

**HIAST**

الجمهورية العربية السورية

المعهد العالي للعلوم التطبيقية والتكنولوجيا

قسم النظم المعلوماتية

أعدت هذه الأطروحة لنيل درجة الماجستير

في نظم دعم القرار

نظام توصية يعتمد على البيانات الضمنية لتطبيقات تلفاز بروتوكول الإنترنت (IPTV)

A Recommendation System Based on Implicit Data for Internet Protocol Television (IPTV)

إعداد

م. لمى منصور

إشراف

د.مصطفى دقاق

د. ياسر رحال

كانون الأول 2021

# المعهد العالي للعلوم التطبيقية والتكنولوجيا

## Higher Institute for Applied Science & Technology

مؤسسة سورية حكومية للتعليم العالي أحدثت في عام 1983، بهدف إعداد أطر متميزة مؤهلة للبحث العلمي والتطوير في مجال العلوم التطبيقية والتقانة، لتساهم بفاعلية في التنمية العلمية والصناعية والاقتصادية في القطر. يشكل التأهيل الهندسي والدراسات العليا في المعهد العالي محور عمليّة إعداد الأطر المتخصصة. يخرّج المعهد العالي مهندسين متميزين، بعد دراسة لمدة خمس سنوات، في اختصاصات الاتصالات والمعلوماتية والنظم الالكترونية والميكاترونيكس وهندسة الطيران وعلوم وهندسة المواد. كما يمنح المعهد العالي درجة الماجستير الأكاديمي، ماجستير بحثي يمتد على سنتين، من خلال مجموعة من برامج الماجستير. في نظم الاتصالات وفي التحكم والروبوتيك وفي علوم المواد وفي نظم المعلومات واتخاذ القرار وفي نظم معالجة المعطيات الكبيرة. وأخيراً يمنح المعهد العالي درجة الدكتوراه في عدّة اختصاصات موازية لما ذكر في برامج الماجستير. يعتمد المعهد العالي في تميزه على تركيزه على النوع وليس الكم، فهو ينتقي في المرحلة الهندسية شريحة الطلاب المتفوقين في شهادة الدراسة الثانوية السورية من الفرع العلمي أو من في حكمهم. أمّا في مرحلة الماجستير فيقبل المعهد العالي جملة الشهادات الجامعية الموازية للماجستير المطلوب، وذلك على أساس مفاضلة خاصّة لاختيار الأفضل. كما يقدم المعهد العالي للطلال جواً متميزاً للدراسة والبحث بدءاً من كوادره المتفرغة عالية التأهيل ومناهجه المواكبة للتطورات العلمية، وانتهاءً بإمكانيات مختبراته المتميزة في القطر وبنيتها التحتية الموازية من صالات حواسب وورش ومقدرات مادية وشبكات تعاون مع الصناعة والهيئات الأكاديمية داخل وخارج القطر. كل ذلك في وسائل للراحة والترفيه من سكن طلابي مطعم وصلات رياضية وملاعب ونشاطات طلابية متنوعة. بالإضافة إلى نشاطه الأكاديمي، يضم المعهد العالي أقساماً علمية ومخابر متنوعة ومراكز تكنولوجية، كمخبر الدراسات البيئية ومركز تقانات اللحام ومركز الحوسبة عالية الأداء. تقدم هذه الفعاليات خدمات واستشارات للقطاعين العام والخاص، بالإضافة إلى المشاريع التطويرية والنشاطات البحثية والدورات التدريبية وتنظيم ورش العمل والمؤتمرات العلمية.

## تصريح

أنا الموقع أدناه لمي محسن منصور معدّ أطروحة الماجستير التي تحمل العنوان:

" نظام توصية يعتمد على البيانات الضمنية لتطبيقات تلفاز بروتوكول الإنترنت (IPTV) "

" A Recommendation System Based on Implicit Data for Internet Protocol Television (IPTV) "

أصرح بأن:

- الأعمال والنتائج المعروضة في هذه الأطروحة هي نتيجة جهودي الشخصية وبتوجيه من المشرف، وأن ما عدا ذلك من معلومات ونتائج قد نُسبت إلى مصادرها ومؤلفيها، وأشير إلى ذلك في متن النص وفي قائمة المراجع.
- المعطيات والمعلومات المستخدمة في هذه الأطروحة جرى تحصيلها بطرائق سليمة ومشروعة ونُسبت إلى مصادرها في المواضيع الملائمة.
- كل مكون من مكونات هذه الأطروحة (مقطع نصي، صورة، مخطط، ...) مقتبس من عمل آخر جرى تمييزه بوضوح ونُسب إلى مصدره.
- الأعمال والنتائج المعروضة في هذه الأطروحة لم تُستخدم سابقاً وليست قيد الاستخدام للحصول على أي شهادة أكاديمية أخرى.

التوقيع

## كلمة شكر

أتوجه بخالص الشكر والتقدير لحضرات المشرفين الأفاضل الدكتور ياسر ربحال والدكتور مصطفى دقاق على توجيهاتهم الدقيقة ومتابعتها المستمرة لي في كل خطوة في هذا البحث.

كما أتوجه بالشكر لكافة أعضاء الكادر التدريسي والإداري لماجستير نظم دعم القرار لما قدموه خلال فترة الماجستير من جهد ومعرفة.

لا يمكن أن أنسى شكر المعهد العالي للعلوم التطبيقية والتكنولوجيا لإتاحته الفرصة لي لدراسة هذا الماجستير والحصول على شهادته.

كل الشكر إلى شركة سيريتل التي قدمت كل الدعم الفني والتقني لنجاح هذه البحث.

م. لمى محسن منصور

## الإهداء

إلى بلسم حياتي ومنازقي في الظلمات والخبيات القاسية.. إلى معلمتي ومرشدتي الأولى.. إلى مثال القوة والعنفوان.. إلى المرأة التي أحلم أن أشبهها.. إلى ست الكل..

أبي العظيمة هند ديب

إلى من علمني الحلم وتحقيقه.. إلى من رافقتني في كل خطوة.. إلى أول صديق لي.. إلى بطلي الدائم ومثلي الأعلى.. إلى من افتخر بأبنتي من صلبه.. أمد الله بعمرك..

أبي العزيز محسن منصور

إلى شمس حياتي.. إلى الجبل القوي.. إلى الشمعة التي بنورها أبصر طريقي.. إلى الموجة الأقوى.. إلى شعلة الذكاء المتقدة التي لا ترضى الاستسلام..

أخي د. غطفان منصور

إلى عزتي وعزوتي.. إلى بطلي الشجاع.. إلى الفارس المقدم.. إلى أسمرى الجميل.. إلى من تشاطرت معه معظم مراحل حياتي.. إلى مصدر قوتي..

أخي م. مصطفى منصور

إلى نصفني الثاني.. إلى صديقة دربي.. إلى مرآتي التي أبصر بها ما يحميني.. إلى أنقى البشر.. إلى جميلتي وطفلتي التي أصبحت أمماً..

أختي د. مايا منصور

إلى من باتوا أقرب الناس إلي.. إلى صديقات دربي.. إلى أخواتي التي لم تنجهم أُمِّي..

رنيم الصالح، نسرين مشولح

إلى الأخ الجديد والكنف الذي لا يميل.. إلى السند الجديد.. إلى من يقف بجاني دوماً ويقويني..

صهري د. مراد الخضر

إلى نجوم سائي.. إلى مصدر الأمل والجمال.. إلى بهجة الدنيا.. إلى أولاد أخوتي..

نايا، آيا، علي، مينيسا، لانا، حسن، يوسف

## جدول المحتويات

|          |  |
|----------|--|
| i.....   | الملخص   |
| iii..... | المقالات الناتجة عن هذا البحث                    |
| iv.....  | قائمة الأشكال                                    |
| v.....   | قائمة الجداول                                    |
| vii..... | قائمة المصطلحات والاختصارات                      |
| xi.....  | قائمة الرموز                                     |
| 1.....   | 1- الفصل الأول: مدخل لموضوع البحث وأهميته        |
| 2.....   | 1-1 تمهيد  |
| 2.....   | 2-1 دوافع البحث                                  |
| 3.....   | 3-1 إشكالية البحث                                |
| 3.....   | 4-1 فكرة الحل المقترح                            |
| 5.....   | 2- الفصل الثاني: الإطار النظري العام             |
| 6.....   | 1-2 مقدمة  |
| 6.....   | 2-2 أنواع آراء المستخدمين في أنظمة التوصية       |
| 6.....   | 1-2-2 آراء صريحة (Explicit Feedback)             |
| 7.....   | 2-2-2 آراء ضمنية (Implicit Feedback)             |
| 8.....   | 3-2 أنواع أنظمة التوصية                          |
| 9.....   | 1-3-2 نظم التوصية المعتمدة على المحتوى           |
| 10.....  | 2-3-2 نظم التوصية المعتمدة على التصفية التعاونية |
| 19.....  | 3-3-2 نظم التوصية الهيكلية                       |
| 21.....  | 4-2 تقييم نظم التوصية                            |
| 27.....  | 3- الفصل الثالث: الدراسة المرجعية                |
| 28.....  | 1-3 مقدمة  |
| 28.....  | 2-3 نظم التوصية بالاعتماد على المحتوى            |

|    |       |   |
|----|-------|---|
| 29 | 3-3   | نظم التوصية بالاعتماد على التصفية التعاونية |
| 30 | 4-3   | نظم التوصية بالاعتماد على التعلم العميق     |
| 31 | 4-    | الفصل الرابع: النماذج المقترحة والنتائج     |
| 32 | 1-4   | مقدمة                                       |
| 32 | 2-4   | المعطيات المستخدمة في البحث                 |
| 32 | 3-4   | بنية النموذج المقترح الأول CB               |
| 34 | 4-4   | بنية النموذج المقترح الثاني MF&KNN          |
| 35 | 5-4   | بنية النموذج المقترح الثالث NCF-A           |
| 37 | 6-4   | بنية النموذج المقترح الرابع NCF-D           |
| 38 | 7-4   | مقاييس التقييم المطبقة                      |
| 38 | 1-7-4 | HR & NDCG                                   |
| 39 | 2-7-4 | Mean- PCCP                                  |
| 40 | 3-7-4 | Diversity                                   |
| 40 | 4-7-4 | Coverage                                    |
| 40 | 5-7-4 | Novelty                                     |
| 42 | 8-4   | تحليل النتائج                               |
| 44 | 5-    | الفصل الخامس: الخاتمة والآفاق المستقبلية    |
| 45 | 1-5   | الخاتمة                                     |
| 45 | 2-5   | الآفاق المستقبلية                           |
| 46 | 6-    | الملاحق                                     |
| 47 | 1-6   | الملحق أ: المقالة الأولى                    |
| 60 | 2-6   | الملحق ب: المعطيات المستخدمة                |
| 65 | 7-    | المراجع                                     |



## المخلص

يقدم تلفاز بروتوكول الإنترنت IPTV محتوى تلفزيوني عبر شبكات بروتوكول الإنترنت IP. تعد مقاطع الفيديو عند الطلب VOD أشهر أنواع IPTV، مما يتيح للمستخدمين الاختيار بحرية من بين مجموعة كبيرة من أنواع البرامج. لذلك، من الضروري تقديم ميزات مبتكرة لجذب مستخدمين جدد والاحتفاظ بالمستخدمين الحاليين. لتحقيق هذا الغرض، تستخدم أنظمة IPTV عادةً محركات توصية لمقاطع الفيديو عند الطلب VOD. الغرض الأساسي من أنظمة التوصية هو اقتراح عناصر ذات صلة بالمستخدم من عناصر مختلفة من خلال إنتاج قائمة بالتوصيات لكل مستخدم. تقدم في هذا البحث نهجًا لأنظمة التوصية في IPTV. لقد طورنا هذا النهج بناءً على التعليقات الضمنية المستمدة من تفاعل المستخدمين مع مجموعات الأفلام/المسلسلات، مثل عدد المرات التي شاهدوا فيها فيلمًا والمدة التي قضوها في مشاهدة أفلام/مسلسلات معينة. بالنسبة للعوامل السابقة، اخترنا مجموعة متنوعة من خوارزميات التوصية، القائمة على المحتوى، القائمة على التعاون، والقائمة على طرق هجينة بين المنهجين السابقين. ثم طبقنا الخوارزميات المذكورة سابقًا على مجموعات بيانات ضخمة واقعية بعد إدخال بعض التعديلات على الخوارزميات، وقسنا النتائج على مقاييس أداء متعددة. لاحظنا أن التغييرات المطبقة حققت نتائج واعدة.

**الكلمات المفتاحية:** نظام التوصيات (RS)، البيانات الضمنية، البيانات الضخمة، مقاييس الأداء، مقاطع الفيديو عند الطلب (VOD)، تلفزيون بروتوكول الإنترنت (IPTV).

## Abstract

IPTV delivers television content over Internet Protocol (IP) networks. Videos On Demand (VOD) is the most popular IPTV, allowing users to freely select from a vast pool of program genres. Therefore, it is necessary to introduce innovative features to attract new users and retain existing ones. For this purpose, IPTV systems typically use VOD recommendation engines. The primary purpose of recommendation systems is to suggest user-relevant items from various items by producing a list of recommendations for each user. In this paper, we introduce an approach to recommendation systems in IPTV. We developed this approach on implicit feedback derived from users' interaction with movies/series sets, such as how many times they watched a movie and how long they have spent watching specific movies/series. For the previous factors, we tested a variety of recommendation algorithms, content-based, collaborative-based, and hybrid algorithms. Then applied the previously mentioned algorithms on real-life big data sets after introducing some modifications to the algorithms, then benchmarked the results on multiple performance metrics. We noticed that the applied changes achieved promising results.

**Keywords:** Recommendation system (RS), implicit data, Big Data, Performance Metrics, Videos On Demand (VOD), Internet Protocol Television (IPTV).

## المقالات الناتجة عن هذا البحث

✓ مقالة قُبلت ونُشرت

العنوان باللغة العربية: "نظام توصية يعتمد على البيانات الضمنية لتطبيقات تلفاز بروتوكول الإنترنت (IPTV)"

العنوان باللغة الانكليزية: " A Recommendation System Based on Implicit Data for Internet Protocol Television (IPTV)"

إشراف: دياسر رحال، د. مصطفى دقاق

حصلت على قبول نشر من مجلة جامعة البعث في المجلد رقم /43/، 5/12 لعام 2021.

➤ مقالة أرسلت للنشر بتاريخ 5/11/21

معلومات المجلة:

| Title                                 | Type    | Publisher  | SJR   | SJR Best Quartile | H index | Publisher  | Coverage    | Categories                            |
|---------------------------------------|---------|--|-------|-------------------|---------|--|-------------|---------------------------------------|
| Malaysian Journal of Computer Science | journal | Faculty of Computer Science and Information Technology | 0,197 | Q3                | 18      | Faculty of Computer Science and Information Technology | 1996 - 2021 | Computer Science (miscellaneous) (Q3) |

Title: A Recommendation System Based on Implicit Data for Internet Protocol Television (IPTV)

Authors: Lama Mohsen Mansour, Yasser Rahhal, Mustapha Dakkak

Affiliation: Higher Institute for Applied Sciences and Technology, Damascus, Syria

يمكن الاطلاع على هذه المقالة في الملحق أ: المقالة الأولى

## قائمة الأشكال

- الشكل 1: مصفوفة التقييم ..... 6
- الشكل 2: أمثلة عن آراء المستخدم الصريحة في موقع الخدمات على الإنترنت ..... 7
- الشكل 3: أصناف نظم التوصية ..... 9
- الشكل 4: طريقة التصفية التعاونية المعتمدة على المستخدم ..... 12
- الشكل 5: طريقة التصفية التعاونية المعتمدة على العنصر ..... 14
- الشكل 6: مصفوفة التقييم المبعثرة ..... 19
- الشكل 7: المزايا النموذجية لأنواع التجارب المختلفة المستخدمة في التقييم ..... 22
- الشكل 8: بنية "PersonalTVware" ..... 28
- الشكل 9 : بنية الشبكة العصبية متعددة الطبقات MLP ..... 37
- الشكل 10: توزيع المدة بناءً على عدد الأفلام والمسلسلات التي تمت مُشاهدتها ..... 38
- الشكل 11: عدد التوصيات الناجمة لكل خوارزمية في مجموعتي المعطيات ..... 39
- الشكل 12: نتائج المقياس الخامس على مجموعتي معطيات البحث ..... 40
- الشكل 13: نتائج المقياس السادس على مجموعة معطيات المسلسلات ..... 41
- الشكل 14: نتائج المقياس السادس على مجموعة معطيات الأفلام ..... 41
- الشكل 15: مقاييس التقييم الستة على مجموعتي المعطيات المستخدمة ..... 42
- الشكل 16: مخطط صفوف جداول بيانات تطبيق "ISHOW" ..... 64

## قائمة الجداول

- الجدول 1: مزايا وعيوب نظم التوصية ..... 20
- الجدول 2: تصنيف النتيجة المحتملة للتوصية بعنصر إلى مستخدم ..... 24
- الجدول 3: احصائيات عن معلومات تدريب "EPG" ..... 28
- الجدول 4: احصائيات عن معلومات اختبار "EPG" ..... 28
- الجدول 5: احصائيات عن معلومات تدريب "PersonalTVware" ..... 29
- الجدول 6: احصائيات عن معلومات اختبار "PersonalTVware" ..... 29
- الجدول 7: مقارنة نتائج الخوارزميات المتبعة في Netflix باستخدام مقياس RMSE ..... 29
- الجدول 8: مقارنة الخوارزميات المطبقة للبحث [78] باستخدام مقياس الخطأ RMSE ..... 30
- الجدول 9: بعض الخصائص الاحصائية لمجموعي المعطيات "MovieLens" و "Pinterest" ..... 30
- الجدول 10: مقارنة نتائج الاختبار على مجموعتي المعطيات لمجموعي المعطيات "MovieLens" و "Pinterest" ..... 30
- الجدول 11: بعض خصائص معطيات تدريب تطبيق ISHOW ..... 32
- الجدول 12: بعض خصائص معطيات اختبار تطبيق ISHOW ..... 32
- الجدول 13: مصفوفة مميزات الخدمات التي شاهدها المستخدم  $u$  ..... 33
- الجدول 14: نتائج تعظيم ميزة النوع على قيم التقييم باستخدام مقياسي التقييم Precision & Recall ..... 34
- الجدول 15: قيم معلمات نموذج ALS لحساب التقييم ..... 35

- الجدول 16: معلمات نموذج MLP لحساب التنبؤ بتفضيل المستخدم ..... 37
- الجدول 17: نتائج مقياسي التقييم الأول والثاني على مجموعتي معطيات البحث ..... 39
- الجدول 18: نتائج مقياس التقييم الثالث على مجموعتي معطيات البحث ..... 39
- الجدول 19: نتائج المقياس الرابع على مجموعتي معطيات البحث ..... 40
- الجدول 20: نتائج المقياس السادس على مجموعتي المعطيات المستخدمة ..... 42
- الجدول 21: نتائج مقارنة مقاييس التقييم المطبقة على مجموعة بيانات المسلسلات ..... 42
- الجدول 22: نتائج مقارنة مقاييس التقييم المطبقة على مجموعة معطيات الأفلام ..... 43

