ارزیابی RMSE و MAE، میزان خطای مدل محاسبه می‌شود. برای محاسبه خطاهای مذکور از روابط زیر استفاده می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (r_i - p_i)^2}{n}} \quad (4)$$

$$MAE = \frac{\sum_{i=1}^n |r_i - p_i|}{n} \quad (5)$$

در روش تجزیه ماتریس به مقادیر منفرد که دارای کاربردهای فراوانی در کاهش ابعاد^۱، فشرده سازی تصاویر^۲ و نادیده گرفتن داده‌های نویز^۳ دارد، یک ماتریس بجای دو ماتریس به سه ماتریس U، S و V بصورت زیر تجزیه می‌شود:

$$R_{m \times n} = U_{m \times p} * S_{p \times p} * V_{p \times n}^T \quad (6)$$

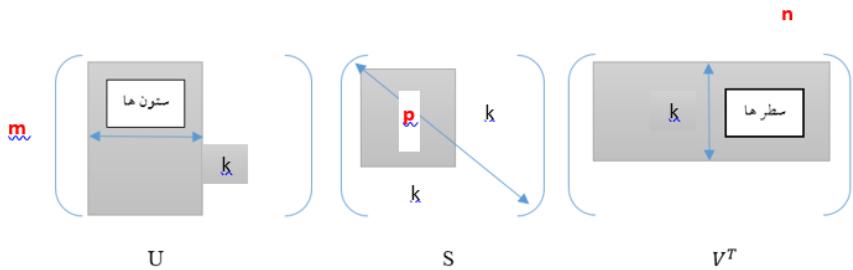
که در آن ماتریس U، ماتریس متعاملی است که به آن ماتریس عوامل نهانی^۴ کاربر می‌گویند و خصوصیات کاربران را بصورت فشرده و ترکیبی نمایش می‌دهد. ماتریس S مقادیر منفرد ماتریس امتیازات R است و ماتریس V نیز ماتریس متعاملی است که به آن ماتریس عوامل نهانی آیتم‌ها می‌گویند و خصوصیات آیتم‌ها (محصولات) را بصورت ترکیبی و فشرده در خود دارد. نهانی بودن عوامل فوق به این معنی است که توسط مدل محاسبه و تعیین می‌شود و در تعیین آنها، انسان نقشی ندارد. همچنین لازم به ذکر است مقادیر عوامل نهانی اغلب قابل تفسیر و توضیح نمی‌باشند.

در این روش، هر دو ماتریس U و V متعامد می‌باشند و ماتریس S یا سیگما، ماتریس قطری است که مقادیر منفرد آن بصورت نزولی بر روی قطر اصلی ماتریس چیده شده و اندازه این مقادیر نشان می‌دهد هر یک از مقادیر حاوی چه مقدار اطلاعات می‌باشند. برای

-
1. Dimensionality Reduction
 2. Image Compression
 3. Noising Data
 4. Latent Factors

کاهش همانطور که در معادله (۶) دیده می‌شود، مقدار بعد p ، هایپر پارامتر است و قابل تعیین است. لذا در تعیین این مقدار می‌توان مقدار بهینه‌ای را طوری انتخاب کرد که ابعاد سه ماتریس U ، S و V^T کاهش یافته و مقدار خطا نیز حداقل شود. برای اینکار لازم است میزان خطا به ازای مقادیر مختلف p محاسبه شود و مقدار بهینه انتخاب شود. در حقیقت میزان کاهش ابعاد ماتریس‌ها بر اساس تعداد مقادیر انتخاب شده از ماتریس S تعیین می‌شود. شکل (۳) این حالت را نمایش می‌دهد. (Aggarwal, 2016; Falk, 2019).

شکل (۳)، ماتریس R_{m*n} به کمک روش تجزیه به مقادیر منفرد به حاصلضرب سه ماتریس $R = U S V^T$ تبدیل می‌شود که در آن p تعداد مقادیر منفرد غیر صفر ماتریس R است. حال اگر تعداد k مقدار منفرد حفظ و بقیه برابر صفر قرار داده شود، در اینصورت ماتریس‌های فوق به صورت U_{m*k} ، S_{k*k} و V^T_{k*n} کاهش ابعاد خواهند یافت که در آنها $k \leq p$ است.



شکل ۳. نمایش نحوه کاهش ابعاد ماتریس با استفاده از روش SVD

پیشینه پژوهش

هر چند مبانی ریاضی و کاربردهای روش تقریب ماتریس از طریق تجزیه به مقادیر منفرد از سالیان دور مورد استفاده بوده است، ولی استفاده از روش تجزیه مقادیر منفرد برای سیستم‌های توصیه‌گر، اولین بار توسط سیمون فانک و در جریان مسابقه شرکت نتفلیکس مورد توجه قرار گرفت. این روش در مسابقه نتفلیکس رتبه سوم را کسب کرد، ولی به جهت مزایای آن به سرعت به یکی از روش‌های پر طرفدار در سیستم‌های توصیه‌گر تبدیل