## قائمة المصطلحات والاختصارات

| المصطلح أو الاختصار                     | المعنى باللغة الانكليزية           | المعنى باللغة العربية                       |
|---|------------------------------------|---|
| IPTV                                    | Internet Protocol Television       | تلفاز بروتوكول الإنترنت                     |
| IP                                      | Internet Protocol                  | بروتوكول الإنترنت                           |
| VOD                                     | Videos On Demand                   | مقاطع الفيديو عند الطلب                     |
| RS                                      | Recommendation System              | نظام توصية                                  |
| Content-Based Recommendations           |                                    | أنظمة التوصية المعتمدة على المحتوى          |
| Collaborative Filtering Recommendations |                                    | أنظمة التوصية المعتمدة على الترشيح التعاوني |
| Hybrid Recommendations                  |                                    | أنظمة التوصية                               |
| Cosine Similarity                       |                                    | مقياس التشابه المعتمدة على تجيب الزاوية     |
| VSS                                     | Vector Space Similarity            |   |
| PCC                                     | Pearson Correlation Coefficient    |   |
| K-NN                                    | K-Nearest Neighbour                | خوارزمية أقرب جار                           |
| Weighted Average                        |                                    | المتوسط الموزون                             |
| Latent Factors                          |                                    | العوامل الكامنة                             |
| MF                                      | Matrix Factorization               | عامل المصفوفة                               |
| SVD                                     | Singular Value Decomposition       | نموذج تحليل القيمة المفردة                  |
| PCA                                     | Principal Component Analysis       | نموذج تحليل المكونات الأساسية               |
| PMF                                     | Probabilistic Matrix Factorization | نموذج تحليل المصفوفات الاحتمالي             |
| NMF                                     | Negative Matrix Factorization      | نموذج تحليل المصفوفات السلبي                |

|                                     |                           |                     |
|-------------------------------------|---------------------------|---------------------|
| نماذج التجميع                       |                           | Clustering models   |
| النماذج المعتمدة على المشي العشوائي | Random-walk based models  |                     |
|                                     | Alternating Least Squares | ALS                 |
|                                     | Markov Chain Monte Carlo  | MCMC                |
| التحليل الدلالي الكامن              | Latent Semantic Analysis  | LSI                 |
| التعمق العميق                       |                           | Deep Learning       |
| بعثرة المعطيات                      |                           | Data Sparsity       |
| تفضيلات المستخدم                    |                           | User Preference     |
| الدقة التنبؤية                      |                           | Predictive Accuracy |
| التغطية                             |                           | Coverage            |
| الوثوقية                            |                           | Confidence          |
| الثقة                               |                           | Trust               |
| الابتكار، الجودة                    |                           | Novelty             |
| المصادفة                            |                           | Serendipity         |
| التنوع                              |                           | Diversity           |
| المنفعة                             |                           | Utility             |
| الخطر                               |                           | Risk                |
| المثانة                             |                           | Robustness          |
| الخصوصية                            |                           | Privacy             |
| قابلية التكيف                       |                           | Adaptivity          |

|  |   |                                    |
|--|---|------------------------------------|
| الدقة                                    |   | Precision                          |
| الاسترجاع                                |   | Recall                             |
|  | Normalized Cumulative Discounted Gain           | NDCG                               |
|  | Discounted Cumulative Gain                      | DCG                                |
|  | Hit Ratio                                       | <i>HR</i>                          |
| النموذج المقترح الأول                    | Content Based                                   | CB                                 |
| النموذج المقترح الثاني                   | Matrix Factorization and K-Nearest Neighbour    | MF&KNN                             |
| تابع التكلفة                             |   | Cost Function                      |
| الإفراط في تجهيز البيانات                |   | Overfitting                        |
| تنظيم النموذج                            |   | Regularization Term                |
| شرط المرور على كافة عناصر مصفوفة التقييم |   | Completion Term                    |
| معامل التنظيم                            |   | $\lambda$                          |
| قيمة الخطأ في توقع التقييم               |   | <i>Error</i> <sub><i>i,j</i></sub> |
| النموذج المقترح الثالث                   | Neural Collaborative Filtering based on Actions | NCF-A                              |
| شبكة عصبية متعددة الطبقات                | Multi-layer Perceptron                          | MLP                                |
| خوارزمية الأمثلة                         | Optimization Algorithm                          |                                    |
| النموذج                                  |   | Model                              |
| مجموعة المعطيات                          |   | Dataset                            |
| مرحلة التدريب                            |   | Training                           |
| مرحلة الاختبار                           |   | Testing                            |

|  |  |                |
|--|--|----------------|
| طبقة الدخل للنموذج                     |  | Input Layer    |
| طبقة الخرج للنموذج                     |  | Output Layer   |
| الطبقات المخفية بين طبقتي الدخل والخرج |  | Hidden layers  |
| وزن الوصلة بين عصبونين                 |  | Weight         |
| التحسين الزوجي                         |  | Pairwise Loss  |
| التحسين النقطي                         |  | Pointwise Loss |
| تابع التنشيط                           | Activation Function                              | $\phi$         |
|  | Rectified Linear Unit                            | ReLU           |
| تقدير العزم المتكيف                    | Adaptive moment estimation                       | Adam           |
|  | Leave-One-Out Cross-Validation                   | LOOCV          |
| النموذج المقترح الرابع                 | Neural Collaborative Filtering based on Duration | NCF-D          |

## قائمة الرموز

|   |                     |
|---|---------------------|
| مصفوفة المستخدمين   | $U$                 |
| مصفوفة العناصر  | $V$                 |
| عدد المستخدمين  | $n= U $             |
| عدد العناصر   | $m= V $             |
| قيمة تقييم المستخدم $u_i$ للعنصر $v_j$  | $R_{i,j}$           |
| مصفوفة تقييمات المستخدمين للعناصر   | $R$                 |
| تقدير تقييم المستخدم $u_i$ للعنصر $v_j$   | $\hat{R}_{i,j}$     |
| المستخدم الفردي   | $u_i$               |
| العنصر الفردي   | $v_j$               |
| مجموعة المستخدمين الأكثر تشابهاً مع المستخدم $u_i$ والذين قاموا بتقييم العنصر $v_j$ . | $\hat{U}$           |
| عامل معايرة   | $B$                 |
| مقياس التشابه بين المستخدمين $u_k$ و $u_i$  | $sim(u_i, u_k)$     |
| مجموعة العناصر التي تم تقييمها من المستخدم $u_i$                                      | $S_i$               |
| التقييم الوسطي للمستخدم $u_i$   | $\bar{R}_i$         |
| التشابه بين المستخدم $u_i$ والمستخدم $u_k$  | $corr(u_i, u_k)$    |
| هي مجموعة من المستخدمين المشابهين للمستخدم $u_i$ الذين قاموا بتقييم العنصر $v_j$      | $N_j(i)$            |
| تعقيد إيجاد المستخدمين المشابهين  | $O( U )$            |
| مجموعة من الخدمات   | $I$                 |
| قيمة تقييم المستخدم $u$ للخدمة $i$  | $R_{u,i}$           |
| مستخدم فردي   | $u$                 |
| خدمة فردية  | $i$                 |
| مراكز العناقيد  | $H$                 |
| مستخدم جديد   | $a$                 |
| أعلى 10 جيران مشابهين ل $a$   | $A$                 |
| الخدمات التي لم يشاهدها المستخدم $a$ بعد  | $I_N$               |
| تقييم المستخدم $a$ على خدمة $i$   | $Predicit(a, i)$    |
| متوسط قيم التقييم للمستخدم $a$  | $\bar{R}_a$         |
| قيمة تفاعل المستخدم $u$ مع الخدمة $i$ أو مصفوفة التفاعل                               | $\gamma_{ui}$       |
| قيمة توقع تفاعل المستخدم $u$ مع الخدمة $i$ أو مصفوفة التوقع                           | $\hat{\gamma}_{ui}$ |
| عدد العوامل الكامنة   | $K$                 |
| تابع منفعة توصية عنصر $v_j$ للمستخدم  | $g_{u,i}$           |
| عدد العناصر ذات الصلة $k$ التي لاحظها المستخدم  | $e_k$               |
| مدة مشاهدة المستخدم $u$ للخدمة $i$ (فيلم، مسلسل)                                      | $t_{u,i}$           |
| مدة الخدمة الكلية $i$   | $t_i$               |

|   |                   |
|---|-------------------|
| مميزات الخدمات (ممثل، مخرج، كاتب، نوع)  | $c$               |
| المميزات التي تخص الخدمات التي شاهدها مستخدم ما   | $J_c$             |
| مجموعة الخدمات التي شاهدها المستخدم $u$ ضمن مجموعة التدريب  | $I_u^{train}$     |
| وزن الميزة $j$ في $J_c$ للمستخدم $u$  | $w_c(u, j)$       |
| قيمته 1 إذا الميزة $j$ موجودة ضمن الخدمة $i$ أو 0 إذا العكس   | $x_{c,u}(i, j)$   |
| تمثل المميزات التي تظهر في الخدمة $i$ من مجموعة المميزات $C$  | $D_{c,i}$         |
| عامل تعظيم لميزة النوع  | $f$               |
| أصغر قيمة تقييم للمستخدم $u$ ضمن مجموعة المميزات $C$ في مجموعة التدريب                              | $mR_{u,c}$        |
| أكبر قيمة تقييم للمستخدم $u$ ضمن مجموعة المميزات $C$ في مجموعة التدريب                              | $MR_{u,c}$        |
| تسوية قيم التقييم $R_c(u, i)$ للمستخدم $u$ ضمن مجموعة المميزات $C$ في مجموعة التدريب للخدمة $i$     | $\hat{R}_c(u, i)$ |
| مصفوفة العناصر  | $P$               |
| مصفوفة الأوزان في الطبقة $X$  | $w_X$             |
| شعاع الانحياز في الطبقة $X$   | $b_X$             |
| طبقات شبكة عصبية متعددة الطبقات   | $z_L$             |
| العناصر الملحوظة  | $Y$               |
| العناصر الغير ملحوظة  | $Y'$              |
| العوامل الكامنة للمستخدم $u$  | $p_{uk}$          |
| العوامل الكامنة للعنصر $q$  | $q_{ik}$          |
| معلمات النموذج  | $\theta_f$        |
| عدد العناصر الأكثر تشابهاً مع العناصر ذوي عدد المشاهدات تحت العتبة والمشار لها ب "0" في نموذج NCF-D | $S$               |
| يمثل الاختلاف بين العنصرين $v_j, v_q$   | $d(v_j, v_q)$     |
| قائمة الاقتراحات الواحدة  | $l_s$             |
| تنوع قائمة الاقتراحات $l_s$   | $f_D(l_s)$        |
| عدد جميع العناصر المقترحة   | $L$               |

## الفصل الأول: مدخل لموضوع البحث وأهميته

## 1-1 تمهيد

مع التطور السريع لتكنولوجيا المعلومات، يزداد حجم البيانات أيضاً يوماً بعد يوم، ويشعر الناس بشكل متزايد بالعجز في مواجهة كميات هائلة من البيانات لذلك نحتاج إلى نظام توصية لمساعدة المستخدمين في العثور على المنتجات التي يريدونها (أخبار، موسيقى... إلخ) حيث لا ينتبه الأشخاص إلا للعناصر ذات معدل العرض المرتفع ويتجاهلون العناصر ذات معدل العرض المنخفض. لم يتسبب هذا في إهدار استخدام الموارد فحسب، بل منع أيضاً العديد من المستخدمين ذوي الأذواق المتخصصة من العثور على المحتوى الذي يهتمون به. كل ذلك جعل من وجود أنظمة التوصية ضرورة أساسية للتعامل مع هذا الكم الكبير من المعلومات المتاحة، حيث تقوم هذه الأنظمة بتقديم اقتراحات العناصر للمستخدمين. تتضمن الاقتراحات عمليات صنع القرار المختلفة، مثل العناصر التي يجب شراؤها، الموسيقى التي يجب الاستماع إليها، الأخبار عبر الإنترنت التي يجب قراءتها، أو الأفلام التي يجب مشاهدتها بعد ذلك. يمكن تعريف مشكلة التوصية بأنها تقدير استجابة المستخدم للأغراض الجديدة بناءً على تاريخه السابق، وبالتالي اقتراح الأغراض التي من المتوقع أن تنال إعجابها منها. تم إنشاء نظام توصية YouTube في عام 2005 [1]، واحتل موقع YouTube المرتبة الثانية بين أكثر الشبكات الاجتماعية شهرة، حيث يملك 2.1 مليار مستخدم في جميع أنحاء العالم اعتباراً من عام 2021 ويتم دعم المحتوى بـ 80 لغة. كل يوم، يشاهد الأشخاص مليار ساعة من YouTube ويحصلون على مليارات المشاهدات. وفقاً للباحثين، لا يرجع نجاح YouTube إلى مجموعته الضخمة من مقاطع الفيديو فحسب، بل يرجع أيضاً إلى آليات اكتشاف الفيديو المتنوعة مثل محرك البحث المستند إلى الكلمات الرئيسية، وتوصيات الفيديو ذات الصلة، وتسليط الضوء على الفيديو على صفحة YouTube الرئيسية، واشتراك القناة، وإمكانية تضمين صفحات الويب والمدونات والشبكات الاجتماعية. بالنظر للحالات السابقة، تعتبر تقنيات استرجاع المعلومات والتقنيات المساعدة على اتخاذ القرار بشكل واسع كأدوات قيمة في هذا المجال.

## 2-1 دوافع البحث

تعتمد العديد من أنظمة التوصية على تقنيات بسيطة تقارن بين تفاعلات المستخدم مع العناصر التي تعامل معها في الماضي، حيث تقوم بتحليل ميزات العناصر التي تفاعل معها المستخدم لإنشاء اقتراحات مناسبة لهذا المستخدم. على سبيل المثال، إذا استمعت إلى أغنية من نوع معين، فسأحصل على الأغاني الموصى بها من هذا النوع المحدد. سمات الأغنية مثل العنوان وسنة الإصدار والمغني والآلات مفيدة أيضاً في تحديد الموسيقى المماثلة. تسمى هذه الأنظمة بالأنظمة المعتمدة على المحتوى **Content-Based Recommendations**. لا تحتاج تقنيات التوصية المستندة إلى المحتوى [2] إلى ملفات تعريف المستخدمين الآخرين لأنها لا تؤثر على التوصيات. لذلك، إذا تغير ملف تعريف المستخدم، فلا يزال بإمكان هذه التقنية تعديل التوصيات في غضون فترة زمنية قصيرة.

تعتمد مقارنة أخرى على بناء قاعدة بيانات للتفضيلات للعناصر من قبل المستخدمين السابقين، ثم يُطابق المستخدمين الجدد ذوي الاهتمامات والتفضيلات ذات الصلة عن طريق حساب أوجه التشابه بين ملفاتهم الشخصية مع الملفات الشخصية السابقة من أجل تقديم الاقتراحات المناسبة، حيث يحصل المستخدم على توصيات لتلك العناصر التي لم يتم بتصنيفها من قبل ولكن تم تصنيفها بشكل إيجابي من قبل مستخدمين آخرين لهم نفس الاهتمامات [3]. تسمى هذه الأنظمة بالأنظمة المعتمدة على الترشيح التعاوني **Collaborative Filtering Recommendations**.

هناك مقارنة ثالثة تعتمد على دمج التقنيتين السابقتين معاً للحصول على تحسين أفضل لنظام التوصية وتوفير توصيات أكثر دقة [4]، تدعى بالأنظمة الهجينة **Hybrid Recommendations**.

تعد قائمة Netflix الطويلة للأفلام والبرامج التلفزيونية المقترحة مثلاً رائعاً لتجربة مستخدم مخصصة. في الواقع، حوالي 70 بالمائة من كل ما يشاهده المستخدمون هو بالاعتماد على مقترحات نظام التوصية.

## 3-1 إشكالية البحث

تحتاج أنظمة التوصية أن تميز ردود فعل المستخدمين لكي تستطيع أن توصي بمنتجات تناسب اهتماماتهم ولذلك كانت ولا تزال تعتمد على ميزة التقييم التي تعكس قيمتها ردة فعل المستخدم، هذه الميزة تعتبر بيانات صريحة. تحظى البيانات الصريحة دائماً بقيمة أكثر وضوحاً من البيانات الضمنية، ولكن ذلك في حال قدم المستخدمون ملاحظات واضحة وكافية. يعد جمع المعلومات الصريحة صعباً بسبب الطبيعة البشرية حيث أغلبهم يميلون إلى التقييم في أقصى الحدود. يقيم المستخدمون كل شيء بانتظام على أنه 10 أو 1، لا يأخذ الكثير من الأشخاص الوقت الكافي لترك تصنيف 4 من 10 لأنه من الواضح أنه لم يكن لديهم رأي قوي في المقام الأول لذلك لجأ الباحثون في أنظمة التوصية للاستفادة من وفرة البيانات الضمنية. ولكن هناك العديد من أنظمة التوصية لا تحوي ميزة التقييم في بنيتها، ولذلك يتم الاعتماد على ردود فعل المستخدم الضمنية التي من شأنها أن تعكس مدى اهتمام المستخدم. يعد تقييم أداء أنظمة التوصية مسألة مهمة جداً فبصرف النظر عن قياس قوة التنبؤ لنظام التوصيات، من المهم جداً قياس كيفية أداء النموذج لتحقيق هدف العمل، قد يكون هدف العمل زيادة الإيرادات، وتحسين التجربة أو زيادة التفاعل داخل التطبيق. هناك مقاييس تقييم تشخيصية يمكن أن توفر تصورات إضافية ورؤى أعمق ومدهشة في بعض الأحيان حول أداء النموذج، فحسب مجال التطبيق يتم استخدام مقياس أداء التوصية المناسب. لذلك، يعتبر هدف هذه الأطروحة بناء عدة أنظمة توصية بالاعتماد على البيانات الضمنية المستمدة من تفاعل المستخدمين مع مجموعة مقاطع الفيديو أو المسلسلات مثل عدد المرات التي شاهدوا فيها فيلماً والمدة التي قضوها في مشاهدة مقطع فيديو أو مسلسل معين، وتقييم هذه الأنظمة بناءً على عدة مقاييس تقييم متنوعة واتخاذ القرار المناسب حسب مجال التطبيق.

## 4-1 فكرة الحل المقترح

نعمد في حلنا في هذه الأطروحة على الملاحظات الضمنية للمستخدم والتي يمكن استخراجها من سجل مشاهداته، ونقوم ببناء التقييم وفق هذه الملاحظات وإدخالها إلى نظام التوصية، أو نقوم بإدخال الملاحظات كما هي. تقوم فكرة الحل الأساسي على تجريب الطرق الشائعة لأنظمة التوصية ابتداءً من التقنيات الإحصائية وتعلم الآلة وانتهاءً بالتعلم العميق على مجموعتين مختلفتين من البيانات، بحيث نقوم بترتيب هذا الخوارزميات وفق كل معيار من معايير التقييم.