شد (Falk, 2019). در سال‌های بعد، پژوهش‌های متعددی در خصوص ارایه راهکارهایی برای ارایه سیستم‌های توصیه‌گر بر این مبنای توسعه داده شد که در زیر به برخی از آنها اشاره می‌شود. لی و همکاران^۱ (2020) در پژوهش خود روشی تحت عنوان "فیلتر کردن مبتنی بر دسته‌های فیلم- تجزیه مقادیر منفرد"^۲ را برای پیش‌بینی امتیازات کاربران فعال، به فیلم‌ها بر مبنای داده‌های صریح^۳ و ضمنی^۴ ناشی از دیتابست فیلم‌ها ارایه می‌دهند. در ابتدا، روش فوق از عوامل وزن دار برای بررسی اثر انواع دسته بندی فیلم بر روی پیش‌بینی امتیازات کاربران و همچنین ارتقا روش پالایش بر مبنای دسته بندی فیلم‌ها استفاده می‌کند. در نهایت، روش فیلتر کردن مبتنی بر دسته‌های فیلم با الگوریتم تجزیه ماتریس به مقادیر منفرد^۵ ترکیب می‌شود تا از عملکرد خوب آن در فیلتر اشتراکی استفاده نماید. در مقایسه با انواع الگوریتم‌های مختلف موجود، روش پیشنهادی به میزان قابل توجهی دقت پیش‌بینی امتیازدهی را ارتقاء می‌بخشد و مقیاس پذیری و اثربخشی سیستم‌های توصیه‌گر شخصی را افزایش می‌دهد. ژو و همکاران^۶ (2015) یک الگوریتم تدریجی^۷ مبتنی بر تجزیه مقادیر منفرد با مقیاس پذیری مناسبی را پیشنهاد داده اند که ترکیبی از الگوریتم تجزیه مقادیر منفرد تدریجی و الگوریتم تقریب مقدار تجزیه مقادیر منفرد است. تجزیه و تحلیل دقیق خطاب، اثربخشی عملکرد این روش را نشان می‌دهد. سپس آنها اقدام به مقایسه ای از دقت پیش‌بینی و زمان اجرا بین الگوریتم پیشنهادی و الگوریتم تجزیه مقادیر منفرد تدریجی بر روی مجموعه داده‌های مووی لنز و فلیسکتر^۸ ارایه داده اند و نتیجه گرفته اند که روش پیشنهادی از سایر روش‌های مشابه خود بهتر است. در مقاله بال و همکاران^۹ (2020) یک روش فیلتر ترکیبی از ترکیب فیلتر محظوظ بر اساس همبستگی بین فیلم‌ها و روش

1. Li et al.

2. MCBF-SVD

3. Explicit

4. Implicit

5. Singular Value Decomposition

6. Zhou et al.

7. Incremental Algorithm

8. Flixster

9. Bahl et al.

اشتراکی مبتنی بر تجزیه به مقادیر منفرد را ارایه داده اند. هدف از ارایه روش مذکور بدست آوردن حداقل خطای ممکن برای پیش‌بینی امتیازات کاربران به فیلم‌ها است. نتایج بر روی دیتاست‌های ۱۰۰ هزار مولوی لنز نشان از بهبود خطا نسبت به روش‌های دیگر از جمله تجزیه مقادیر منفرد تنها است. همچنین باوانا و همکاران^۱ (2019) با اعتقاد به اینکه روش تجزیه مقادیر منفرد یکی از روش‌های قدرتمند در تجزیه ماتریس است، در مقاله خود موضوع استفاده از این الگوریتم برای سیستم‌های توصیه‌گر بر مبنای توزیع محاسبات در واحد‌های پردازشگر موازی جهت تسریع در بدست آوردن نتایج را مورد بررسی قرار داده‌اند. پاترا و گانگولی^۲ (2019) روش‌های مختلف پیش‌پردازش برای اعمال به الگوریتم تجزیه مقادیر منفرد را با هم مورد بررسی قرار داده اند. برای بررسی از دیتاست‌های یک میلیون مولوی لنز استفاده شده است. در ابتدا با استفاده از روش خوش بندی نزدیکترین همسایه‌های کاربران، با روش‌های متفاوت فاصله یابی مانند ژاکارد و اقلیدسی مشخص شده و امتیازات بدست آمده از این روش را جاییگزین مقادیر نامعلوم در ماتریس امتیازات نموده‌اند. نتایج بدست آمده نشان می‌دهد، وقتی که همسایه‌های کاربران با استفاده از روش فاصله اقلیدسی بدست آید و سپس با استفاده از روش میانگین امتیازات، متوسط امتیاز آنها در ماتریس امتیازات اعمال و از الگوریتم تجزیه مقادیر منفرد استفاده شود، نتایج بهتری حاصل خواهد شد. در مقاله راهول و همکاران^۳ (2021) برای سیستم توصیه‌گر فیلم از روش تجزیه مقادیر منفرد برای کاهش ابعاد و از روش متوسط امتیاز همسایگان برای خوش بندی استفاده کرده‌اند. برای پیاده‌سازی مدل از دیتاست‌های مولوی لنز و فلیکستر استفاده شده است. نتایج بدست آمده از روش مذکور را با روش‌های مختلف ارزیابی نموده و به این نتیجه رسیده‌اند که روش پیشنهادی آنها دارای عملکرد بهتری نسبت به سایر روش‌ها است. سعادتی و همکاران^۴ (2019) در مقاله خود نسبت به ارایه نتایج حاصل از پیاده‌سازی چند مدل سیستم توصیه‌گر فیلم، فیلتر اشتراکی کاربر محور، فیلتر اشتراکی