## الفصل الثاني: الإطار النظري العام

## 1-2 مقدمة

نظام التوصية هو فئة فرعية من نظام تصفية المعلومات الذي يسعى إلى التنبؤ بـ "التصنيف" أو "التفضيل" الذي قد يمنحه المستخدم لعنصر ما. في نظم التوصية يكون لدينا مجموعة من المستخدمين  $U = \{u_1, u_2, \dots, u_n\}$  ومجموعة من العناصر  $V = \{v_1, v_2, \dots, v_m\}$  حيث  $n$  هو عدد المستخدمين و  $m$  هو عدد العناصر. يقوم المستخدم  $u_i$  بتقييم مجموعة جزئية من العناصر ببعض القيم، ونستخدم الرمز  $R \in R^{n \times m}$  لنشير إلى مصفوفة التقييم (Rating Matrix) المعطاة من المستخدمين على العناصر، حيث  $R_{i,j}$  يمثل قيمة التقييم إذا قام المستخدم  $u_i$  بتقييم العنصر  $v_j$ ، وإلا نستخدم الرمز "?" لنشير إلى التقييم غير المعروف كما هو موضح في الشكل 1. تكون مصفوفة التقييم عادة مبعثرة جداً، حيث هناك الكثير من القيم غير المعروفة للتقييمات في  $R$ . مثلاً، كثافة مصفوفة التقييم في أنظمة التوصية التجارية هو غالباً أقل من 1% [5].

|       | $v_1$ | $v_2$ | $v_3$ | ... | $v_m$ |
|-------|-------|-------|-------|-----|-------|
| $u_1$ | 2     | 3     | ?     | ... | 5     |
| $u_2$ | ?     | 4     | 3     | ... | ?     |
| $u_3$ | 3     | 2     | ?     | ... | 3     |
| ...   | ...   | ...   | ...   | ... | ...   |
| $u_n$ | 1     | ?     | 5     | ... | 4     |

الشكل 1: مصفوفة التقييم

بالعموم يمكن تعريف مهمتين أساسيتين لنظم التوصية:

- التنبؤ بالتقييم (Rating predication): وفيها يتم تخمين القيم المفقودة في  $R$  اعتماداً على التقييمات المعروفة، والقيم المتنبأ بها يجب أن تكون في مجال التقييمات التي يمكن للمستخدم أن يعطيها للعنصر والمحددة من قبل نظام التوصية مثلاً،  $[1, 10]$ ،  $[1, 5]$  ... إلخ.

- التوصية بـ  $N$  عنصر الأوائل (Top-N Recommendation): وفيها يتم التوصية للمستخدم بقائمة من العناصر التي تم تخمينها على أنها الأكثر تفضيلاً من قبله، بحيث أن العناصر التي يتم تحديدها في قائمة التوصية يجب ألا تكون قد استهلكت سابقاً من قبل ذلك المستخدم.

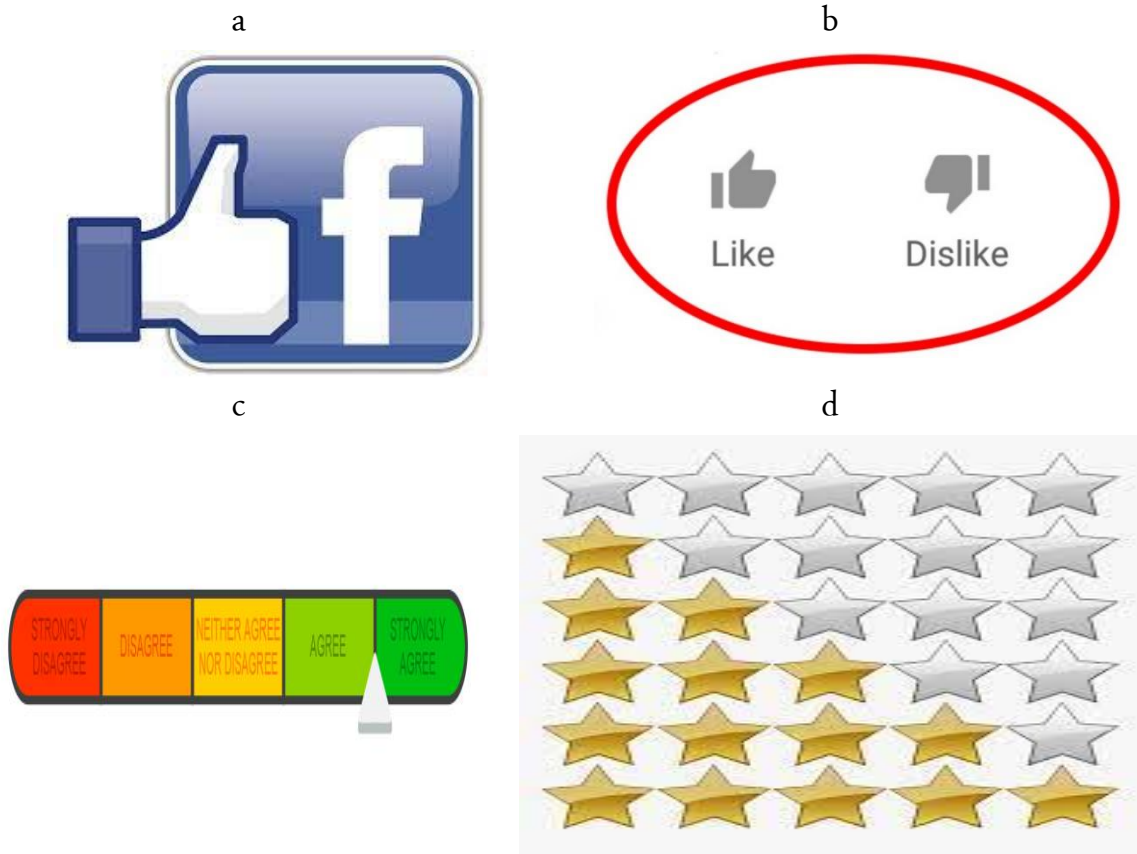
يتم التركيز في الأطروحة على المهمتين المذكورتين، بحيث قد يكون نتيجة إحدى طرق التوصية المستخدمة بالاعتماد على المهمة الأولى، دخلاً للطرق الأخرى المعتمدة على المهمة الثانية، إلا أن نتيجة التنبؤ بالتقييم يمكن تحويلها إلى توصيات عن طريق التوصية بالعناصر التي لها التقييمات الأعلى المتنبأ بها بالنسبة لمستخدم محدد. هذه الطريقة بسيطة لكنها ليست فعالة دوماً، حيث أن التنبؤ الجيد بالتقييمات ليس بالضرورة أن ينعكس بتوصيات جيدة نظراً لوجود العديد من الاعتبارات الأخرى التي يجب مراعاتها أثناء تقديم التوصيات. وهناك طرق أكثر تطوراً للتوصية بـ  $N$  عنصر الأوائل كما سنها لاحقاً.

## 2-2 أنواع آراء المستخدمين في أنظمة التوصية

تتطلب معظم أنظمة التوصية معرفة حول تفضيلات المستخدمين وسلوكهم من أجل تقديم توصيات فعالة. يتم تجميع المعلومات الخاصة بالمستخدمين عادةً بواسطة الآراء المعبر عنها من قبلهم أثناء تفاعلهم مع النظام، حيث يتم تصنيف هذه الآراء وفقاً لكيفية جمعها [6].

**1-2-2 آراء صريحة (Explicit Feedback):** وهي الآراء التي يتم تزويدها صراحة من قبل المستخدمين على شكل تقييمات تمثل تفضيلاتهم على العناصر، هذه التقييمات مرتبطة مع مجال محدد من القيم يدعى مقياس التقييم. الحالة الأبسط منه هي مقياس التقييم الأحادي (unary)

(scale) والذي يشير إلى أن المستخدم معجب بعنصر معين كما في حالة تطبيق "Facebook" قديماً مثلاً الشكل (2-a). كذلك هناك مقياس تقييم ثنائي والذي بالإضافة لوجود مؤشر الإعجاب (like) بالعناصر فيه، يكون هناك أيضاً مؤشر لعدم الإعجاب (dislike) كما هو الحال في تطبيق "YouTube" مثلاً الشكل (2-b)، علماً أن غياب رأي المستخدم عن عنصر معين في حالة التقييمات الأحادية غير مكافئ لمؤشر عدم الإعجاب. الحالة الأكثر شيوعاً لمقياس التقييم هي حالة المقاييس ذات الخمس نقاط (5-point scale) أو (10-point scale) كما هو الحال في موقع "MoviePilot" وموقع "Netflix" مثلاً الشكل (2-c) (2-d) على التوالي، والتي تجعل المستخدم يعبر عن مستويات دقيقة من التفضيلات. نلاحظ هنا أنه بصرف النظر عن المقياس المستخدم، يمكن للمستخدم إسناد قيمة واحدة فقط إلى كل عنصر معطى.



الشكل 2: أمثلة عن آراء المستخدم الصريحة في موقع الخدمات على الإنترنت

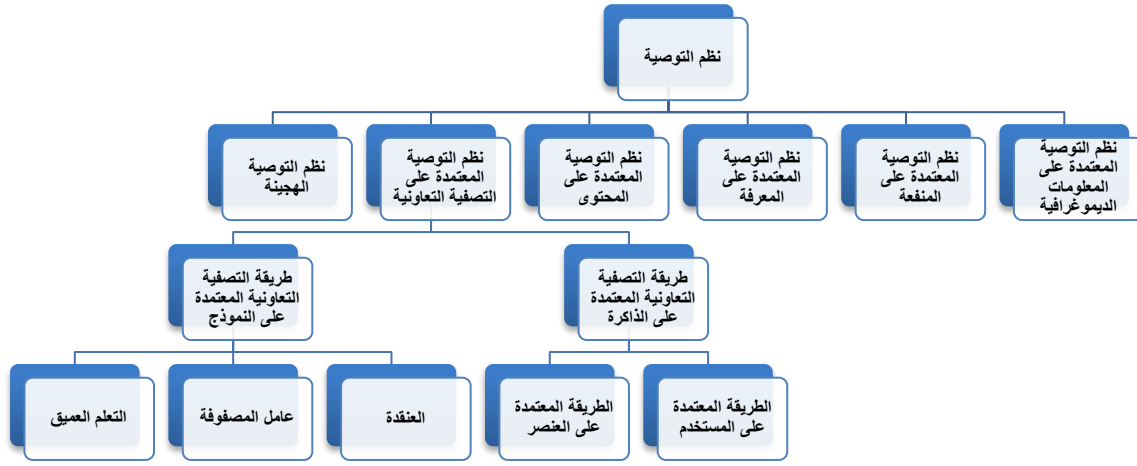
2-2-2 آراء ضمنية (Implicit Feedback): وهي الآراء التي يتم جمعها بشكل آلي عندما يتفاعل المستخدمون مع النظام عن طريق مراقبة سلوكهم عند استعراض المنتجات مثلاً أو شرائها في مواقع التجارة الإلكترونية، أو مراقبة الوقت الذي يتم قضاؤه في استهلاك الخدمات على الإنترنت كمشاهدة برنامج تلفزيوني أو تشغيل عدد من الأغاني، أو مراقبة حركات الفأرة أو حتى عينات البحث، كل ذلك يمكن استخدامه كطريقة لمعرفة تفضيلات المستخدمين بالنسبة للعناصر [7]. هذا النوع من الآراء لا يعكس دوماً تفضيلات المستخدم الفعلية، لأن استخدام أو استهلاك عنصر لا يشير بالضرورة لتفضيلات المستخدم بالنسبة لذلك العنصر. مثلاً، قد يتم افتراض أن المدة الطويلة التي يقضيها المستخدم في مشاهدة برنامج تلفزيوني معين هي بمثابة مؤشر إيجابي لإعجاب المستخدم بهذا البرنامج، لكن الحقيقة قد تكون أن المستخدم ربما نسي التلفاز يعمل خلال فترة عرض البرنامج ويقوم بنشاط آخر ولا يشاهده، مما يجعل هذه الفرضية غير صحيحة. علاوة على ذلك، في الآراء الضمنية قد يكون من الصعب تحديد ماهي العناصر غير المرغوب بها من قبل المستخدمين، إذ أنّ عدم استهلاك عنصر (مثلاً عدم مشاهدة برنامج تلفزيوني أو عدم شراء منتج ما) لا يمكن اعتباره رأياً سلبياً تجاه هذا العنصر، إذ أنّ المستخدم ربما لا يعلم عن هذا العنصر في الأصل.

على العموم من الأصعب الحصول على الرأي الصريح أكثر من الرأي الضمني، حيث يكون بعض المستخدمين مترددين في تزويد التقييمات نظراً لاعتبارات الخصوصية، الجهد المعرفي المطلوب، إلخ [8]. بينما في الرأي الضمني، قد يكون تفاعل المستخدم بشكل صريح مع النظام غير مطلوب للحصول على تفضيلاته تجاه عناصر معينة، مما يجعل الآراء الضمنية عادةً متاحة بشكل أكبر، الأمر الذي له أهمية أساسية في السيناريوهات العملية. من جهة أخرى، يتم اعتبار الآراء الصريحة ذات جودة ووثوقية أكثر من الآراء الضمنية التي لا تمثل تفضيلات المستخدمين بشكل مباشر وصريح، أما يتم استنتاجها من تفاعلاتهم مع النظام، لذلك معظم الأعمال على أنظمة التوصية قد ركزت على معالجة آراء المستخدم الصريحة [7]، [8]، ويبقى للآراء الضمنية أهميتها العالية في تقديم التوصيات عند عدم توفر آراء صريحة للمستخدمين، كما يمكن استخدام كلا النوعين من الآراء معاً لزيادة دقة التوصيات.

## 2-3 أنواع أنظمة التوصية

يمكن تخمين التقييمات على العناصر بعدة أساليب مختلفة باستخدام طرق من مجال التعلم الآلي، نظرية التقارب، ومنهجيات تجريبية متنوعة [9]. الصيغة المقبولة عموماً لمشكلة التوصية تم ذكرها أولاً في [10]، [11]، وقد تمت دراسة هذه المشكلة بشكل واسع منذ ذلك الحين. أصبحت نظم التوصية مجالاً بحثياً مستقلاً في منتصف التسعينات، ونتيجة لذلك كان هناك العديد من نظم التوصية المقترحة، والتي يمكن تجميعها عموماً اعتماداً على نوع المعطيات المطلوبة لتوليد التوصيات وكيفية القيام بالتوصية إلى الأنواع التالية [12] الشكل (3):

- نظم التوصية المعتمدة على المعلومات الديموغرافية (Demographic-based RSs): وفيها يتم التوصية للمستخدم بالعناصر التي يجدها مستخدمون مشابهون له من حيث المعلومات الديموغرافية (مثل العمر، الجنس، الإقامة، المهنة.. إلخ) حيث يتم تصنيف المستخدم اعتماداً على هذه المعلومات لتعلم العلاقة بين العناصر ونوع الأشخاص الذين يحبونها، ومن ثم تقديم توصيات اعتماداً على التصنيف الديموغرافي.
  - نظم التوصية المعتمدة على المنفعة (Utility-based RSs): وفيها يتم التوصية للمستخدم اعتماداً على حساب المنفعة من كل عنصر بالنسبة لذلك المستخدم. لا تهتم تقنيات التوصية المعتمدة على المنفعة بالتقييمات على العناصر، إنما تحتاج لتوصيفات مزايا تلك العناصر لاستنباط تابع منفعة من خلالها وتحديد تفضيلات المستخدم، ومن ثم تطبيق هذا التابع لتحديد ترتيب العناصر بالنسبة للمستخدم الذي يتم التوصية له، بالتالي هي أكثر ملاءمة لمشاكل الترتيب من مشاكل التنبؤ بالتقييمات الدقيقة.
  - نظم التوصية المعتمدة على المعرفة (Knowledge-based RSs): وفيها يتم التوصية للمستخدم اعتماداً على المعرفة المبينة حول المستخدمين والعناصر. وهي مشابهة لنظم التوصية المعتمدة على المنفعة من حيث كونها تعتمد على مزايا العناصر ولا تحتاج للتقييمات، وبدلاً من تابع المنفعة، يتم استنتاج التوصيات من احتياجات المستخدمين وتفضيلاتهم.
  - نظم التوصية المعتمدة على المحتوى (Content-based RSs): وفيها يتم التوصية للمستخدم بالعناصر المشابهة للعناصر التي قد أحبها المستخدم في الماضي.
  - نظم التوصية الهجينة (Hybrid RSs): وفيها يتم دمج اثنين أو أكثر من تقنيات نظم التوصية المختلفة بهدف الحصول على توصيات ذات دقة وجودة أعلى من خلال تجنّب عيوب التقنيات الفردية والاستفادة من مزاياها.
- إن طرق التوصية الأكثر نضوجاً واستخداماً في أبحاث نظم التوصية بالعموم هي: الطريقة المعتمدة على المحتوى، والطريقة المعتمدة على التصنيفية التعاونية، والطريقة الهجينة. لذا في المقاطع اللاحقة، سوف نتكلم بشكل مفصل أكثر عن هذه الأصناف الثلاثة مع الأنظمة المماثلة لها والمشاكل التي تعاني منها.



الشكل 3: أصناف نظم التوصية

### 1-3-2 نظم التوصية المعتمدة على المحتوى

إنّ نظم التوصية المعتمدة على المحتوى لديها جذورها في أبحاث فلتر المعلومات (Information Filtering) واسترجاع المعلومات (Information Retrieval) [13]، وهي تقوم بالتوصية بعناصر مشابهة للعناصر التي أحبها المستخدم في الماضي. بسبب التطورات الباكورة والهامة من قبل مجتمعات استرجاع وفلتر المعلومات وبسبب وفرة وأهمية التطبيقات المعتمدة على النص، فإنّ معظم أنظمة التوصية الموجودة المعتمدة على المحتوى تركّز على التوصية بمعلومات نصية مثل الأخبار، الكتب، المستندات، روابط موقع الويب (URLs)، الرسائل الإخبارية... إلخ. إنّ التحسين الذي تقدمه الطرق المعتمدة على المحتوى مقارنةً مع طرق فلتر واسترجاع المعلومات التقليدية يأتي من استخدام الملفات الشخصية للمستخدمين (user profiles) والتي تحوي معلومات حول أذواقهم، وتفضيلاتهم، واحتياجاتهم وكذلك ملفات العناصر (item profiles) التي تحوي خصائصهم ومزاياهم. يمكن استنتاج معلومات الملفات الشخصية للمستخدمين إمّا بشكل صريح من خلال استبيانات مثلاً أو يتم تعلّمها بشكل ضمني من سلوكيات المناقالات الخاصة بالمستخدمين عبر الزمن [9]. على الرغم من فوائد نظم التوصية المعتمدة على المحتوى ومزاياها إلا أنّها تعاني من عدّة قيود أهمّها:

#### ● التحليل المقيّد للمحتوى

إنّ الأنظمة المعتمدة على المحتوى مقيّدة بالمزايا المرتبطة بشكل صريح مع العناصر التي توصي بها هذه الأنظمة. لذلك حتى يكون لدينا مجموعة كافية من المزايا، يجب أن يكون المحتوى بالشكل الذي يمكن عمل استخراج آلي له من قبل الحاسوب (مثلاً، نص) وإلاّ يجب إسناد المزايا إلى العناصر يدوياً. بينما تعمل تقنيات استرجاع المعلومات جيداً في استخراج المزايا من المستندات النصية، فإنّ بعض المجالات الأخرى لديها مشاكل موروثّة مع استخراج المزايا الآلي. مثلاً، تطبيق طرق الإستخراج الآلي للمزايا على معطيات الوسائط المتعددة مثل الصور، الصوت والفيديو أصعب بكثير من النص، كما أنّه من غير العملي إسناد الخصائص يدوياً نظراً لقيود الموارد [11].

مشكلة أخرى مع التحليل المقيّد للمحتوى هي أنّه إذا كان لدينا عنصران مختلفان قد تمّ تمثيلها بواسطة نفس المجموعة من المزايا، فهذا غير قابلين للتمييز بينها. لذلك، بما أنّه يتم تمثيل المستندات النصية عادةً بواسطة الكلمات المفتاحية الأكثر أهمية، لا يمكن لنظم التوصية المعتمدة على المحتوى التمييز بين المقالات المكتوبة جيداً والمقالات المكتوبة بشكل سيء إذا استخدمت نفس المصطلحات. مثلاً، تقنية "TF-IDF" المستخدمة بكثرة تتجاهل ترتيب الكلمات لذلك لا يمكن إخبار الفرق بين مستنديّن إذا كان لهما نفس ترددات الكلمات [11].

## ● التخصيص الزائد (Over specialization)

إنّ نظام التوصية المعتمد على المحتوى سيوصي فقط بالعناصر المشابهة لتلك التي قام المستخدم بتقييمها بشكل إيجابي سابقاً، لذلك تميل التوصيات لأن تصبح مخصصة جداً بشكل متزايد [14]. مثلاً، إذا لم يذهب المستخدم الذي يحب الطعام الإيطالي إلى مطعم يوناني من قبل، فإنّ نظام التوصية المعتمد على المحتوى من غير المحتمل أن يوصي بمطعم يوناني إلى ذلك المستخدم، حتى أفضل مطعم يوناني في المدينة لا يُوصى له به. هذا لأنّه مقارنة بالمطاعم الإيطالية، لا يمكن أن يكون المطعم اليوناني مشابهاً بما فيه الكفاية للتوصية به. علاوة على ذلك، قد لا يريد المستخدم توصيات بهذا القدر من التشابه، مثلاً، المستخدم الذي اشترى كتاباً مؤخراً وأعطاه تقييماً عالياً، هذا لا يعني أنّه يريد شراء كل الإصدارات الأخرى من هذا الكتاب. لذلك، في بعض الحالات، تحتاج نظم التوصية المعتمدة على المحتوى لفلتر العناصر المشابهة جداً للعناصر التي اشترتها سابقاً [15]. تتم معالجة هذه المشكلة غالباً، والتي تمت دراستها أيضاً في مجالات أخرى، عن طريق تقديم بعض العشوائية مثل استخدام الخوارزميات الجينية التي تم اقتراحها كحل ممكن في سياق مجال استرجاع المعلومات [16]. كذلك بعض التوصية المعتمدة على المحتوى مثل "Daily Learner" [15]، يقوم بفلتر العناصر ليس فقط إذا كانوا مختلفين جداً عن تفضيلات المستخدم لكن أيضاً إذا كانوا مشابهيين جداً لشيء قد رآه المستخدم سابقاً. لا يزال موضوع نقص التنوع قضية هامة بالنسبة لأنظمة التوصية المعتمدة على المحتوى. من الناحية المثالية، يجب أن يُقدم للمستخدم مجموعة من الخيارات وليس مجموعة من البدائل المتجانسة (المتأثلة)، حيث أنّه ليس بالضرورة أن تكون التوصية بكل الأفلام الخاصة بـ "Woody Allen" مثلاً إلى مستخدم قد أحبّها هي فكرة جيدة.

## ● مشكلة المستخدم الجديد

يجب على المستخدم أن يقوم بتقييم عدد كاف من العناصر قبل أن يستطيع نظام التوصية المعتمد على المحتوى أن يفهم حقاً تفضيلات هذا المستخدم وأن يقدم له توصيات موثوقة. لذلك فإن المستخدم الجديد الذي لديه القليل من التقييمات لن يحصل على توصيات دقيقة. اقترحت عدة تقنيات لمعالجة هذه المشكلة، يستخدم معظمها الطريقة الهجينة والتي تدمج التقنيات المعتمدة على المحتوى والتقنيات التعاونية معاً (والتي سنتكلم عنها لاحقاً).

## 2-3-2 نظم التوصية المعتمدة على التصفية التعاونية

إنّ تقنية التصفية التعاونية هي إحدى التقنيات الأكثر شيوعاً لبناء أنظمة التوصية [17]، [18]، [19]. الفرضية الأساسية لها هي أنّه إذا توافق المستخدمون مع بعضهم في الماضي، من المحتمل أن يتوافقوا مع بعضهم في المستقبل. على خلاف أنظمة التوصية المعتمدة على المحتوى، تحاول هذه النظم التنبؤ بالتقييم على العناصر من قبل مستخدم محدد اعتماداً على التقييمات المعبر عنها سابقاً من قبل نفس المستخدم ومستخدمين آخرين مشابهيين له. نلاحظ أنّنا لانستخدم توصيفات العناصر في نظم التوصية التعاونية وهذا منطقي بما أنّه ليس بالإمكان دوماً الحصول على مزايا العناصر. مثلاً، في التطبيق الخاص بالتوصية بالأفلام، للتنبؤ بالتقييم المعطى من المستخدم  $u_i$  على الفيلم  $v_j$ ، يحاول نظام التوصية التعاوني إيجاد مستخدمين مشابهيين للمستخدم  $u_i$  أي مستخدمين آخرين قاموا بتقييم نفس الأفلام بشكل مشابه. بعد ذلك، نجمع التقييمات المعبر عنها على الفيلم  $v_j$  من قبل أولئك المستخدمين المشابهيين واعتبارها تقييماً مُنتبأً به للمستخدم  $u_i$ . في النهاية، نقوم بالتوصية فقط بالأفلام التي لها التقييم المنتبأً به الأعلى (أي الأكثر تفضيلاً من قبل الأقران) إلى ذلك المستخدم. هناك العديد من نظم التوصية التعاونية المطوّرة في الأوساط الأكاديمية والصناعية. يمكن القول أنّ أنظمة التوصية "GroupLens" [20]، "Video Recommender" [21]، "Ringo" [22] من أوائل الأنظمة التي استخدمت خوارزميات التوصية التعاونية لأتمتة عملية التنبؤ. هناك أمثلة أخرى على نظم التوصية التعاونية تتضمن نظام التوصية بالكتب من "Amazon" [23]، ونظام "PHOAKS" الذي يساعد الأشخاص على إيجاد المعلومات ذات الصلة على الإنترنت [24].

يمكن تجميع خوارزميات التصفية التعاونية إلى صنفين أساسيين:

- طرق التصفية التعاونية المعتمدة على الذاكرة أو تعرف أحياناً بطرق التصفية التعاونية المعتمدة على الجوار.

• طرق التصفية التعاونية المعتمدة على النموذج.

إن الخوارزميات المعتمدة على الذاكرة هي في أساسها عبارة عن أساليب تجريبية والتي تقوم بالتنبؤ بالتقييم اعتماداً على المجموعة الكاملة من العناصر التي تم تقييمها بشكل مسبق من قبل المستخدم. بينما تستخدم الخوارزميات المعتمدة على النموذج مجموعة التقييمات لتعلم نموذج ولا يحتاج بعد ذلك للولوج إلى كامل التقييمات مجدداً حيث يمكننا تخزين بارامترات النموذج التي تم تعلمها واستخدامها لاحقاً لحساب التنبؤات. على خلاف الطرق المعتمدة على الذاكرة، فإن الطرق المعتمدة على النموذج لديها مرحلة تعلم والتي قد تكون مستهلكة للوقت. من جهة أخرى، الطرق المعتمدة على الذاكرة أبطأ في جزء التنبؤ بالتقييم لأن مهمتها تتضمن استكشاف التقييمات بأكملها بشكل تجريبي، بينما الطرق المعتمدة على النموذج سريعة جداً لأنها تستخدم وسطاء النموذج فقط لحساب التقييم المتنبأ به. كذلك الطرق المعتمدة على الذاكرة سهلة التحقيق وتعطي قيمة تنبؤ جيدة لهذا السبب هي مفضلة من قبل العديد من الشركات التجارية مثل "Google"، "Amazon"، "Netflix" [19]. بينما الطرق المعتمدة على النموذج من الصعب تحقيقها عادةً وتأخذ وقتاً أكبر لبناء نظام التوصية، وتعطي تنبؤات أفضل نسبياً مع خطر فقدان معلومات هامة، حيث إن معظمها تقوم بنوع من الضغط أو التلخيص للمعلومات. فيما يلي، سوف نتكلم عن هذين النوعين من الطرق بتفصيل أكثر.

### 2-3-2 طرق التصفية التعاونية المعتمدة على الذاكرة

إن الطرق المعتمدة على الذاكرة هي طرق التنبؤ الأكثر شيوعاً وقد تم اعتمادها على نطاق واسع في العديد من نظم التصفية التعاونية التجارية [10]، [23]. كما ذكرنا، فإن الخوارزميات المعتمدة على الذاكرة هي عبارة عن أساليب تجريبية بشكل أساسي والتي تجعل التنبؤ بالتقييم معتمداً على المجموعة الكاملة من العناصر التي تم تقييمها سابقاً من قبل المستخدمين. لذلك، يتم حساب قيمة التقييم غير المعروف  $\hat{R}_{ij}$  بالنسبة للمستخدم  $u_i$  والعنصر  $v_j$  عادةً كتجميع لتقييمات بعض المستخدمين الآخرين (عادةً  $N$  مستخدم الأكثر تشابهاً) بالنسبة لنفس العنصر كما يلي:

$$\hat{R}_{ij} = \text{aggr}_{u_k \in \bar{U}} R_{kj} \quad (1)$$

حيث تشير  $\bar{U}$  إلى مجموعة المستخدمين الأكثر تشابهاً مع المستخدم  $u_i$  والذين قاموا بتقييم العنصر  $v_j$ . بعض الأمثلة عن توابع التجميع لدينا [9]:

$$\begin{aligned} a) \quad \hat{R}_{ij} &= \frac{1}{N} \sum_{u_k \in \bar{U}} R_{kj} \\ b) \quad \hat{R}_{ij} &= K \sum_{u_k \in \bar{U}} \text{sim}(u_i, u_k) R_{kj} \\ c) \quad \hat{R}_{ij} &= \bar{R}_i + b \sum_{u_k \in \bar{U}} \text{sim}(u_i, u_k) (R_{kj} - \bar{R}_k) \end{aligned} \quad (2)$$

حيث يعمل  $b$  كعامل معايرة ويتم اتخاذه عادة وفق العلاقة  $b = 1 / \sum_{u_k \in \bar{U}} |\text{sim}(u_i, u_k)|$ ، ويتم تعريف التقييم الوسطي للمستخدم  $u_i$  أي  $\bar{R}_i$  في المعادلة كما يلي:

$$\bar{R}_i = (1/|S_i|) \sum_{v_j \in S_i} R_{ij} \quad (3)$$

حيث  $S_i$  هي مجموعة العناصر التي تم تقييمها من قبل المستخدم  $u_i$  أي  $S_i = \{v_j \in V | R_{ij} \neq \emptyset\}$ . في الحالة الأبسط، يمكن أن يكون تابع التجميع هو متوسط بسيط كما هو معرف في المعادلة (2 a). إلا أن طريقة التجميع الأكثر شيوعاً هي استخدام المجموع الموزون الظاهر في المعادلة (2 b)، حيث مقياس التشابه بين اثنين من المستخدمين " $\text{sim}(u_i, u_k)$ " (والذي سنتكلم عن أنواعه لاحقاً) هو في الجوهر مقياس مسافة ويتم استخدامه كوزن، أي كلما كان المستخدمان  $u_i$  و  $u_k$  أكثر تشابهاً كلما كان للمستخدم  $u_k$  وزن تقييم أكبر ليتم استخدامه في التنبؤ بقيمة  $\hat{R}_{ij}$ . إحدى المشاكل مع استخدام المجموع الموزون كما في المعادلة (2 b)، هي أنه لا يأخذ بالاعتبار حقيقة أن مستخدمين مختلفين قد يستخدمان مقياس التقييم بشكل مختلف، لذلك تم استخدام المجموع الموزون المعدل الظاهر في

المعادلة (2 c) على نطاق واسع لمعالجة هذا القيد. في هذه الطريقة، بدلاً من استخدام القيم المطلقة للتقييمات، يتم استخدام الانحرافات عن التقييم الوسطي للمستخدم المقابل في حساب المجموع الموزون. يمكن تقسيم طرق التوصية التعاونية المعتمدة على الذاكرة بشكل إضافي إلى:

- طرق التوصية التعاونية المعتمدة على المستخدم.
- طرق التوصية التعاونية المعتمدة على العنصر.

تتنبأ طرق التوصية التعاونية المعتمدة على المستخدم بالتقييم غير المعروف من مستخدم على عنصر كمتوسط الموزون لكل التقييمات المعطاة من المستخدمين المشابهين له على ذلك العنصر، بينما تتنبأ طرق التوصية التعاونية المعتمدة على العنصر بذلك التقييم اعتماداً على متوسط التقييمات للعناصر المشابهة لذلك العنصر والتي تم تقييمها من قبل نفس المستخدم. فيما يلي سنتكلم على هذين النوعين من الطرق بتفصيل أكثر.

### 2-3-2-1 طرق التوصية التعاونية المعتمدة على المستخدم

تعرف أيضاً بطريقة الـ K جار الأقرب "K-NN" (K-Nearest Neighbour)، وهي طريقة التوصية التعاونية الآلية الأولى التي تم إيجادها [10]. تقدم هذه الطريقة تنبؤات بشأن اهتمامات المستخدم عن طريق تجميع معلومات حول أذواق مستخدمين متشابهين [26] كما هو موضح في (الشكل 4)، والفرضية الأساسية لها هي أن المستخدمين الذين يتوافقون في الماضي يميلون لأن يتوافقوا مجدداً في المستقبل. مثلاً النظم الناصحة المعتمدة على التوصية التعاونية من أجل التوصية ببرامج تلفزيونية قد تقدم تنبؤات حول فيما لو كان مستخدم محدد يجب برنامجاً تلفزيونياً بإعطاء قائمة جزئية من أذواق المستخدم وكذلك آراء مستخدمين آخرين بأذواق مشابهة.



الشكل 4: طريقة التوصية التعاونية المعتمدة على المستخدم

حتى تعمل طريقة التوصية التعاونية المعتمدة على المستخدم، تحتاج تابعاً لحساب التشابه بين المستخدمين وكذلك طريقة لاستخدام التقييمات وقيمة التشابه في حساب التنبؤ، حيث حساب التشابه هو خطوة هامة بالنسبة للطرق المعتمدة على المستخدم وهناك عدة تقنيات مقترحة للقيام بذلك، والتي من بينها طريقة حساب التشابه المعتمدة على تجيب الزاوية بين الأشعة الخاصة بالمستخدمين أي "Cosine Similarity" أو ما يُعرف بـ "Vector Space Similarity" أو "VSS"، وطريقة حساب التشابه المعتمدة على مقدار الارتباط بين المستخدمين "Coefficient Pearson Correlation" أو "PCC" [10] هي الطرق الأكثر استخداماً على نطاق واسع.

- مقياس "VSS"

في هذه الحالة، يتم اعتبار المستخدمين كشعاعين في فضاء عناصر ذي بعد  $N$ ، ويتم قياس التشابه بينهما عن طريق حساب تجيب الزاوية بين هذين الشعاعين. وبالتالي في مصفوفة التقييمات ذات البعد  $N \times M$  يتم إعطاء التشابه بين المستخدم  $u_i$  والمستخدم  $u_k$  المشار له وفق العلاقة  $sim(u_i, u_k)$  كما يلي:

$$sim(u_i, u_k) = \cos(\vec{u}_i, \vec{u}_k) = \frac{\vec{u}_i \cdot \vec{u}_k}{\|\vec{u}_i\|_2 \times \|\vec{u}_k\|_2} = \frac{\sum_{V_j \in V_{i,k}} R_{ij} R_{kj}}{\sqrt{\sum_{V_j \in V_{i,k}} R_{ij}^2} \sqrt{\sum_{V_j \in V_{i,k}} R_{kj}^2}} \quad (4)$$

حيث تشير " " إلى الجداء الداخلي للشعاعين ويشير "  $\| \cdot \|_2$  " إلى ال "  $L_2$  norm" للشعاع، كما تشير  $V_{i,k}$  إلى مجموعة العناصر التي تم تقييمها من قبل المستخدمين  $u_i$  و  $u_k$  معاً.

- مقياس "PCC"

في هذه الحالة، يتم قياس التشابه بين المستخدم  $u_i$  والمستخدم  $u_k$  عن طريق حساب "Pearson-r correlation" أي  $corr(u_i, u_k)$  المشار له بـ  $sim(u_i, u_k)$  كما يلي:

$$sim(u_i, u_k) = corr(u_i, u_k) = \frac{\sum_{V_j \in V_{i,k}} (R_{ij} - \bar{R}_i)(R_{kj} - \bar{R}_k)}{\sqrt{\sum_{V_j \in V_{i,k}} (R_{ij} - \bar{R}_i)^2} \sqrt{\sum_{V_j \in V_{i,k}} (R_{kj} - \bar{R}_k)^2}} \quad (5)$$

تشير  $\bar{R}_i$  هنا إلى متوسط التقييمات المعبر عنها بواسطة المستخدم  $u_i$ ، وتتراوح قيمة التشابه بين المستخدمين في هذا المقياس من -1 إلى +1 والقيمة الأكبر تعني أن المستخدمين أكثر تشابهاً.

الآن وبعد الحصول على قيم التشابه بين المستخدمين، تقوم نظم التوصية التعاونية المعتمدة على المستخدم بالتنبؤ بالتقييم المعطى من قبل المستخدم  $u_i$  على العنصر  $v_j$  اعتماداً على التقييمات المعطاة للعنصر  $v_j$  من قبل مجموعة من المستخدمين الذين سجلات التقييم الخاصة بهم أكثر تشابهاً مع سجلات التقييم للمستخدم  $u_i$ . هناك عدة استراتيجيات للتنبؤ بالتقييم، أشهرها صيغة المتوسط الموزون (Weighted Average) المعرفة كما يلي:

$$\hat{R}_{ij} = \frac{\sum_{u_k \in N_j(i)} sim(u_i, u_k) R_{kj}}{\sum_{u_k \in N_j(i)} sim(u_i, u_k)} \quad (6)$$

حيث تشير  $\hat{R}_{ij}$  إلى التقييم المتوقع به،  $N_j(i)$  هي مجموعة من المستخدمين المشابهين للمستخدم  $u_i$  الذين قاموا بتقييم العنصر  $v_j$ ،  $sim(u_i, u_k)$  هو وزن التشابه بين المستخدم  $u_i$  والمستخدم  $u_k$ . بهذه الطريقة فالتقييم المعبر عنها من قبل مستخدم مشابه جداً له تأثير كبير على التقييم المتوقع به بالنسبة للمستخدم الهدف.