1. Bhavana et al.

2. Patra & Ganguly

3. Rahul et al.

4. Saadati et al.

آیتم محور، سیستم محتوا محور، تجزیه مقادیر منفرد و شبکه عصبی برای پیش‌بینی امتیازات کاربران با استفاده از زبان برنامه نویسی پایتون اقدام کرده و نتایج حاصل را با یکدیگر مقایسه کرده‌اند. بررسی نتایج نشان می‌دهد، روش تجزیه مقادیر منفرد نسبت به سایر روش‌های فیلتر اشتراکی دارای خطای کمتری است.

جدول ۳. جمع بندی مقالات بررسی شده فیلتر اشتراکی با روش SVD

ردیف	نویسنده‌ها	چالش مورد بررسی	روش بکار رفته
۱	Rahul, et.al., 2021	عملکرد	Truncated SVD+ K_Means
۲	Bahl et al., 2020	خطای کمتر	CBF+SVD
۳	Li et al., 2020	کاهش خطا + مقیاس پذیری	MCBF-SVD
۴	Bhavana et al., 2019	سرعت پردازش	SVD
۵	Patra& Ganguly, 2019	پیش پردازش	SVD+ K_Means
۶	Saadati et al., 2019	خطای کمتر	SVD و سایر روش‌ها
۷	Zhou et al., 2015	مقیاس پذیری و عملکرد	Incremental SVD

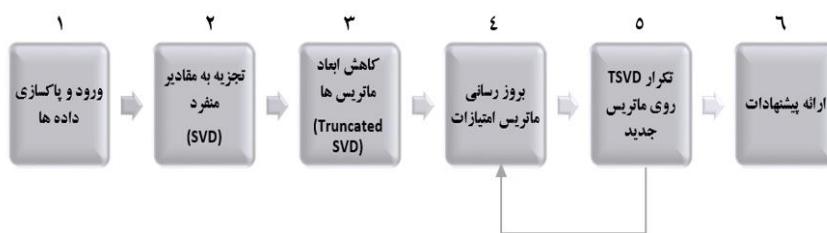
روش پژوهش

در این پژوهش، مدل بهینه شده‌ای از سیستم توصیه‌گر فیلم با استفاده از روش تجزیه به مقادیر منفرد و بر اساس مدل‌های ارایه شده توسط راهول و همکاران (2021) و آندریاس (2017) توسعه داده شده‌است. به عنوان داده‌های ورودی از نسخه ۱۰۰ هزار امتیاز دیتابست مowی لنز دانشگاه مینه سوتا با ۹۷۲۴ فیلم، ۶۱۰ کاربر و حدود ۱۰۰ هزار امتیاز کاربر به فیلم‌ها استفاده شده و با استفاده از زبان برنامه نویسی پایتون ویرایش ۳ مدل پیاده سازی شده‌است. مراحل مدلسازی و بهینه سازی آن در شکل (۴) نمایش داده شده‌است.

مرحله ۱. ورود و پاکسازی داده‌ها: با توجه به اینکه بیش از ۹۸ درصد دیتابست امتیازات مورد استفاده خالی است، لذا برای اطمینان از صحت و دقت مدل لازم است ابتدا نسبت به پاکسازی و مرتب سازی داده‌ها اقدام شود. اهم اقدامات به شرح ذیل است:

- حذف سطر و ستون‌های اضافی
- حذف سطر و ستون‌های تکراری و خالی

- حذف کاربران با کمتر از ۲۰ امتیاز و فیلم‌های با کمتر از ۱۰ امتیاز
- تقسیم امتیازات به ماتریس آموزش و تست با نسبت ۸۰ به ۲۰
- پر کردن سلول‌های بدون مقدار با میانگین امتیاز هر فیلم
- نرمال کردن امتیازات با کم کردن میانگین امتیاز هر فیلم از امتیازات



شکل ۴. فرایند پیاده سازی مدل بهینه شده

مرحله ۲. تجزیه به مقادیر منفرد: نسبت به تجزیه ماتریس آموزش اقدام و مقادیر ماتریس‌های U ، S و V را بدست می‌آوریم.

مرحله ۳. کاهش ابعاد ماتریس‌ها: در این مرحله برای مقادیر مختلف k ، میزان دقت مقادیر پیش‌بینی شده برای داده‌های تست را بدست می‌آوریم و بهترین مقدار آن را انتخاب می‌کنیم.