كانت نظم التصفية التعاونية المعتمدة على المستخدم ناجحة جداً في الماضي، لكن استخدامها واسع الانتشار قد كشف عن بعض التحديات التي تعاني منها [5]، حيث هناك عدة نظم توصية تجارية والتي توصي بأنواع مختلفة من العناصر (مثلاً الكتب من "Amazon.com" والألبومات الموسيقية من "dnow.com"). في هذه الأنظمة حتى المستخدمون النشطون جداً قد يشتركون أقل من 1% من العناصر (1% من أصل 2 مليون كتاب هي 20000 كتاب). وفقاً لذلك، قد تكون هذه الأنظمة غير قادرة على تقديم أي تنبؤ بالنسبة لبعض المستخدمين [5]، حيث يجب أن يتم التعبير عن عدد كافٍ من التقييمات من قبل المستخدمين حتى تكون الخوارزمية قادرة على حساب التشابه وإيجاد مستخدمين مشابهين. لذلك، فإن طرق التصفية التعاونية المعتمدة على المستخدم غير فعالة بالنسبة للمستخدمين الذين يعانون من مشكلة الإقلاع البارد (cold-start users) والذين قاموا بتقييم عدد قليل من العناصر. كذلك تتطلب الخوارزميات المعتمدة على المستخدم حسابات، والتي تزداد مع زيادة كل من المستخدمين والعناصر، وبالتالي مع ملايين المستخدمين والعناصر، فإن نظام التوصية النموذجي سوف يعاني من مشاكل توسع جدية.

## 2-1-2-3-2 طرق التوصية التعاونية المعتمدة على العنصر

على الرغم من فعالية الطرق المعتمدة على المستخدم إلا أنها كما ذكرنا تعاني من مشكلة قابلية التوسع عندما يزداد عدد المستخدمين بشكل كبير، ويصبح إيجاد المستخدمين المشابهين له تعقيد  $O(U)$  أو ربما يكون أسوأ عدد التشابهات التي يجب حسابها، لذلك تم اقتراح خوارزمية التوصية التعاونية المعتمدة على العنصر. إن هذه الطريقة هي من تقنيات التوصية الأكثر شيوعاً اليوم، وقد تم تقديمها في [27], [28] وفي نفس الوقت تم استخدامها من قبل "Amazon" [23].

على خلاف خوارزميات التوصية التعاونية المعتمدة على المستخدم التي تمت مناقشتها في المقطع السابق، تنظر الطريقة المعتمدة على العنصر في مجموعة العناصر التي قام المستخدم بتقييمها وتحسب مدى تشابهها مع العنصر الهدف  $v_j$ ، وبعدها يتم اختيار ال  $K$  عنصر الأكثر تشابهاً  $\{v_1, v_2, \dots, v_k\}$  على أساس قيم التشابهات المقابلة الخاصة بها  $\{sim(v_j, v_1), sim(v_j, v_k), \dots\}$  كما هو موضح في (الشكل 5). المفهوم مشابه إلى حد ما لمفهوم التوصيات المعتمدة على المحتوى، لكن هذه المرة يتم حساب التشابهات من تقييمات المستخدم عبر العناصر بدلاً من مزايا العناصر بحد ذاتها، لهذا السبب يمكن لهذه الخوارزمية توفير تشابه بين عنصرين من نوعين مختلفين مثلاً، الملابس الصيفية وآلة صنع الآيس كريم حيث يكون للمستخدم عندها سلوك متشابه عبر كليهما، وهذه إحدى الأشياء التي لا يمكن للطرق المعتمدة على المحتوى إيجادها.



الشكل 5: طريقة التوصية التعاونية المعتمدة على العنصر

ما تزال الطرق المعتمدة على العنصر بحاجة لإيجاد العناصر الأكثر تشابهاً حتى تعمل، إلا أنه يتم حساب هذا التشابه عبر أبعاد أصغر لأنه عادةً يكون عدد العناصر أقل من عدد المستخدمين. يأتي الرّجح الأساسي في طرق التوصية التعاونية المعتمدة على العنصر من كونها تسمح للشخص بحساب التشابهات بين العناصر بشكل مسبق، الأمر الذي هو غير ممكن في الطريقة المعتمدة على المستخدم، فعندما يقوم المستخدم بإجراءات أكثر في النظام مثل إعطاء تقييم لعناصر أكثر، أو شراء عناصر أخرى فإنّ شعاع التقييمات الخاص به سوف يتغير، وبالتالي فإنّ المستخدمين المشابهين له سوف يتغيرون أيضاً. هذا يعني أنّ التشابه في النظام يمكن أن يتغير من خلال ما يقوم به أي مستخدم في النظام. بينما عندما يكون عدد المستخدمين أكبر من عدد العناصر فإنّ التشابه بين عنصرين لن يتغير عندما يتم عمل أي إجراء في النظام، خاصة إذا كان العنصران لهما بالفعل عدد كافٍ من التقييمات السابقة. هذه هي الفائدة الأساسية من طرق التوصية التعاونية المعتمدة على العنصر. تحتاج الطرق المعتمدة على العنصر كذلك إلى تابع لحساب التشابه بين العناصر وتابع للتنبؤ بالتقييم كما في الطرق المعتمدة على المستخدم، وحساب التشابه بين عنصرين مشابه لحساب تشابهات المستخدمين، نعرّف مقياس "VSS" بين العنصرين  $v_i$  و  $v_j$  كما يلي [5], [29]:

$$sim(v_j, v_l) = \cos(\vec{v}_j, \vec{v}_l) = \frac{\vec{v}_j \cdot \vec{v}_l}{\|\vec{v}_j\|_2 \times \|\vec{v}_l\|_2} = \frac{\sum_{u_i \in U_{jl}} R_{ij} R_{il}}{\sqrt{\sum_{u_i \in U_{jl}} R^2_{i,j}} \sqrt{\sum_{u_i \in U_{jl}} R^2_{i,l}}} \quad (7)$$

حيث  $\vec{v}_j$  هو شعاع يمثل التقييمات المعبر عنها على العنصر  $v_j$  في فضاء المستخدمين ذي البعد  $N$ ، وتشير  $U_{jl}$  إلى مجموعة المستخدمين الذين قاموا بتقييم كل من العناصر  $v_j$  و  $v_l$  معاً. كما نعرف مقياس "PCC" كما يلي:

$$sim(v_j, v_l) = corr(v_j, v_l) = \frac{\sum_{u_i \in U_{jl}} (R_{i,j} - \bar{R}_j)(R_{i,l} - \bar{R}_l)}{\sqrt{\sum_{u_i \in U_{jl}} (R_{i,j} - \bar{R}_j)^2} \sqrt{\sum_{u_i \in U_{jl}} (R_{i,l} - \bar{R}_l)^2}} \quad (8)$$

حيث قيم التشابه بين العناصر باستخدام هذا المقياس هي في المجال  $[-1, +1]$ ، كما هي الحال في التشابه بين المستخدمين تماماً. الآن حالما يتم إيجاد العناصر الأكثر تشابهاً، يتم بعدها حساب التنبؤ عن طريق أخذ المتوسط الموزون للتقييمات الخاصة بالمستخدم على هذه العناصر المشابهة كما يلي:

$$\hat{R}_{ij} = \frac{\sum_{v_l \in N_i(j)} sim(v_j, v_l) R_{il}}{\sum_{v_l \in N_i(j)} sim(v_j, v_l)} \quad (9)$$

حيث  $N_i(j)$  هي مجموعة العناصر التي تم تقييمها من قبل المستخدم  $u_i$  والتي هي مشابهة لـ  $v_j$ . من الجدير بالذكر أن طريقة التصفية التعاونية المعتمدة على العنصر لديها تحديات أيضاً في التعامل مع المستخدمين الجدد والعناصر الجدد. إلا أن الطريقة المعتمدة على المستخدم في أنظمة التصفية التعاونية ليست مفضلة مثل الطريقة المعتمدة على العنصر بسبب عدم الاستقرار في العلاقات بين المستخدمين. حيث أنه بالنسبة للنظام الذي يعالج قاعدة مستخدمين كبيرة، فإنه حتى التغيير الصغير في معطيات المستخدم من المرجح أنه يغير المجموعة الكاملة من المستخدمين المتشابهين، وبما أن عدد المستخدمين هو أكبر بكثير من عدد العناصر في معظم مجموعة المعطيات الخاصة بالتقييمات، فإن التصفية التعاونية المعتمدة على العنصر أكثر قابلية للتوسع من التصفية التعاونية المعتمدة على المستخدم، وذلك لأنه يتم حساب التشابه فيها بالنسبة لأزواج العناصر وليس للمستخدمين. هناك أيضاً إثباتات تجريبية على أن الخوارزميات المعتمدة على العنصر يمكن أن تزود أداءً حسابياً أفضل من خوارزميات التصفية التعاونية المعتمدة على المستخدم، في حين أنها تزود جودة مماثلة أو ربما أفضل من جودة الخوارزميات المعتمدة على المستخدم المتاحة [5]. على أي حال، تفشل أنظمة التوصية المعتمدة على العنصر في إيجاد العناصر المثيرة للدهشة بالنسبة للمستخدم، حيث إن التوصيات الخاصة بها معتمدة على عناصر مشابهة لتلك التي قام المستخدم بتقييمها سابقاً.

## 2-2-3-2 طرق التصفية التعاونية المعتمدة على النموذج

تستخدم الخوارزميات المعتمدة على النموذج مجموعة التقييمات المعروفة لتعلم نموذج تنبؤي، والذي نستخدمه بعد ذلك للتنبؤ بالتقييمات غير المعروفة، حيث نستخدم خوارزميات من مجال التنقيب في المعطيات والتعلم الآلي لإيجاد الأنماط من معطيات التدريب [30] وتقديم تنبؤات أكثر دقة بالنسبة للمستخدمين. بعد تعلم النموذج، لانتاج المجموعة الكاملة من التقييمات، إننا نخزن بارامترات النموذج فقط لحساب التنبؤات، حيث يمكن التنبؤ بالتقييمات عن طريق النموذج بدلاً من المعالجة المباشرة للتقييمات الأصلية كما تفعل الطرق المعتمدة على الذاكرة والتي تستخدم التشابه بين المستخدمين أو العناصر للتنبؤ بالتقييمات المفقودة. مقارنة مع الطرق المعتمدة على الذاكرة، فإن الطرق المعتمدة على النموذج لديها هدف أكثر شمولية وهو اكتشاف العوامل الكامنة (Latent Factors) التي تشرح التقييمات المعروفة [30] بهدف التنبؤ بالتقييمات غير المعروفة.

هناك عدة نظم توصية تعاونية معتمدة على النموذج مقترحة في الدراسات السابقة. من أهم الخوارزميات الموجودة في هذا الصنف لدينا: النماذج البايزية (Bayesian models) [30]، [31]، نماذج تحليل المصفوفات إلى عوامل (Matrix Factorization models) والتي نشير لها اختصاراً بنماذج تحليل المصفوفات مثل نموذج تحليل القيمة المفردة "SVD" (Singular Value Decomposition) [33]، [34]،

[35] ونموذج تحليل المكونات الأساسية "PCA" (Principal Component Analysis) [36]، [37] ونموذج تحليل المصفوفات الاحتمالي "PMF" (Probabilistic Matrix Factorization) [38]، [39]، [40] ونموذج تحليل المصفوفات السلبي "NMF" (Negative Matrix Factorization) [41]، [42]، [43]، نماذج التجميع (Clustering models) [44]، [45]، [46]، [47]، النماذج المعتمدة على المشي العشوائي (Random-walk based models) [48]، [49]، كما يمكن تعميم النموذج الخطي في طريقة تحليل المصفوفة إلى عوامل ضمن اطار اللاخطية عن طريق استخدام الشبكات العصبونية. تنقسم نماذج التوصية التعاونية المعتمدة على النموذج إلى ثلاثة أنواع:

### 2-2-3-2 العنقدة Clustering

تعتمد العنقدة على افتراض أن المستخدمين في نفس المجموعة لديهم نفس الاهتمام [50]، لذلك قاموا بتقييم العناصر بالمثل. نقوم بتقسيم المستخدمين إلى مجموعات تسمى عنقايد والتي يمكن تعريفها على أنها مجموعة من المستخدمين المتشابهين. لنفرض لدينا مجموعة من المستخدمين  $U = \{u = 1, \dots, U\}$ ، مجموعة من الخدمات  $I = \{i = 1, \dots, I\}$ ، ولدينا  $R_{u,i}$ ، تقييم المستخدم  $u$  للخدمة  $i$ ، بحيث يحوي التقييم الذي وضعه المستخدم  $u$  للخدمة  $i$ . نفترض قيمة  $H$  مسبقاً، والتي تعبر عن عدد العناقيد المطلوبة ثم نتبع الخطوات التالية [50]:

- نقوم باختيار  $H$  متجه للمستخدمين من مصفوفة التقييم كمراكز العناقيد  $H$ .
- من أجل تعيين باقي متجهات المستخدمين، نقوم باستخدام مسافة مينكوفسكي أو المسافة الإقليدية أو مسافة مانهاتن، لتحديد مركز العنقود الأقرب لكل متجه.
- نكرر الخطوة السابقة، في كل مرة نعيد حساب مراكز العناقيد  $H$  حتى يتم تحديد مكان متجهات كل المستخدمين ضمن العناقيد  $H$ .
- من أجل مستخدم جديد  $a$  يتم حساب التشابه بينه وبين كل عنقود باستخدام مقياس "PCC" للعثور على أقرب مجموعة ل  $a$ .
- بعد اختبار أقرب مجموعة ل  $a$ ، نختار أعلى 10 جيران مشابهين ل  $a$  ندعوهم  $A$ .

نقوم ببناء تقييم المستخدم  $a$  على كل خدمة  $i \in I_N$ ، حيث  $I_N$  تمثل الخدمات التي لم يشاهدها المستخدم  $a$  بعد وذلك عن طريق تجميع المتوسط المرجح للانحرافات عن المستخدمين  $A$ ، كما في المعادلة التالية، نقوم باختيار الخدمات ذات قيم التقييم العالية ونعتبرها توصيات للمستخدم  $a$  [51].

$$Predicit(a, i) = \overline{R_a} + \frac{\sum_{u \in A} sim(a, u) \cdot (R_{u,i} - \overline{R_u})}{\sum_{u \in A} |sim(a, u)|} \quad (10)$$

حيث  $\overline{R_a}$  متوسط قيم التقييم للمستخدم  $a$ .

### 2-2-3-2 عامل المصفوفة (MF) Matrix Factorization

كمنموذج عامل كامن نموذجي، أثبت عامل المصفوفة (MF) فعاليته الكبيرة في أنظمة التوصية. يمكن تمثيل المستخدمين والعناصر في مساحة مشتركة منخفضة الأبعاد بحيث يمكن نمذجة تفضيل المستخدم من خلال الجمع الخطي لمتجه عامل العناصر  $V$  باستخدام المعاملات الخاصة بمتجه المستخدمين  $U$  [7]. توجد طرق مختلفة لتحليل المصفوفة، مثل طريقة تحليل المصفوفة إلى عوامل Alternating Least Squares (ALS). ALS هي عملية تحسين تكرارية بحيث في كل تكرار، نحاول الاقتراب أكثر فأكثر من تمثيل بياناتنا الأصلية [8].

لنفرض لدينا مجموعة من المستخدمين  $U = \{u = 1, \dots, U\}$ ، مجموعة من الخدمات  $I = \{i = 1, \dots, I\}$ ، ولدينا  $y_{ui}$ ، قيمة تفاعل المستخدم  $u$  مع الخدمة  $i$ ، والتي قد تكون قيمها في حال الآراء الضمنية كالتالي:

- "1" تعني أن المستخدم  $u$  لديه سجل تفاعل مع الخدمة  $i$ ، ومع ذلك هذا لا يعني أن  $u$  يجب حقاً الخدمة  $i$  (بيانات مرصودة).

● "0" تعني أنّ المستخدم  $u$  ليس لديه سجل تفاعل مع العنصر  $i$  إلى الآن. ومع ذلك هذا لا يعني أنّ  $u$  يكره  $i$  ( بيانات غير مرصودة).

في حالة الآراء الصريحة نستبدل "1" بقيمة التقييم التي اختارها المستخدم.

يمكن التعبير عن مشكلة التوصية هنا كمشكلة تقدير درجة العنصر الذي لم يتمّ التفاعل معه بعد (تستخدم هذه الدرجة لتقييم ترتيب العنصر). يمكن تلخيصها ضمن المعادلة التالية:

$$\hat{y}_{ui} = f(u, i | \theta) \quad (11)$$

حيث  $\hat{y}_{ui}$  يمثل درجة التوقع للتفاعل  $y_{ui}$ ،  $\theta$  تمثل معلمات النموذج،  $f$  يمثل وظيفة التفاعل. بشكل رياضي تقوم تقنية MF بتحليل مصفوفة التفاعل  $y_{ui}$  إلى مصفوفتين  $p_u$ ،  $q_i$  تمثلان العوامل الكامنة للمستخدم  $u$  و الخدمة  $i$  على التوالي. تعتبر تقنية عامل المصفوفة أن القيمة المتوقعة  $\hat{y}_{ui}$  هي الجداء الخطي بين المصفوفتين السابقتين كما في المعادلة التالية:

$$\hat{y}_{ui} = f(u, i | p_u, q_i) = p_u^T q_i = \sum_{k=1}^K (p_{uk} q_{ik}) \quad (12)$$

حيث يشير  $K$  إلى بعد العوامل الكامنة.

نلاحظ أنّ MF يستخدم منتجاً داخلياً بسيطاً وثابتاً لتقدير التفاعل المعقد بين المستخدم والعنصر في المساحة الكامنة منخفضة الأبعاد، والتي قد تسبب قيوداً. إحدى طرق حل هذه المشكلة هي استخدام عدد كبير من العوامل الكامنة  $K$ . ومع ذلك، قد يؤثر ذلك سلباً على قدرة التعميم للنموذج (مثل مشكلة فرط البيانات)، كما لا تستطيع MF التعامل بكفاءة مع مستخدمين جدد أو عناصر جديدة لأنّها تحتاج إلى عوامله الكامنة التي لن تكون متاحة بعد.

### 2-2-3-2 طرق التعلم العميق Deep Learning

كما هو مذكور أعلاه، يتعرف MF مباشرة على المتجهات الكامنة للمستخدمين والعناصر من مصفوفة تصنيفات عناصر المستخدم ويلتقط التفاعل بين المستخدم والعنصر. ومع ذلك، لا يمكن التقاط التفاعلات المعقدة بواسطة MF نظراً لأنّ  $\hat{y}_{ui}$  يتم إنتاجه بواسطة المنتج الداخلي البسيط بين المتجهات الكامنة المقابلة للمستخدم والعنصر [9]. في السنوات الأخيرة، تم اقتراح استبدال النموذج الخطي بالشبكات العصبية لتحديد معلمات وظيفة التفاعل  $\theta$ . على سبيل المثال، باستخدام الشبكة متعددة الطبقات (MLP) Multi-Layer Perceptron. بهذا المعنى، يمكننا إعطاء النموذج مستوى عالٍ من المرونة وقدرات النمذجة غير الخطية، بدلاً من مجرد استخدام المنتج الداخلي. من أجل حساب  $\theta$ ، هناك طريقتين لتحسين الوظيفة الهدف هما:

1. التحسين النقطي Pointwise Loss:

هنا نقوم باتباع نموذج الانحدار لتقليل متوسط الخطأ التربيعي بين القيمة المتوقعة  $\hat{y}_{ui}$  والقيمة المستهدفة  $y_{ui}$ . في الوقت نفسه، من أجل التعامل مع البيانات غير المرصودة، فإنهم يعتبرون جميع العناصر غير المرصودة ردود فعل سلبية، أو يتم أخذ عينة من العناصر غير المرصودة على أنها حالات ردود فعل سلبية [52]، [53].