مراحل ۴ و ۵. مرحله بهینه سازی: در این مرحله با توجه به مقدار کاهش ابعاد بدست آمده در مرحله قبل، مقادیر بدست آمده برای داده‌های تست را در ماتریس کاهش ابعاد بدست آمده قرار می‌دهیم و با تجزیه مجدد ماتریس امتیازات به مقادیر منفرد، میزان خطای بهینه را بدست می‌آوریم.

مرحله ۶. ارایه پیشنهادات: در این مرحله با مرتب کردن امتیازات پیش‌بینی شده برای فیلم‌های دیده نشده برای کاربر فعال، نسبت به پیشنهاد تعدادی فیلم برتر اقدام می‌شود.

یافته‌ها

شکل (۵) دیتاست اصلی امتیازات، شکل (۶) و (۷) به ترتیب دیتاست آموزش و دیتاست

تست را پس از تفکیک به نسبت ۸۰ به ۲۰ نمایش می‌دهند:

'test'	'train'	'data'									
movielid	rating	userid	movielid	rating	userid	userid	movielid	rating			
50022	1682.0	3.5	322.0	2052	27831.0	3.5	18.0	0	1	1	4.0
25564	50872.0	4.0	177.0	11736	165.0	5.0	71.0	1	1	3	4.0
87281	55118.0	4.5	562.0	49865	318.0	4.5	319.0	2	1	6	4.0
2083	47200.0	3.0	18.0	51918	95.0	5.0	337.0	3	1	47	5.0
51265	7438.0	3.0	331.0	57780	56775.0	4.0	380.0	4	1	50	5.0
...
11962	96588.0	3.5	73.0	4788	1224.0	4.0	29.0	100831	610	166534	4.0
80284	71535.0	4.0	505.0	58227	2085.0	3.0	381.0	100832	610	168248	5.0
55967	5418.0	3.5	369.0	38745	1275.0	4.0	266.0	100833	610	168250	5.0
17707	94777.0	1.0	111.0	28875	6565.0	4.0	199.0	100834	610	168252	5.0
38039	2692.0	4.5	260.0	45346	95441.0	2.0	298.0	100835	610	170875	3.0
15863 rows × 3 columns			63451 rows × 3 columns			100836 rows × 3 columns					

شکل ۷. دیتابست تست

شکل ۶. دیتابست آموزش

شکل ۵. دیتابست اصلی

با اعمال روش تجزیه مقادیر منفرد بر روی دیتابست آموزش، مقادیر پیش‌بینی شده برای دیتابست تست بصورت شکل (۸) بدست می‌آید. مقدار جذر میانگین مربعات خطأ^۱ و میانگین قدر مطلق خطأ^۲ به ترتیب عبارتند از ۰/۹۴۴۸۲ و ۰/۰۷۳۲۱۲. در شکل (۸) مقادیر پیش‌بینی با نماد RATING_HAT و مقادیر واقعی با نماد RATING نمایش داده شده‌اند.

-
1. RMSE (Root Mean Square Error)
 2. MAE (Mean Absolute Error)

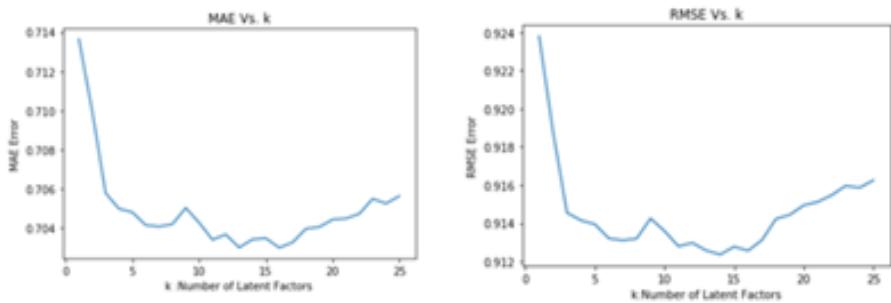
	movielid	rating	userId	rating_hat
50022	1682.0	3.5	322.0	3.83
25564	50872.0	4.0	177.0	3.84
87281	55118.0	4.5	562.0	4.04
2083	47200.0	3.0	18.0	3.11
51265	7438.0	3.0	331.0	3.85
...
11962	96588.0	3.5	73.0	3.59
80284	71535.0	4.0	505.0	3.83
55967	5418.0	3.5	369.0	3.85
17707	94777.0	1.0	111.0	3.55
38039	2692.0	4.5	260.0	3.94

15863 rows × 4 columns

```
iteration= 1 k= 590 mae_error= 0.73212 rmse_error= 0.94482
*****
tims(s)= 504.09
```

شکل ۸ نتیجه اعمال روش SVD

با در نظر گرفتن تعداد مقادیر منفرد (K) از یک تا ۲۵ و اعمال بر روی ماتریس های U ، S و V^T ، ماتریس های با ابعاد کاهش یافته جدید R ، U_R ، S_R و R_U بدست می آیند که از طریق ضرب آنها، مقادیر پیش‌بینی برای دیتابست تست بدست آمده و مقدار خطاهای اندازه گیری می کنیم. شکل (۹) نمودار میزان تغییرات جذر میانگین مربعات خطای داده های تست بر مبنای تعداد مقادیر منفرد (K) را نمایش می دهد. همانگونه که از نمودار (۹) مشاهده می شود، کمترین مقدار خطای در $K=14$ رخ داده است که مقدار آن برابر با 0.91236 است. این مقدار نسبت به روش تجزیه مقادیر منفرد، به میزان 0.343 ٪ خطای را کاهش داده است. شکل (۱۰) نیز نمودار تغییرات خطای میانگین قدر مطلق خطای بر حسب K را نشان می دهد.