2. التحسين الزوجي Pairwise Loss:

إنّ هدف التحسين الزوجي هي أنّ العناصر المرصودة يجب أن تكون مرتبة أعلى من العناصر غير المرصودة. لذلك، يعمل التحسين الزوجي على زيادة الفجوة بين  $y_{ui}$  و  $\hat{y}_{ui}$  بدلاً من تقليل الخسارة [54] [55].

$$\hat{y}_{ui} = f(P^T v_u^U, Q^T v_i^I | P, Q, \theta_f) \quad (13)$$

حيث  $\theta_f \in P, Q \in q_{ik}$ ،  $P \in p_{uk}$ ،  $f$  [56].

نظراً لتعريف الوظيفة  $f$  على أنها شبكة عصبية متعددة الطبقات، يمكن تخصيصها على النحو التالي:

$$f(P^T v_u^U, Q^T v_i^I | P, Q, \theta_f) = \phi_{out}(\phi_x(\dots\phi_2(\phi_1(P^T v_u^U, Q^T v_i^I))\dots)) \quad (14)$$

حيث تشير  $\phi_{out}$ ،  $\phi_{\chi}$  على التوالي إلى وظيفة التعيين لطبقة الإخراج والطبقة  $\chi$ -th من طبقات الترشيح التعاوني، حيث إجمالي عدد الطبقات العصبية هو  $\chi$  طبقة [57].

كما سبق نلاحظ أنه يمكن تفسير MF كحالة خاصة من الشبكة العصبية، حيث منحت MLP وظيفة التفاعل السابقة مستوى عالياً من قدرات النمذجة غير الخطية.

بما أن النظم التعاونية تستخدم التقييمات من المستخدمين الآخرين، وبالتالي يمكنها التعامل مع أي نوع من المحتوى وأن توصي بأي عنصر من أي نوع، حتى العناصر غير المشابهة لتلك المرئية في الماضي وهذه إحدى مزاياها. على الرغم من أنه ليس لديها بعض أوجه القصور التي لدى النظم المعتمدة على المحتوى، إلا أن لديها القيود الخاصة بها والتي من أهمها [14]:

### 3. مشكلة الإقلاع البارد (cold-start):

تحدث هذه المشكلة عندما يدخل مستخدم جديد أو عنصر جديد إلى النظام، حيث يكون من الصعب إيجاد مستخدمين أو عناصر مشابهة لأنه ليس هناك معلومات كافية. لذلك يمكن أخذ هذه المشكلة في طرق التصفية التعاونية من جانبيين:

❖ مشكلة المستخدم الجديد: إنها نفس المشكلة كما مع النظم المعتمدة على المحتوى، حيث تتطلب الطرق التعاونية تقييمات من المستخدم لتقديم توصيات. إذا لم يتم تقييم المستخدم بتقييم عدد كافٍ من العناصر، فإن نظام التوصية التعاوني يكون غير قادر على تقديم توصيات دقيقة ذات طابع شخصي. تم اقتراح عدة تقنيات لمعالجة هذه المشكلة، يستخدم معظمها الطريقة الهجينة.

❖ مشكلة العنصر الجديد: تتم إضافة عناصر جديدة إلى نظم التوصية باستمرار والنظم التعاونية تعتمد على تفضيلات

المستخدم فقط لتقديم تنبؤات، لذلك يكون نظام التوصية غير قادر على التوصية بالعنصر الجديد ما لم يتم تقييمه من قبل عدد كافٍ من المستخدمين. يمكن معالجة هذه المشكلة أيضاً باستخدام طرق التوصية الهجينة التي سيتم توصيفها لاحقاً.

4. مشكلة بعثرة المعطيات (Data Sparsity): في أي نظام توصية، عدد التقييمات التي يتم الحصول عليها بالفعل يكون عادةً صغير جداً مقارنةً مع عدد التقييمات التي تحتاج لأن يتم التنبؤ بها كما هو موضح في (الشكل 6). إن التنبؤ الفعّال بالتقييمات من عدد صغير من التقييمات المعروفة هو أمر هام جداً، حيث نجاح نظم التوصية التعاونية يعتمد على إتاحة كمية كافية من المستخدمين. مثلاً، في نظم التوصية بالأفلام، قد يكون هناك عدة أفلام والتي قُيِّمت من قبل عدد قليل من الأشخاص، هذه الأفلام سيتم التوصية بها بشكل نادر جداً، حتى لو أن أولئك المستخدمين القليلين قد أعطوا تقييمات عالية لها. أيضاً، بالنسبة للمستخدم الذي ذوقه غير عادي مقارنةً مع باقي المستخدمين، سوف لن يكون هنالك مستخدمين آخرين مشابهين لذلك المستخدم، مما يقود إلى توصيات سيئة. تم اقتراح عدة طرق معتمدة على النموذج لحل مشكلة بعثرة المعطيات في نظم التوصية، أحدها هي استخدام معلومات الملف الشخصي للمستخدم عند حساب التشابه بين المستخدمين، وبالتالي يُعتبر اثنان من المستخدمين متشابهين ليس فقط إذا قاما بتقييم نفس الأفلام بشكل متشابه لكن أيضاً إذا كانا ينتميان إلى نفس الصنف الديموغرافي. مثلاً، يتم استخدام الجنس، العمر، التعليم، كود المنطقة، المعلومات الوظيفية للمستخدمين في تطبيق التوصية بالمطاعم [58]، هذا الامتداد لتقنيات التصفية التعاونية يدعى أحياناً "التصفية الديموغرافية" (demographic filtering). تم إيجاد طريقة أخرى للتعامل مع مصفوفات التقييم المبعثرة [59]، حيث استخدمنا إحدى تقنيات تقليل الأبعاد وهي "SVD" والتي تقوم بتقليل أبعاد مصفوفات التقييم المبعثرة وتزود بالرتبة (rank) التقريبية الأقل الأفضل للمصفوفة الأصلية.



الشكل 6: مصفوفة التقييم المبعثرة

5. مشكلة قابلية التوسع (Scalability): عندما تنمو أعداد المستخدمين والعناصر بشكل هائل، سوف تعاني خوارزميات التصفية التعاونية التقليدية من مشاكل توسع جديّة، وستتجاوز الموارد الحاسوبية المطلوبة لمعالجتها حدود المستويات العمليّة المقبولة. كذلك تحتاج عدة أنظمة للاستجابة الفوريّة على الطلبات وتقديم توصيات بالنسبة للمستخدمين بغض النظر عن التاريخ الشرائي لهم أو سجلات التقييم الخاصّة بهم، والذي يتطلّب قابليّة توسع عالية من نظام التصفية التعاونيّة. يمكن لتقنيات تقليل الأبعاد مثل "SVD" أن تتعامل مع مشكلة قابلية التوسع وأن تنتج توصيات ذات جودة عالية وبسرعة، لكن عليها أن تخضع لمراحل مكلفة من عمليات تحليل المصفوفات. كما ويمكن لخوارزميات التصفية التعاونيّة المعتمدة على الذاكرة خاصّة تلك المعتمدة على العنصر تحقيق قابليّة توسع مرضية، حيث إنّها بدلاً من حساب التشابهات بين كل أزواج العناصر، فإنّها تحسب التشابه بين زوج من العناصر التي تمّ تقييمها من قبل المستخدم بشكل مشترك. كذلك يمكن لخوارزمية تصفية تعاونيّة بسيطة معتمدة على النماذج البايزية أن تحلّ مشكلة قابليّة التوسع عن طريق جعل التنبؤات معتمدة على التقييمات المعروفة فقط [60]. كما أنّ خوارزميات التصفية التعاونيّة المعتمدة على نماذج التجميع يمكنها معالجة مشكلة قابليّة التوسع من خلال البحث عن المستخدمين المشابهين من أجل التوصيات داخل مجموعات (clusters) صغيرة ومتشابهة جداً بدلاً من قاعدة المعطيات الكاملة [6]، لكن بهذا الأسلوب سيكون هناك مقايضة بين قابليّة التوسع والأداء التنبؤي.

### 2-3-3 نظم التوصية الهجينة

لتجنّب القيود الموجودة في نظم التوصية الفرديّة مثل النظم المعتمدة على المحتوى والنظم المعتمدة على التصفية التعاونيّة، تدمج الطرق الهجينة عدّة طرق معاً للاستفادة من مزاياها وتحسين دقّة التوصيات. مثال معروف جيداً عن ذلك هو المنافسة على جائزة "Netflix" [61]، حيث وُجد فيها أنّ طرق التوصية الأفضل تقابل تجميع العديد من خوارزميات التوصية المختلفة. هناك عدّة طرق لدمج الطريقة التعاونيّة والطريقة المعتمدة على المحتوى في نظام توصية هجين ويمكن تصنيفها كما يلي [9]:

6. تحقيق الطريقة التعاونيّة والطريقة المعتمدة على المحتوى بشكل منفصل ودمج التنبؤات الخاصّة بهم.

7. إدراج بعض مزايا الطريقة المعتمدة على المحتوى في الطريقة التعاونيّة.

8. إدراج بعض مزايا الطريقة التعاونيّة في الطريقة المعتمدة على المحتوى.

9. بناء نموذج موحد عام والذي يدمج المزايا المعتمدة على المحتوى والمزايا التعاونيّة.

فيما يلي، سنتكلّم عن كيفية استخدام كل واحدة من الطرق السابقة من قبل باحثي نظم التوصية.

#### دمج عدّة نظم ناصحة منفصلة

إحدى الطرق لبناء نظم توصية هجينة هي تحقيق نظام التصفية التعاوني والنظام المعتمد على المحتوى بشكل منفصل. بعدها يمكن أن يكون لدينا سيناريوهين مختلفين: إمّا يمكننا دمج التقييمات التي تمّ الحصول عليها من نظم التوصية الفرديّة إلى نظام توصية واحد نهائيّ باستخدام

مزيج خطي من التقييمات [62] أو باستخدام تقنية تصويت [58]. أو بشكل بديل يمكننا استخدام أحد نظم التوصية الفردية، وعند لحظة ما نختار نظام التوصية الأفضل اعتماداً على مقياس ما لجودة التوصيات. مثلاً، يختار نظام "Daily Learner" [15] نظام التوصية الذي يمكنه أن يعطي التوصيات بالمستوى الأعلى من الثقة، بينما في عمل آخر يتم اختيار نظام التوصية الذي تكون التوصيات الخاصة به أكثر تجانساً مع التقييمات السابقة للمستخدم [63]. إن المزج لأنواع مختلفة من خوارزميات التوصية يمكن أن يقود إلى تحسينات كبيرة في الأداء مقارنة مع الخوارزميات الفردية، إلا أن تدريب عدة أنظمة توصية ودمج نتائجها يمكن أن يكون مكلفاً من الناحية الحسابية، لذلك المعيار المستخدم لتقييم نظام التوصية والمقايضة بين السرعة والدقة يصبح هاماً جداً.

#### إضافة المزايا المعتمدة على المحتوى إلى النماذج التعاونية

إن عدة نظم توصية هجينة بما في ذلك نظام "Fab" [14] وطريقة "Collaborative Filtering" [58] معتمدة على تقنية التصفية التعاونية التقليدية، لكن تحتفظ أيضاً بالملفات الشخصية المعتمدة على المحتوى من أجل كل مستخدم. هذه الملفات المعتمدة على المحتوى وليس العناصر التي تم تقييمها بشكل مشترك يتم استخدامها لاحقاً لحساب التشابه بين المستخدمين، وهذا يسمح بالتغلب على بعض المشاكل المتعلقة بالبعثرة للطريقة التعاونية البحتة لأنه عادةً ليس كل أزواج المستخدمين سيكون لهم عدد كبير من العناصر التي تم تقييمها بشكل مشترك. فائدة أخرى لهذه الطريقة هي أن المستخدمين يمكن أن يوصى لهم بعنصر لم يتم تقييمه بشكل عالٍ من قبل المستخدمين بملفات متشابهة، لكن أيضاً بشكل مباشر أي عندما يكون لهذا العنصر تقييم عالٍ مقابل الملف الشخصي للمستخدم.

#### إضافة المزايا التعاونية إلى النماذج المعتمدة على المحتوى

إن الطريقة الأكثر شيوعاً في هذا الصنف هي استخدام بعض تقنيات تقليل الأبعاد على مجموعة من الملفات الشخصية المعتمدة على المحتوى. مثلاً، نستخدم تقنية التحليل الدلالي الكامن "LSI" (Latent Semantic Analysis) لإنشاء وجهة نظر تعاونية لمجموعة من ملفات المستخدمين، حيث تقوم بتمثيل هذه الملفات بواسطة أشعة المزايا، مما ينتج عنه تحسين في الأداء مقارنة مع الطريقة المعتمدة على المحتوى بشكل بحت [64].

#### تطوير نموذج ناصح موحد

قام عدة باحثين باتباع هذه الطريقة في السنوات الأخيرة. مثلاً، اقترحوا احتمالية موحدة لدمج التوصيات التعاونية والتوصيات المعتمدة على المحتوى، والتي هي معتمدة على تحليل المحتوى الكامن بشكل احتمالي [65]. كذلك اقترحوا طريقة أخرى موحدة والتي تقوم بتخمين البارامترات والتنبؤ بالتقييم باستخدام طرق ("MCMC" Carlo) Markov Chain Monte [66]. علاوةً على ذلك، تبين عند مقارنة الأداء بشكل تجريبي للطرق الهجينة مع الطريقة التعاونية البحتة والطريقة المعتمدة على المحتوى البحتة أن الطرق الهجينة يمكن أن تزود توصيات أكثر دقة من الطرق البحتة.

في النهاية نلخص مزايا وعيوب الطرق المشروحة سابقاً بشكل مختصر في الجدول 1 التالي:

الجدول 1: مزايا وعيوب نظم التوصية

| العيوب   | المزايا   | الصنف |
|--|---|-------|
| <ul style="list-style-type: none"> <li>• إنها مقيدة بالمزايا المرتبطة بشكل صريح مع العناصر التي توصي بها هذه الأنظمة، ويجب أن يكون المحتوى بالشكل الذي يمكن عمل استخراج آلي له من قبل الحاسوب والأي يجب إسناد المزايا إلى العناصر يدوياً.</li> </ul> | <ul style="list-style-type: none"> <li>• لا تتطلب معطيات على مستخدمين آخرين لتحقيق دقة توصية معقولة</li> <li>• قادرة على التوصية بالعناصر للمستخدمين ذوي الأذواق الفريدة.</li> <li>• لا تعاني من مشكلة العنصر الجديد، أي هي قادرة على التوصية بالعناصر الجديدة وغير الشائعة إلى كل مستخدم.</li> </ul> |       |

|  |   |   |
|--|---|---|
| <ul style="list-style-type: none"> <li>● توصي فقط بالعناصر التي هي مشابهة لتلك التي قام المستخدم بتقييمها بشكل إيجابي في السابق، لذلك تميل التوصيات لأن تصبح مخصصة جداً.</li> <li>● غير قادرة على تقديم توصيات دقيقة بالنسبة للمستخدم الجديد الذي لديه القليل من التقييمات.</li> </ul>   | <ul style="list-style-type: none"> <li>● يمكنها إدراج شروحات حول كيفية عمل نظام التوصية عن طريق إدراج توصيات المحتوى صراحةً والتي كانت السبب في ظهور العنصر في قائمة التوصيات.</li> </ul>   | <p>نظم التوصية المعتمدة على المحتوى</p>           |
| <ul style="list-style-type: none"> <li>● غير قادرة على تقديم توصيات دقيقة بالنسبة للمستخدم الجديد الذي لديه القليل من التقييمات، كذلك الأمر بالنسبة للعنصر الجديد الذي لم يتقيم من قبل عدد كافٍ من المستخدمين.</li> <li>● غير قادرة على تقديم توصيات دقيقة في حال عدم توفر كمية كافية من المعطيات.</li> <li>● تعاني من مشاكل توسع عندما تنمو أعداد المستخدمين والعناصر بشكل هائل.</li> <li>● تعاني من مشكلة الهجمات التي تجعل النظام الناصح يتصرف بالطريقة التي يرغب بها المهاجم.</li> </ul> | <ul style="list-style-type: none"> <li>● لا تحتاج تمثيل للعناصر من حيث المزايا، حيث المعلومات الوحيدة الضرورية هي التقييمات، لذلك يمكن تطبيقها على أي نوع من العناصر.</li> <li>● يمكنها تقديم توصيات غير متوقعة من المستخدمين لأنها غير معتمدة على تفضيلات المستخدمين فقط، إنَّما على تفضيلات المستخدمين ذوي الأذواق المشابهة.</li> <li>● يمكنها أن توصي بأي عنصر من أي نوع، حتى العناصر غير المشابهة لتلك المرئية في الماضي.</li> <li>● تتحسن جودة التوصيات فيها عبر الزمن.</li> </ul> | <p>نظم التوصية المعتمدة على التصفية التعاونية</p> |
| <ul style="list-style-type: none"> <li>● لديها زيادة في التعقيد وكلفة إضافية في التحقيق.</li> <li>● قد تحتاج معلومات خارجية والتي تكون عادة غير متاحة.</li> </ul>  | <ul style="list-style-type: none"> <li>● تتغلب على قيود نظم التوصية المعتمدة على المحتوى ونظم التوصية المعتمدة على التصفية التعاونية مثل البعثة والإقلاع البارد.</li> <li>● تحسن الدقة التنبؤية.</li> </ul>   | <p>نظم التوصية الهجينة</p>                        |

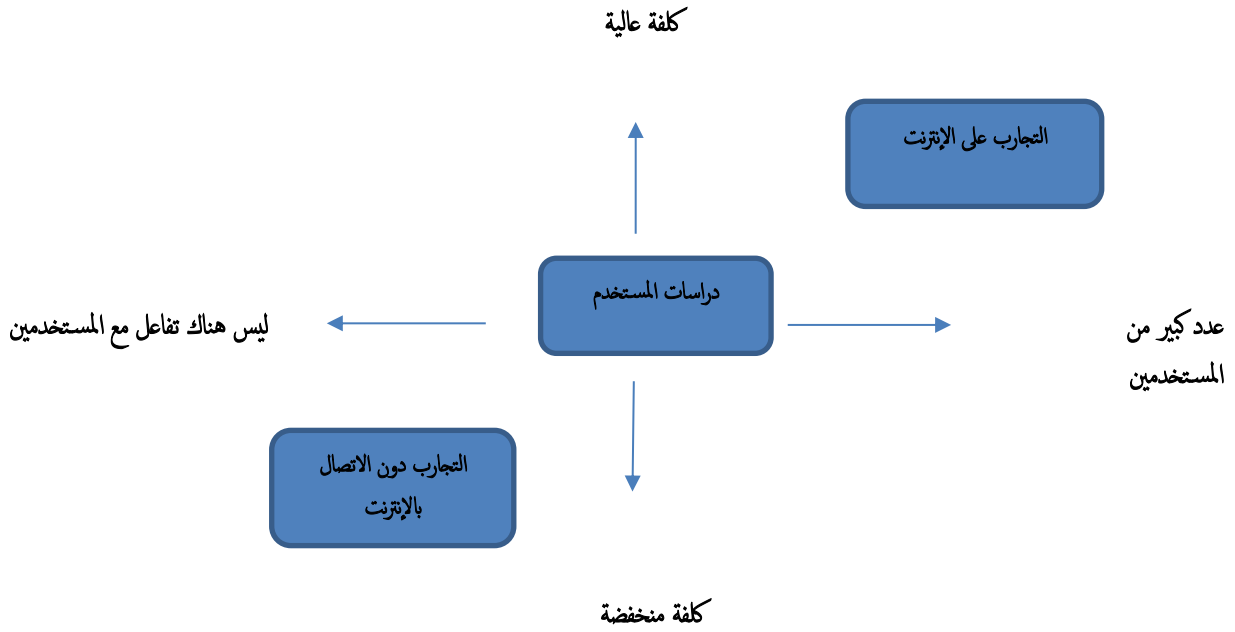
## 4-2 تقييم نظم التوصية

من أجل اختيار خوارزمية التوصية التي تعمل بالشكل الأفضل من بين عدّة خوارزميات، من الضروري قياس ومقارنة أدائها. نقوم بهذه المقارنة عادةً بشكل تجريبي عن طريق تطبيق بروتوكول تقييم محدد حيث من خلاله نختار منهجية التقييم المطبقة والتي تحدّد ما نقوم بتقييمه (مثلاً: دقة التنبؤ، دقة الترتيب، التغطية، التنوع...إلخ).

إنّ تقييم أداء نظم التوصية هو مهمّة صعبة تتكوّن غالباً من 3 مستويات مختلفة من التجارب [67] وهي:

- التجارب دون الاتصال بالإنترنت (offline experiments).
- دراسات المستخدم (user studies).
- التجارب على الإنترنت (online experiments).

تعتمد التجارب دون الاتصال بالإنترنت على المعطيات الثابتة بشكل بحث دون الحاجة للتفاعل مع المستخدمين الحقيقيين ولذلك من السهل القيام بها، بينما تقوم بتطبيق دراسات المستخدم في بيئة مُتحكّم بها عن طريق الطلب من مجموعة صغيرة من الأفراد استخدام النظام وإعطاء تقرير عن تجربتهم من خلال الإجابة على مجموعة من الأسئلة. أمّا التقييم على الإنترنت نطبقه عادةً على كمية كبيرة من المستخدمين الحقيقيين عبر فترة من الزمن والذين هم غير مُدرّكين للتجربة التي هي أقرب إلى الواقع. المزايا النموذجية لأنواع التجارب المختلفة موضحة في الشكل (7). يمكن أن نلاحظ من هذا الشكل أنّ التجارب دون الاتصال بالإنترنت لا تتطلب تفاعلاً مع المستخدم مطلقاً، لذلك يمكن إجراؤها بكلفة منخفضة ومن السهل إعادة إنتاج البيئة التجريبية من أجل اختبار خوارزميات جديدة، لذا هي مستخدمة بكثرة في أبحاث نظم التوصية. بينما دراسات المستخدم والتجارب على الإنترنت على الرغم من مزاياها ودقتها الأعلى إلا أنّها أكثر كلفة من التجارب دون الاتصال بالإنترنت كما أنّها أكثر صعوبة في إجرائها، حيث تتطلب تجنيد عدد من المستخدمين للقيام باختبار النظام وربما يُدفع لهم للقيام بذلك. لذلك أحد الإجراءات الشائعة لتخفيف عبء هذه التكاليف هو القيام بالتجارب دون الاتصال بالإنترنت كخطوة سابقة للتجارب على الإنترنت، بحيث الخوارزميات التي تبين أنّها الأفضل عند الاختبار دون الاتصال بالإنترنت هي التي يتم اختبارها على الإنترنت فقط [67].



الشكل 7: المزايا النموذجية لأنواع التجارب المختلفة المستخدمة في التقييم

في هذه الأطروحة، نركّز على التجارب دون الاتصال بالإنترنت كاستراتيجية تقييم، والتي يتم فيها إجراء التجارب على مجموعتي معطيات تمّ جمعها مسبقاً تتضمن سلوكيات المستخدم على مجموعة من الأفلام والمسلسلات. الهدف من التجارب هو فلتر الطرق غير الملائمة حسب سياق التطبيق، لذلك تحقيقاً لهذه الغاية، نقوم بتصميم عملية ضبط البارامترات في هذه التجارب، كما نقوم بتقسيم المعطيات المستخدمة إلى مجموعتين مختلفتين هما معطيات تدريب ومعطيات اختبار. نستخدم معطيات التدريب لتعلّم نموذج التوصية أو تحسين بارامترات النموذج، بينما

نستخدم معطيات الاختبار لتقييم نموذج التوصية الذي تمّ تعلّمه باستخدام مقاييس التقييم المختارة. في النهاية، سوف تولّد خوارزمية التوصية تنبؤاً بالتقييم بالنسبة للمستخدم الهدف أو تقدّم توصيات بالعناصر الأكثر ملاءمةً لهذا المستخدم. بما أنّ التطبيقات المختلفة لها احتياجات مختلفة، من المهم أن نقرّر بشأن الخصائص التي سنأخذها بالاعتبار عند التقييم لاختيار خوارزمية التوصية الأفضل. من أهم هذه الخصائص لدينا [67]: تفضيلات المستخدم (User Preference)، الدقة التنبؤية (Predictive Accuracy)، التغطية (Coverage)، الوثوقية (Confidence)، الثقة (Trust)، الابتكار (Novelty)، المصادفة (Serendipity)، التنوع (Diversity)، المنفعة (Utility)، الخطر (Risk)، المتانة (Robustness)، الخصوصية (Privacy) و قابلية التكيف (Adaptivity). هناك مقايضة بين بعض الخصائص مثلاً الابتكار، التنوع والخصوصية تتعارض غالباً مع الدافع وراء الدقة، لذلك من المهم أن نفهم أيضاً كيفية تأثير المقايضات على الأداء الكلي. بالعموم إنّ نظام التوصية الذي يزوّد تنبؤات أكثر دقة سيكون مفضلاً من قبل المستخدمين، لذلك ركّزت العديد من الأعمال في تقييم أنظمة التوصية على خاصية الدقة التنبؤية أكثر من غيرها، والتي ستكون تركيزنا أيضاً في هذه الأطروحة بالإضافة لخاصية التغطية، التنوع والابتكار [67].

#### 1-4-2 الدقة التنبؤية

إنّ الدقة التنبؤية هي الخاصية الأكثر استخداماً في أدب نظم التوصية، إذ الافتراض الأساسي في نظم التوصية هو أن النظام ذا الدقة الأعلى سيكون مفضلاً من قبل المستخدم، لذلك يتعيّن على العديد من الباحثين إيجاد الخوارزميات التي تقدم أفضل التنبؤات. مثلاً في بعض التطبيقات، كما في خدمة تأجير الأفلام من "Netflix"، هناك رغبة بالتنبؤ بالتقييم الذي قد يعطيه المستخدم إلى العنصر (من 1-5 نجوم مثلاً)، وبالتالي في مثل هكذا حالات، لا بدّ من قياس دقة التقييمات المتنبأ بها من قبل النظام لمحاولة جعلها أفضل ما يكون وتقديم توصيات جيّدة اعتماداً عليها، وبالتالي تعزيز رضى المستخدم.

يمكن تصنيف مقاييس تقييم نظم التوصية الخاصّة بالدقة التنبؤية إلى الأصناف التالية بشكل عام [67]:

- مقاييس دقة التنبؤ بالتقييم مثل: "MAE"، "RMSE"، "NMAE".
  - مقاييس دقة التنبؤ بالاستخدام مثل: "Precision"، "Recall"، "F1-measure"، "ROC-sensitivity".
  - مقاييس دقة التنبؤ بالترتيب مثل: "NDCG"، "DCG"، "HR".
- نقدّم فيما يلي المقاييس التي تمّ استخدامها في الأطروحة، ويمكن إيجاد معلومات أكثر حول مقاييس الأداء الأخرى في [6]، [67].

#### 1-1-4-2 مقاييس دقة التنبؤ بالاستخدام

بعض تطبيقات التوصية لا تتطلب من المستخدمين إعطاء تقييمات على العناصر. مثلاً، في نظام التوصية بالأخبار، فإنّ المستخدمين يعبرون عن آرائهم ببساطة من خلال النقر / عدم النقر على المقالات الإخبارية الموصى بها. لذلك الوظيفة الأساسية لهذه الأنظمة هي التنبؤ فيما لو كان المستخدم قد نقر على العنصر أم لا. كذلك في عدّة تطبيقات أخرى، نظام التوصية لا يتنبأ بتفضيلات المستخدم تجاه العناصر، لكن يحاول أن يوصي للمستخدمين بالعناصر التي قد يستخدموها. في هذه الحالة نحن مهتمون ليس فيما لو كان النظام يتنبأ بشكل مناسب بالتقييمات على العناصر لكن فيما لو كان النظام يتنبأ بشكل مناسب بأنّ المستخدم سوف يستخدم هذا العنصر.

لتقييم قائمة التوصية كاملةً ومدى أهميتها بالنسبة للمستخدم، نستخدم مقاييس "Precision" وهو (مقياس للجودة) وال "Recall" (وهو مقياس للنوعية) من مجال استرجاع المعلومات. إنّ قيمة "Precision" العالية تعني أنّ الخوارزمية تعيد فعلياً نتائج ذات صلة أكثر من النتائج غير ذات الصلة، بينما تعني قيمة "Recall" العالية أنّ الخوارزمية تعيد معظم النتائج ذات الصلة. عند القيام بتقييم نظام التوصية، يتم إخفاء جزء من تقييمات المستخدمين على العناصر، بعد ذلك نطلب من نظام التوصية أن يتنبأ بالتقييمات التي قد يعطيها المستخدم للعنصر. ينتج من هذا الافتراض 4 حالات وهي ظاهرة في الجدول 2.

الجدول 2: تصنيف النتيجة المحتملة للتوصية بعنصر إلى مستخدم

|          | Recommended        | Not recommended    |
|----------|--------------------|--------------------|
| Used     | True-Positive(TP)  | False-Negative(FN) |
| Not used | False-Positive(FP) | True-Negative(TN)  |

اعتماداً على الحالات الناتجة، يمكن حساب قيمة "Precision" كما يلي [6]:

$$Precision = \frac{\#TP}{\#TP + \#FB} \quad (15)$$

أي تمثل قيمة الـ "Precision" نسبة العناصر الموصى بها بشكل صحيح من بين كل العناصر الموصى بها. ويمكن حساب قيمة الـ "Recall" كما يلي [6]:

$$Recall = \frac{\#TP}{\#TP + \#FN} \quad (16)$$

أي تمثل قيمة الـ "Recall" نسبة العناصر الموصى بها بشكل صحيح من بين كل العناصر ذات الصلة. أحد العيوب لهذه الطريقة هي أننا مضطرون لافتراض أن العناصر غير ممتمة بالنسبة للمستخدمين ولن يتم استخدامها حتى لو رآها المستخدم، لكن هذا ليس صحيحاً تماماً. في بعض الحالات، المستخدم لا يستهلك العنصر لأنه لا يعلم بوجوده لكن عند لفت انتباهه له قد يستهلكه. في بعض تطبيقات التوصية، عدد التوصيات التي يمكن تقديمها إلى المستخدم يتم تعريفها مسبقاً. مثلاً، في نظام توصية الأخبار، تحتوي الخلاصة الموصى بها على 5 إلى 10 مقالات إخبارية حديثة. مثال آخر هو الإعلانات المقدمة من قبل "Google"، حيث عدد أماكن الإعلانات المتاحة يكون مقيّداً. في هذه الأنظمة، المقياس المفيد لتقييم دقة التوصيات هو "Precision@N"، والذي يقيس دقة قائمة التوصية ذات الحجم N.

#### 2-1-4-2 مقاييس دقة التنبؤ بالترتيب

في بعض السيناريوهات، يتم تقديم نتيجة التوصية كقائمة من العناصر، عادةً قائمة عمودية أو أفقية، مما يفرض ترتيب تصفح محدد. مثلاً، في نظام توصية الأخبار، سوف يُظهر التطبيق قائمة من المقالات الإخبارية الشائعة إلى المستخدم حالما يدخل المستخدم إلى النظام، بالتالي يضع النظام هنا تركيزاً على التنبؤ بترتيب العناصر أكثر من التنبؤ بقيم التقييم على هذه العناصر. المخطط الشائع لتقييم جودة الترتيب هو افتراض أن المنفعة من قائمة التوصيات تراكمية [67]، ويتم حسابها كمجموعة المنفعات لكل العناصر الموصى بها في القائمة، بحيث المنفعة للعنصر تتناقص بعامل مرتبط بموقعه في القائمة. يتم تعريف المنفعة عادةً كاحتمال أن يلاحظ المستخدم توصية عند الموقع  $j$  في القائمة، وكلما ذهب المستخدم أبعد في قائمة التوصية، سوف تقل المنفعة بينما الموقع سوف يزداد. لحساب التناقص في المنفعة، نستخدم مقياس "NDCG" (Normalized Cumulative Discounted Gain) بشكل واسع في مجال استرجاع المعلومات، والذي تتناقص فيه المواقع بشكل لوغاريتمي. بالعموم، يمكن افتراض أن كل مستخدم  $u_i$  سيكون له منفعة  $g_{u,i}$  من كونه أوصى له بالعنصر  $v_j$ ، عندها يمكن تعريف مقياس "DCG" (Discounted Cumulative Gain) بالنسبة لقائمة من  $n$  عنصر كما يلي [6]:

$$DCG = \frac{1}{|U|} \sum_{u_i \in U} \sum_{n=1}^N \frac{g_{u,i,n}}{\log_b(n+1)} \quad (17)$$

حيث يتم وضع أساس اللوغاريتم عادةً على قيمة 2 ليمت التأكد من أن كل المواقع تتناقص. بعدها يتم تعريف مقياس "NDCG" الذي هو الإصدار الذي تم عمل معايرة له من "DCG" كما يلي [6]:

$$NDCG = \frac{DCG}{DCG^*} \quad (18)$$

حيث "  $DCG^*$  " هو "  $DCG$  " المثالي. في مثل هكذا ضبط، فإن قائمة التوصية التي تضع العناصر المثيرة للاهتمام مع منفعة عالية قريبة إلى بداية القائمة، ستكون مفضلة على القائمة التي تضع هذه العناصر أسفل القائمة. السبب بسيط وهو أنه عند وضع هذه العناصر المثيرة للاهتمام أسفل القائمة قد لا تتم ملاحظتها من قبل المستخدم، وبالتالي قد لا تولد أي منفعة بالنسبة للنظام [67].

هناك مقياس آخر يُستخدم عادةً مع "  $NDCG$  " يدعى "  $HR$  " (Hit Ratio) لمعرفة عدد العناصر ذات الصلة  $e_k$  التي لاحظها المستخدم من القائمة السابقة  $N$  [68] [69] [70]، والتي يمكن التعبير عنها كالتالي:

$$HR = \frac{1}{N} \sum_{k=1}^N e_k \quad (19)$$

#### 2-4-2 التغطية "Coverage"

في حين أن الدقة التنبؤية لنظام التوصية، خاصة في نظم التصنيفية التعاونية، تزداد مع زيادة كمية المعطيات، قد تزود بعض الخوارزميات توصيات بجودة عالية لكن بالنسبة لجزء صغير فقط من العناصر التي لديها كميات كبيرة من التقييمات. مصطلح "التغطية" يمكن أن يشير إلى عدة خصائص متميزة للنظام، حيث في فضاء العناصر، تقيس التغطية النسبة المئوية من العناصر التي يمكن لنظام التوصية تشكيل تنبؤات من أجلها أو تقديم توصيات بها [6]، والأنظمة بتغطية عناصر منخفضة قد تكون أقل قيمة بالنسبة للمستخدمين لأنهم سيفقدون العناصر من المنطقة المهمة والتي قد تتطابق مع تفضيلات المستخدمين [67]. معظم الوقت يجب أخذ تغطية العناصر بعين الاعتبار سويةً مع الدقة، بسبب حقيقة أن العناصر غير المهمة لجميع المستخدمين من الأفضل أن تتم فلترتها للحصول على دقة أعلى على الرغم من أن ذلك قد يقود إلى تغطية منخفضة. في فضاء المستخدمين، التغطية هي النسبة المئوية من المستخدمين الذي يمكن لنظام التوصية تقديم توصيات من أجلهم [67]. في بعض الحالات، قد لا يوصي النظام بالعناصر إلى المستخدمين إذا كان المستخدم لديه معلومات قليلة حولهم، أو إذا كانت تفضيلات المستخدمين غامضة جداً ولا يمكن العثور على العناصر المطابقة لتفضيلاتهم. لذا يمكن قياس التغطية هنا عن طريق غنى الملف الشخصي للمستخدم بالمعلومات المطلوبة لتقديم توصيات [71]. مثلاً، في حالة التصنيفية التعاونية، تغطية المستخدم يمكن قياسها كعدد التقييمات التي يجب على المستخدم تزويدها قبل تلقي التوصيات [67].

#### 2-4-3 التنوع (Diversity)

التنوع هو مقياس لمدى اختلاف توصيات المستخدم عن بعضها البعض [72]. مثلاً، لنفرض أن المستخدم قد انتهى من مشاهدة الجزء الأول من فيلم ما على "Netflix"، قد يقوم نظام التوصية باقتراح الأجزاء التالية من هذا الفيلم للمستخدم، وبالتالي تكون التوصية منخفضة التنوع. من ناحية أخرى، يمكن تحقيق تنوع كبير من خلال التوصية بالعناصر بشكل عشوائي تماماً. قد يبدو التنوع كمقياس شخصي، ولكن يمكن حسابه باستخدام متوسط درجة التشابه بين العناصر الموصى بها. لنفرض  $sim_N$  متوسط درجة التشابه من أجل قائمة التوصية  $N$ ، يمكن استنتاج قيمة "Diversity" على أنه عكس متوسط درجة التشابه، كما في المعادلة التالية:

$$Diversity_N = 1 - sim_N \quad (20)$$

إن اعتبار التنوع فقط كمقياس لجودة التوصية يمكن أن يكون مضللاً. هذا هو السبب في أنه يجب استخدامه كمكمل إلى جانب المقاييس الأخرى.

#### 2-4-3 الابتكار (Novelty)

الابتكار هو مقياس لمدى شعبية العناصر المقترحة في نظام التوصية، قد يكون الابتكار مشابه لِمقياس التنوع، حيث يمكن أيضاً لنظام التوصية أن يحقق "Novelty" أعلى من خلال التوصية بالعناصر بشكل عشوائي لأن معظم العناصر ليست في قائمة العناصر الشائعة. على الرغم من أنه يمكن حساب "Novelty"، إلا أنه من الصعب استخدامه لوحده للتعبير عن جودة نظام التوصية [72]. يرغب المستخدمون غالباً في رؤية التوصيات الشائعة في قائمة توصياتهم لأن هذا من شأنه أن يجلب ثقتهم لنظام التوصية. إذا كانت أنظمة التوصية توصي فقط بالعناصر التي لاتعكس اهتمام المستخدم [73]، فقد يؤدي ذلك إلى الإضرار بثقة المستخدم ودفعه إلى مغادرة التطبيق الذي يتحكم به نظام التوصية.