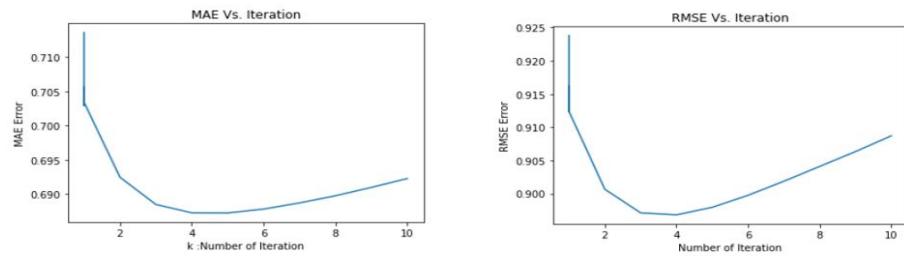


شکل ۹. نمودار تغییرات خطای RMSE بر حسب k نسباً تغییرات خطای MAE بر حسب k

در مرحله بعد برای کاهش بیشتر میزان خطا، از جاگذاری مقادیر پیش‌بینی در ماتریس امتیازات اولیه کاهش ابعاد یافته و انجام تجزیه مقادیر منفرد روی آن استفاده می‌کنیم. مرحله جاگذاری و تجزیه مقادیر منفرد را تا ۱۰ مرتبه تکرار می‌کنیم تا نمودار میزان خطا بر حسب تعداد تکرار حاصل شود. در این مرحله همواره مقدار K برابر با ۱۴ است که از مرحله قبل بدست آمده است. نتایج حاصل در شکل (۱۱) نمایش داده است. همانگونه که در نمودار مذکور مشاهده می‌شود کمترین مقدار جذر میانگین مربعات خطا در تکرار چهارم و با مقدار 0.896814 بدست می‌آید. در این حالت میزان خطا به مقدار 1.7% نسبت به مرحله قبل بهبود می‌یابد. بنابراین مجموع میزان کاهش خطا نسبت به روش تجزیه مقادیر منفرد، به میزان 0.85 درصد کاهش می‌یابد. همچنین مقدار میانگین قدر مطلق خطا در این حالت برابر با 0.67705 خواهد شد. نتایج حاصل در مقایسه با نتایج مندرج در مقالات (Rahul et al., 2021; Saadati et al., 2019; Andreas et al., 2017) دارای خطای کمتری است.

برای مشاهده خروجی مدل پیشنهادی و با توجه به ماتریس پیش‌بینی بدست آمده می‌توان پیشنهادات را برای کاربرهای مختلف استخراج کرد. در این مرحله لازم است پس از استخراج فیلم‌های مشاهده توسط کاربر فعل، لیست فیلم‌های مذکور از لیست کلیه فیلم‌ها حذف شده، فیلم‌های باقیمانده بر اساس امتیازات پیش‌بینی شده بصورت نزولی مرتب گرددند و ۲۰ فیلم اول به عنوان پیشنهادات انتخاب و نمایش داده شود. به عنوان نمونه

خروجی مدل برای کاربرهای با شناسه ۱۰ و ۲۵۰ در شکل (۱۲) نمایش داده شده است. لازم به ذکر است مقادیر RATING در جداول خروجی، امتیازات پیش‌بینی شده توسط مدل پیشنهادی "تجزیه مقادیر منفرد با ابعاد کاهش یافته تکرار شده"^۱ است.



شکل ۱۱. نمودار تغییرات MAE و RMSE نسبت به تعداد تکرار

user_id= 250		user_id= 10			
'فیلم های پیشنهادی'		'فیلم های پیشنهادی'			
moviedb_id	rating	moviedb_id	rating		
1041	4.69	Secrets & Lies (1996)	89904	4.73	The Artist (2011)
89904	4.64	The Artist (2011)	1270	4.70	Back to the Future (1985)
1104	4.61	Streetcar Named Desire, A (1951)	1212	4.70	Third Man, The (1949)
3451	4.52	Guess Who's Coming to Dinner (1967)	457	4.70	Fugitive, The (1993)
1209	4.50	Once Upon a Time in the West (C'era una volta ...)	1041	4.69	Secrets & Lies (1996)
2360	4.46	Celebration, The (Festen) (1998)	1207	4.63	To Kill a Mockingbird (1962)
1178	4.42	Paths of Glory (1957)	1250	4.59	Bridge on the River Kwai, The (1957)
306	4.42	Three Colors: Red (Trois couleurs: Rouge) (1994)	1204	4.59	Lawrence of Arabia (1962)
2329	4.40	American History X (1998)	1104	4.55	Streetcar Named Desire, A (1951)
3429	4.38	Creature Comforts (1989)	1223	4.51	Grand Day Out with Wallace and Gromit, A (1989)
912	4.37	Casablanca (1942)	1197	4.49	Princess Bride, The (1987)
527	4.37	Schindler's List (1993)	1209	4.49	Once Upon a Time in the West (C'era una volta ...)
904	4.35	Rear Window (1954)	3089	4.48	Bicycle Thieves (a.k.a. The Bicycle Thief) (a...
1213	4.34	Goodfellas (1990)	1284	4.47	Big Sleep, The (1946)
58559	4.34	Dark Knight, The (2008)	2360	4.45	Celebration, The (Festen) (1998)
1221	4.34	Godfather: Part II, The (1974)	1234	4.45	Sting, The (1973)
475	4.34	In the Name of the Father (1993)	260	4.44	Star Wars: Episode IV - A New Hope (1977)
858	4.34	Godfather, The (1972)	2318	4.43	Happiness (1998)
593	4.33	Silence of the Lambs, The (1991)	1178	4.43	Paths of Glory (1957)
356	4.33	Forrest Gump (1994)	1262	4.43	Great Escape, The (1963)
3083	4.33	All About My Mother (Todo sobre mi madre) (1999)	3429	4.41	Creature Comforts (1989)

شکل ۱۲. خروجی مدل برای کاربرهای با شناسه ۱۰ و ۲۵۰

1. Iterated Truncated Singular Value Decomposition (ITSVD)

بحث و نتیجه‌گیری

در بین روش‌های مختلف فیلتر اشتراکی، بکارگیری روش تجزیه ماتریس به مقادیر منفرد دارای قابلیت انعطاف مناسبی در کاهش حجم محاسبات، کاهش حافظه مورد نیاز و همچنین اعمال روش‌های مختلف برای کاهش خطای مقادیر پیش‌بینی شده است. در مدل ارایه شده، با اعمال سه روش: حذف کاربران و فیلم‌های دارای تعداد امتیاز کم، پیدا کردن بهترین میزان کاهش ابعاد ماتریس‌ها و تکرار جاگذاری مقادیر و تجزیه مجدد ماتریس پیش‌بینی با ابعاد کاهش یافته، خطای مقادیر پیش‌بینی به مقدار مناسبی بهبود یافتند. همانطور که از جدول (۴) مشاهد می‌شود در هر مرحله از اعمال روش‌های بهینه سازی مقدار خطای جذر میانگین مربعات خطأ به میزان قابل توجهی کاهش می‌یابد.

جدول ۴. کاهش خطای جذر میانگین مربعات خطأ با بهینه سازی روش تجزیه مقادیر منفرد

روش	مقدار k	RMSE	Dataset	خالی بودن دیتاست (درصد)
SVD	۵۹۰	۰/۹۴۴۸۲	۱۰۰ هزار امتیازی مجموع لنز با فیلم	۹۸/۴
	۱۴	۰/۹۱۲۳۶۰	۹۷۲۴ کاربر	
	۱۴	۰/۸۹۶۸۱	۶۱۰	

هر چند به دلیل تفاوت دیتاست‌ها، روش‌های پالایش داده‌ها و سرعت اجرای برنامه‌ها مقایسه نتایج بدست آمده با مراجع دیگر، از اعتبار کافی برخوردار ناست ولی جهت روشن شدن حدود خطأ در مراجع مختلف به برخی موارد اشاره می‌شود. شرکت نتفلیکس در سال ۲۰۰۷ اعلام نمود سیستم توصیه‌گر آن شرکت با دیتاست ۱۰۰ میلیون امتیازی دارای خطای RMSE برابر ۰/۹۵۱۴ است (سعادتی و همکاران، ۲۰۱۹). البته سعادتی و همکاران (۲۰۱۷) با استفاده از روش تجزیه به مقادیر منفرد، مقدار خطأ را ۳/۵۴۲ بدست آورده اند که مقدار بسیار بزرگی است. جدول (۵) مقدار خطاهای بدست آمده از روش‌های مختلف تجزیه مقادیر منفرد با یکدیگر مقایسه شده‌اند. همانطور که دیده می‌شود نتایج حاصل از مدل بهینه ارایه شده دارای خطای کمتری نسبت به سایر موارد می‌باشد.

جدول ۵. مقایسه خطای روش پیشنهادی با سایر مراجع

حوالی بودن (درصد)	Dataset	RMSE	مقدار k	روش	مراجع
۹۸/۴	۱۰۰ هزار مولوی لنز	۰/۹۴۴۸۲	۵۹۰	SVD	پژوهش حاضر
۹۸/۴	۱۰۰ هزار مولوی لنز	۰/۹۱۲۳۶۰	۱۴	TSVD	پژوهش حاضر
۹۸/۴	۱۰۰ هزار مولوی لنز	۰/۸۹۶۸۱	۱۴	ITSVD	پژوهش حاضر
۹۳/۷	۱۰۰ هزار مولوی لنز	۰/۹۲۹۳۴	-	SVD+ K_means	Rahul et al., 2021
نامعلوم	Epinions.com	۱/۱۴۷۴	۱۰	TSVD	Andreas, 2017
۹۵/۸	یک میلیون مولوی لنز	۳/۵۴۲	۷۵	SVD	Saadati, et. al., 2019
نامعلوم	۱۰۰ میلیون نتفلیکس	۰/۹۵۱۴	-	فیلتر اشتراکی	Saadati, et. al., 2019

بنا بر خروجی مدل نهایی، می‌توان نتیجه گرفت مدل تجزیه ماتریس امتیازات به مقادیر منفرد، بر روی مجموعه داده‌های موجود که دارای بیش از ۹۸ درصد مقادیر نامعلوم است، بخوبی عمل کرده و تمام مقادیر نامعلوم را با دقت مناسبی می‌تواند پیش‌بینی نماید. البته بکارگیری دو روش بهینه سازی کاهش ابعاد و همچنین تکرار جاگذاری و تجزیه ماتریس، دقت مقادیر پیش‌بینی شده را تا حد بسیار مناسبی ارتقاء داده و نتایج حاصل در مقایسه با سایر مدل‌ها دارای دقت مناسبی است. برای کارهای آتی پیشنهاد می‌شود ترکیب مدل مذکور با سایر روش‌ها مانند روش‌های فیلتر محظوظ و سایر روش‌های فیلتر اشتراکی خصوصاً شبکه‌های عصبی برای کاهش بیشتر میزان خطا بررسی شود. همچنین استفاده از روش‌های مقدار دهی اولیه برای امتیازات ناموجود از طریق روش‌های خوش بندی همسایگی، استفاده از میانگین امتیازات کاربران و یا میانگین کل می‌تواند روش‌هایی برای مقایسه با روش پیشنهادی باشد.

تعارض منافع

تعارض منافع ندارد.

ORCID

Nozar Ebrahimi Lame



<http://orcid.org/0000-0003-4512-8879>

Fatemeh Saghafi



<http://orcid.org/0000-0003-4843-6885>

Majid Gholipour



<http://orcid.org/0000-0003-0804-5310>

منابع

- ابراهیمی، ل، میرابی، و، رنجبر، م و حسن پور، ا. (۱۳۹۸). مدل وفاداری مشتری برای سیستم‌های توصیه‌گر در تجارت الکترونیک، نشریه علمی مطالعات مدیریت کسب و کار هوشمند، ۸، ۱۴۳-۱۷۰. <https://dx.doi.org/10.22054/ims.2019.10379>
- حیدری، ب، پروین نیا، ا. (۱۳۹۶). ارایه مدلی برای سیستم‌های توصیه‌گر فیلم مبتنی بر رویکرد مشارکت محور، مجله فناوری اطلاعات در طراحی مهندسی، ۱۰ (۱)، ۹-۱.
- محمدی، ف، یزدانی، ح و ادیب زاده، م. (۱۳۹۹). فرا تحلیل مطالعات خرید آنلاین، بررسی و ترکیب نتایج پژوهش‌های انجام شده در زمینه خرید آنلاین، نشریه علمی مطالعات مدیریت کسب و کار هوشمند، ۹ (۳۳)، ۱۰۱-۱۴۲. <https://dx.doi.org/10.22054/ims.2020.12038>

References

- Aggarwal, C. C., & Textbook, T. (2016). *Recommender Systems : Text Book*.
- Ahuja, R., Solanki, A., & Nayyar, A. (2019). Movie Recommender System Using K-Means Clustering AND K-Nearest Neighbor. *Proceedings of the 9th International Conference On Cloud Computing, Data Science and Engineering, Confluence 2019*, 263–268. <https://doi.org/10.1109/CONFLUENCE.2019.8776969>
- Alamdar, P. M., Navimipour, N. J., Hosseinzadeh, M., Safaei, A. A., & Darwesh, A. (2020). A Systematic Study on the Recommender Systems in the E-Commerce. *IEEE Access*, 8, 115694–115716. <https://doi.org/10.1109/ACCESS.2020.3002803>
- Andreas, M. (2017). *Matrix Factorization Techniques for Recommender Systems* [University of The Aegean, School of Engineering]/thesis https://hellanicus.lib.aegean.gr/bitstream/handle/11610/18038/Matrix_Factorization_techniques_for_Recommender_Systems.pdf?sequence=1
- Bahl, D., Kain, V., Sharma, A., & Sharma, M. (2020). A novel hybrid approach towards movie recommender systems. *Journal of Statistics and Management Systems*, 23 (6), 1049–1058. <https://doi.org/10.1080/09720510.2020.1799503>
- Bhavana, P., Kumar, V., & Padmanabhan, V. (2019). *Block based Singular Value Decomposition approach to matrix factorization for recommender systems*. <http://arxiv.org/abs/1907.07410>
- Choi, S. M., Ko, S. K., & Han, Y. S. (2012). A movie recommendation algorithm based on genre correlations. *Expert Systems with Applications*, 39 (1), 103–110. <https://doi.org/10.1016/j.eswa.2011.07.030>

- Applications*, 39 (9) , 8079–8085. <https://doi.org/10.1016/j.eswa.2012.01.132>
- Falk, K. (2019). *Practical Recommender Systems*. https://www.mendeley.com/catalogue/4db84cb8-e911-3167-a969-98d4c25707f3/?utm_source=desktop&utm_medium=1.19.4&utm_campaign=open_catalog&userDocumentId=%7B09985284-1648-45ae-9586-8265d1bb4ad2%7D
- Guan, X., Li, C. T., & Guan, Y. (2017). Matrix Factorization with Rating Completion: An Enhanced SVD Model for Collaborative Filtering Recommender Systems. *IEEE Access*, 5, 27668–27678. <https://doi.org/10.1109/ACCESS.2017.2772226>
- Lekakos, G., & Caravelas, P. (2008). A hybrid approach for movie recommendation. *Multimedia Tools and Applications*, 36 (1–2) , 55–70. <https://doi.org/10.1007/s11042-006-0082-7>
- Li, X., Zhao, H., Wang, Z., & Yu, Z. (2020). Research on Movie Rating Prediction Algorithms. *2020 5th IEEE International Conference on Big Data Analytics, ICBDA 2020*, 121–125. <https://doi.org/10.1109/ICBDA49040.2020.9101282>
- Netflix Prize*. www.netflixprize.com
- Patra, S., & Ganguly, B. (2019). Improvising Singular Value Decomposition by KNN for Use in Movie Recommender Systems. *Journal of Operations and Strategic Planning*, 2 (1) , 22–34. <https://doi.org/10.1177/2516600x19848956>
- Patra, S., & Ganguly, B. (2019). Improvising Singular Value Decomposition by KNN for Use in Movie Recommender Systems. *Journal of Operations and Strategic Planning*, 2 (1) , 22–34. <https://doi.org/10.1177/2516600x19848956>
- Raghuwanshi, S. K., & Pateriya, R. K. (2019). Recommendation systems: Techniques, challenges, application, and evaluation. In *Advances in Intelligent Systems and Computing* (Vol. 817, pp. 151–164). https://doi.org/10.1007/978-981-13-1595-4_12
- Rahul, M., Kumar, V., Yadav, V., & Rishabh. (2021). Movie recommender system using single value decomposition and K-means clustering. *IOP Conference Series: Materials Science and Engineering*, 1022 (1). <https://doi.org/10.1088/1757-899X/1022/1/012100>
- Saadati, M., & Shihab, S. (n.d.). *Movie Recommender Systems: Implementation and Performance Evaluation/2019*
- Vaheb, A.. <https://aparat.design/recommendation-systems-in-filimo-cqzge4gfsevi>
- Zhang, Y., Abbas, H., & Sun, Y. (2019). Smart e-commerce integration with recommender systems. In *Electronic Markets* (Vol. 29, Issue 2, pp. 219–220). <https://doi.org/10.1007/s12525-019-00346-x>

Zhou, X., He, J., Huang, G., & Zhang, Y. (2015). SVD-based incremental approaches for recommender systems. *Journal of Computer and System Sciences*, 81 (4), 717–733. <https://doi.org/10.1016/j.jcss.2014.11.016>

References [In Persian]

- Ebrahimi, L., Mirabi, and, Ranjbar, M. and Hassanpour, A. (1398). Customer Loyalty Model for Advisory Systems in E-Commerce, *Scientific Journal of Intelligent Business Management Studies*, 8 (29), 143-170. <https://dx.doi.org/10.22054/ims.2019.10379> [In Persian]
- Heydari, B, Parvin Nia, A. (1396). Providing a Model for Participatory Oriented Film Recommending Systems, *Journal of Information Technology in Engineering Design*, 10 (1), 1-9. [In Persian]
- Mohammadi, F. Yazdani, H. and Adibzadeh, M. (1399). Meta-analysis of online shopping studies, review and synthesis of research results in the field of online shopping, *Scientific Journal of Smart Business Management Studies*, 9 (33), 101-142. <https://dx.doi.org/10.22054/ims.2020.12038>[In Persian]

استناد به این مقاله: ابراهیمی لامع، نوذر، ثقفی، فاطمه، قلیپور، مجید. (۱۴۰۰). سیستم توصیه‌گر فیلم ابتكاری با استفاده از روش تجزیه ماتریس به مقادیر منفرد با ابعاد کاهش یافته تکرار شده، مطالعات مدیریت کسب و کار هوشمند، ۱۰(۳۸)، ۱۷۳-۱۹۹.

DOI: 10.22054/IMS.2022.61702.1994



Journal of Business Intelligence Management Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License..