يجب أن يحافظ نظام التوصية على التوازن بين نسبة العناصر التي قد تعجب المستخدم والعناصر التي لا يعرفها ولكن يمكن اكتشافها في قائمة التوصيات. في حين أن العناصر المألوفة ستسمح للمستخدمين بالثقة في نظام التوصية، فإنّ العنصر الغير مألوف سيسمح لهم باكتشاف أشياء جديدة. يمكن أن يساعد تحقيق قيمة ابتكار جيدة في حل مشكلة الذيل الطويل وهذا هو السبب في أنّه مقياس مهم يجب استخدامه.

## الفصل الثالث: الدراسة المرجعية

### 1-3 مقدمة

نقدم في هذا الفصل شرحاً تحليلياً عن أهم الأبحاث في نظم التوصية باستخدام طرق التوصية الأساسية: المعتمدة على المحتوى باستخدام ميزات محددة، التصنيفية التعاونية بنوعها: عامل المصفوفة والتعلم العميق ثم التوصية الهجينة ما بين طريقة عامل المصفوفة وطريقة العنقدة. علماً أنه، طبقنا الطرق المذكورة سابقاً وفقاً لمشكلة البحث وهي بناء نظام توصية بالاعتماد على المعطيات الضمنية المستخرجة من سجلات مشاهدات المستخدمين.

### 2-3 نظم التوصية بالاعتماد على المحتوى

قدّمت [74] نظام توصية لبرامج تلفزيونية بالاعتماد على محتوى البرامج. مثلاً، معلومات عن مقدّمي البرامج، بالإضافة إلى الكلمات الرئيسية الواردة في البرامج باستخدام دليل البرنامج الإلكتروني "EPG"، وبيانات سجل المشاهدين لشهر واحد، استُخدمت معلومات النصف الأول من هذا الشهر للتدريب والجزء الآخر للاختبار. استُخرجت قيمة الميزات السابقة عن طريق حساب احتمال ورودها ضمن مجموعة التدريب لكل مشاهد. في الجدول 3، 4 إحصائيات عن معلومات التدريب والاختبار على التوالي.

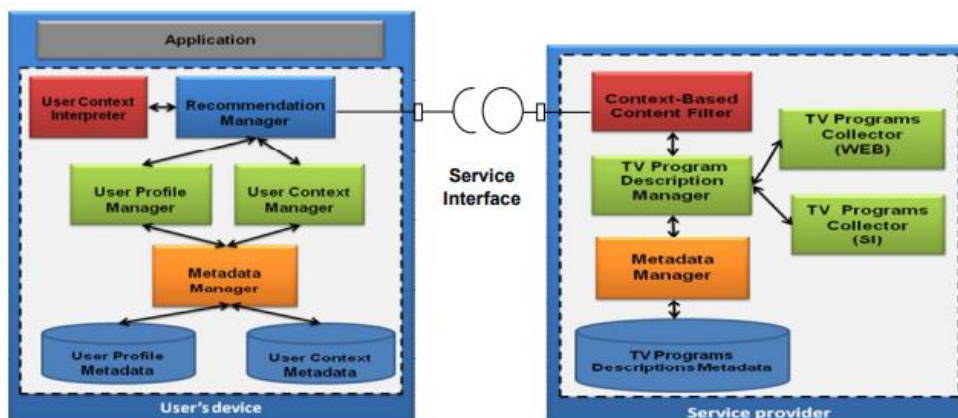
الجدول 3: إحصائيات عن معلومات تدريب "EPG"

| عدد العناصر | عدد المستخدمين | المعطيات المستخدمة |
|-------------|----------------|--------------------|
| 111343      | 923            | "EPG"              |

الجدول 4: إحصائيات عن معلومات اختبار "EPG"

| المعطيات المستخدمة | عدد المستخدمين | عدد العناصر | Recall | precision |
|--------------------|----------------|-------------|--------|-----------|
| "EPG"              | 10             | 1000        | 0.1    | 0.8       |

قدّم [75] بنية مقترحة من أجل التوصية الشخصية للبرامج التلفزيونية أيضاً باستخدام دليل البرنامج الإلكتروني "EPG" بالاعتماد على ملف تعريف المستخدم السياقي: نوع البرنامج، الوقت وموقع جهاز الوصول الحالي بعنوان "PersonalTVware"، كما في الشكل 8. لقد حصلوا على هذه المعلومات عن المستخدمين عن طريق سؤالهم مباشرة. قاموا بتطبيق الطرق المعتمدة على أسلوب الاستدلال القائم على القواعد لاستنتاج العلاقات بين الأبعاد السياقية بطريقة مرنة وبالتالي التوصية المناسبة للمستخدمين.



الشكل 8: بنية "PersonalTVware"

استخدم [76] نظام توصية لأفلام يعتمد على المحتوى والذي يمكن أن يستخدم مجموعات مميزات مختلفة، وهي ميزات الممثل، ميزات المخرج وميزات النوع، باستخدام مجموعة معطيات خاصة بهم تدعى "log data". قاموا بتعيين وزن لكل ميزة من الميزات السابقة لكل مستخدم

بناءً على السلوك السابق له. تم أنتجوا التقييم الضمني للفيلم بناءً على مدة الفيلم الذي شاهده المستخدم، وذلك بدمج أوزان الميزات المرتبطة بالعناصر التي شاهدها المستخدم. في الجدول 5، 6 إحصائيات عن معلومات التدريب والاختبار على التوالي.

الجدول 5: إحصائيات عن معلومات تدريب "PersonalTVware"

| المعطيات المستخدمة | عدد الأبطال | عدد المخرجين | عدد الأنواع |
|--------------------|-------------|--------------|-------------|
| "log data"         | 4716        | 1927         | 34          |

الجدول 6: إحصائيات عن معلومات اختبار "PersonalTVware"

| المعطيات المستخدمة | عدد المستخدمين | عدد العناصر | Recall | precision |
|--------------------|----------------|-------------|--------|-----------|
| "log data"         | 621            | 3700        | 0.06   | 0.136     |

### 3-3 نظم التوصية بالاعتماد على التصفية التعاونية

قدم [77] طريقة عامل المصفوفة لبناء نظام توصية كما هي في "Netflix" والتي هي من أشهر طرق التصفية التعاونية، حيث أظهرنا كيف تم استنتاج العوامل الكامنة من مصفوفة تصنيفات المستخدمين للعناصر باستخدام تقنية عامل المصفوفة، هذه العوامل المكتشفة تقيس أبعاداً جديدة واضحة. مثلاً، في حالة الأفلام: العلاقة بين الدراما والكوميديا، أو العلاقة بين نوع الأفلام وكل فئة عمرية. أو أبعاداً أقل تحديداً، مثل عمق تطور الشخصية أو الغرابة، أو أبعاداً غير قابلة للتفسير. لتحقيق ذلك طورت تقنية عامل المصفوفة التقليدية بحيث استطاعت أن تتغلب على مشكلة الإنحياز في التقييمات باستخدام متوسط التقييمات وطرحه من قيم التصنيف الصريح، وأيضاً استطاعت أن تتغلب على مشكلة بعثرة المعطيات الناتجة عن استخدام الآراء الصريحة، وذلك بالاستفادة أيضاً من الآراء الضمنية لجعل مصفوفة التقييم أكثر كثافة. كما أُعيد ضبط وزن التقييمات عن طريق إرفاق تكرار الإجراءات كقيم عددية. مثلاً، مقدار الوقت الذي شاهد المستخدم خلاله عنصر معين، أو عدد المرات التي اشترى فيها المستخدم عنصراً معيناً. يمكننا ملاحظة نتائج كل عامل من العوامل السابقة على مقياس الدقة المستخدم، وهو RMSE، كما في الجدول 7.

الجدول 7: مقارنة نتائج الخوارزميات المتبعة في Netflix باستخدام مقياس RMSE

| الخوارزمية المتبعة                                       | RMSE  |
|--|-------|
| طريقة عامل المصفوفة التقليدية                            | 0.909 |
| طريقة عامل المصفوفة التقليدية مع حل مشكلة الإنحياز       | 0.905 |
| طريقة عامل المصفوفة التقليدية مع البيانات الضمنية        | 0.894 |
| طريقة عامل المصفوفة التقليدية مع إعادة ضبط وزن التقييمات | 0.884 |

وجد [78] أن الدمج بين تقنية عامل المصفوفة وخوارزمية أقرب جار يعطي نتائج أفضل من أجل مشكلة التوصية، حيث طبق الباحثون تقنية عامل المصفوفة و تقنية أقرب جار، على الترتيب باستخدام معطيات تخص الأفلام، تحوي 2113 مستخدم، 10197 فيلم، 85559 ميزة تقييم وبعثرة معطيات 96%. تم قارنوا نتائج كل تقنية ودمجوا المشاهدين. كان مقدار التحسن بمقدار 0.001 باستخدام مقياس RMSE مقارنة باستخدام تقنية المصفوفة لوحدها، كما في الجدول 8.

الجدول 8: مقارنة الخوارزميات المطبقة للبحث [78] باستخدام مقياس الخطأ RMSE

| الخوارزمية المطبقة                        | RMSE  |
|---|-------|
| طريق عامل المصفوفة                        | 0.789 |
| دمج طريقة عامل المصفوفة مع تقنية أقرب جار | 0.788 |

### 4-3 نظم التوصية بالاعتماد على التعلم العميق

اقترح [79] بنية شبكة عصبية لمحاكات العلاقات بين المستخدمين والعناصر دون وجود ميزة التقييم، والتي بدورها تقدم مستوى عالٍ من قدرات النمذجة اللاخطية ضمن إطار يدعى التصنيفية التعاونية القائمة على الشبكة العصبية "Neural Collaborative Filtering"، وذلك من خلال الإستفادة من الإدراك المتعدد الطبقات (Multi-Layer Perceptron) "MLP" من أجل تعلم وظيفة التفاعل بين المستخدم والعنصر، دون وجود ميزة التقييم. افترض الباحثون أنّ تفاعل المستخدم مع العنصر دليل على إعجابه به والعكس بالعكس. قام الباحثون بدمج "MLP" مع عامل المصفوفة ذي العلاقة الخطية، حيث فسروا عامل المصفوفة على أنّه حالة خاصة من التصنيفية التعاونية العصبية. قام الباحثون بإجراء تجارب على مجموعتين من البيانات الواقعية تخصان الأفلام والكتب كما في الجدول 9، ومقارنة النتائج باستخدام مقياسي "HR" و "NDCG" كما في الجدول 10.

الجدول 9: بعض الخصائص الاحصائية لمجموعتي المعطيات "MovieLens" و "Pinterest"

| المعطيات المستخدمة | عدد الجلسات | عدد العناصر | عدد المستخدمين | خلخلة المعطيات |
|--------------------|-------------|-------------|----------------|----------------|
| "MovieLens"        | 1,000,209   | 3,706       | 6,040          | 95.53%         |
| "Pinterest"        | 1,500,809   | 9,916       | 55,187         | 99.73%         |

الجدول 10: مقارنة نتائج الاختبار على مجموعتي المعطيات لمجموعتي المعطيات "MovieLens" و "Pinterest"

| المعطيات المستخدمة | "HR"  | "NDCG" |
|--------------------|-------|--------|
| "MovieLens"        | 0.678 | 0.406  |
| "Pinterest"        | 0.862 | 0.539  |

## الفصل الرابع: النماذج المقترحة والنتائج

## 1-4 مقدمة

تعتمد معظم أنظمة التوصية على ميزة التقييم لتشكيل توصيات تناسب اهتمامات المستخدمين، لكن مشكلة البحث هي غياب هذه الميزة. لذلك تم اقتراح عدة تقنيات لحساب التوصيات بالاعتماد على استنتاج علاقات ضمنية من تفاعلات المستخدم مع العنصر. هناك عدة طرق لاستنتاج هذه العلاقات، إما بشكل مباشر من خلال النقر / عدم النقر كما في نموذج التعلم العميق NCF-A، أو بشكل غير مباشر من خلال مدة المشاهدة كما في نموذج التعلم العميق NCF-D ونموذجي CB و ALS&KNN. اقترحنا عدة مقاييس ومنهجيات مختلفة لتقييم أداء نظام التوصية اعتماداً على خصائص التوصية المختلفة، وعلى أساس هذه المقاييس قمنا بتحليل النتائج ومقارنة النماذج المقترحة فيما بينها.

## 2-4 المعطيات المستخدمة في البحث

اعتمدنا في هذه الأطروحة على معطيات شركة سيريتل المتولدة من سجلات تطبيق ISHOW للأفلام والمسلسلات. قمنا باستخدام معطيات مجمعة خلال فترة 11 شهراً، بحيث تكون الأشهر العشرة الأولى من أجل مرحلة التدريب، والشهر الأخير من أجل مرحلة الاختبار. يعرض الجدول 11 بعض الإحصائيات عن معطيات التدريب، كما يعرض الجدول 12 إحصائيات عن معطيات الاختبار.

الجدول 11: بعض خصائص معطيات تدريب تطبيق ISHOW

| نوع البيانات | عدد الجلسات | عدد العناصر | عدد المستخدمين | خلصة البيانات |
|--------------|-------------|-------------|----------------|---------------|
| أفلام        | 829314      | 12864       | 64376          | 99.89%98.33   |
| مسلسلات      | 738365      | 1576        | 87549          | 99.46%93.54   |

الجدول 12: بعض خصائص معطيات اختبار تطبيق ISHOW

| نوع البيانات | عدد الجلسات | عدد العناصر | عدد المستخدمين |
|--------------|-------------|-------------|----------------|
| أفلام        | 108064      | 11795       | 8722           |
| مسلسلات      | 143987      | 1199        | 28125          |

## 3-4 بنية النموذج المقترح الأول CB

في هذا النموذج قدمنا طريقة لبناء التقييم بناءً على مدة مشاهدة المحتوى كما في [76]، حيث اتبعنا المراحل التالية:

### I. تحويل مدة المشاهدة إلى تقييم مبدئي

في نظامنا، لا يقوم المستخدمون بتقييم الخدمات بشكل صريح، لذلك اعتمدنا على مدة المشاهدة لحساب التقييم كما في [74]، افترضنا أن المستخدم  $u$  شاهد الخدمة  $i$  (فيلم، مسلسل) لمدة دقيقتين  $t_{ui}$  خلال مدة التدريب. علماً أن مدة الخدمة الكلي  $t_i$ ، فيكون التقييم المبدئي كالتالي:

$$R_{u,i} = \frac{t_{u,i}}{t_i} \quad (21)$$

### II. حساب وزن الميزة في كل خدمة

الهدف من نظام التوصية هو العثور على الخدمات التي قد يرغب المستخدم بالفعل في مشاهدتها. استخدمنا ميزات الخدمات التي شاهدها المستخدم في الماضي والتصنيفات المبدئية لها، وذلك لحساب وزن الميزة لكل مستخدم كما في [76]، حيث الميزات المستخدمة كالتالي: الممثل، النوع، المخرج والكاتب. محتويات التدريب لدينا 4716 ممثلون، 1927 مخرجاً، 34 نوعاً. قمنا بتعيين وزن كل ميزة وفقاً للتصنيف المبدئي للمستخدم لجميع محتويات بيانات التدريب بما في ذلك تلك الميزة. قد تحتوي مجموعة ميزات الممثل على ميزات مثل Mahmoud Yassine و Natalie Portman و Nour El Sherif، قد تحتوي مجموعة ميزات النوع

على Crime، Drama، Thriller، قد تحتوي مجموعة ميزات المخرج على Chanda Bell، Frederic Raphael، Mohamed Hassib، وما إلى ذلك.

ليكن لدينا المستخدم  $u$ ، قد شاهد الخدمات التالية  $i_1, \dots, i_9$  والتي لها الميزات التالية  $j_1, j_2, j_3, \dots, j_c$ . نلاحظ في الجدول 13، الميزات  $J_c$  التي تخص الخدمات التي شاهدها المستخدم  $u$ . علماً أنّ،  $j_1, j_2, j_3, \dots$  هي الميزات التي تظهر في الخدمات التي شاهدها كل المستخدمين في مجموعة التدريب. العمود الأخير يظهر فيه قيمة التصنيف المبدئي الذي أُستخرج من المرحلة السابقة للمستخدم  $u$  للخدمات  $I_9$  التي شاهدها في مجموعة التدريب. إن وزن الميزة  $j$  في  $J_c$  للمستخدم  $u$ ، يمكن حسابها كالتالي:

$$w_c(u, j) = \frac{1}{|I_u^{train}|} \sum_{i \in I_u^{train}} X_{c,u}(i, j) R_{u,i} \quad (21)$$

حيث {ممثل، مخرج، كاتب، نوع}  $c \in \{0, 1\}$  يشير إذا الميزة  $j$  موجودة ضمن الخدمة  $i$  أم لا، و  $I_u^{train}$  هي مجموعة الخدمات التي شاهدها المستخدم  $u$  ضمن مجموعة التدريب.

الجدول 13: مصفوفة مميزات الخدمات التي شاهدها المستخدم  $u$

| المستخدم $u$ | $j_1$ | $j_2$ | $j_3$ | ... | $j_c$ | $R_{u,i}$ |
|--------------|-------|-------|-------|-----|-------|-----------|
| $i_1$        | 1     | 1     | 0     | ... | ...   | 0.5       |
| $i_2$        | 0     | 1     | 0     | ... | ...   | 0.3       |
| $i_3$        | 1     | 1     | 1     | ... | ...   | 0.9       |
| $i_4$        | 1     | 0     | 0     | ... | ...   | 0.7       |
| $i_5$        | 0     | 0     | 0     | ... | ...   | 0.2       |
| $i_6$        | 1     | 0     | 0     | ... | ...   | 1.0       |
| $i_7$        | 1     | 0     | 0     | ... | ...   | 0.44      |
| $i_8$        | 0     | 1     | 0     | ... | ...   | 0.67      |
| $i_9$        | 1     | 0     | 0     | ... | ...   | 0.2       |
| $w_c(u, j)$  | 0.42  | 0.26  | 0.1   | ... | ...   | -         |

### III. دمج الأوزان في عملية حساب التقييم

في هذه المرحلة قمنا بتعديل قيم التقييم المبدئي في المرحلة الأولى بالاستعانة بأوزان الميزات [76] والتي أُستخرجت في الخطوة السابقة كما يلي:

$$R_c(u, i) = \sum_{j \in D_{c,i}} w_c(u, j) \quad (22)$$

حيث  $D_{c,i}$  تمثل الميزات التي تظهر في الخدمة  $i$  من مجموعة الميزات  $c$ .

قمنا بإجراء استبيان على 100 مستخدم حول الميزة الأكثر أهمية ضمن مجموعة الميزات التالية {ممثل، مخرج، كاتب، نوع}، كانت النتيجة هي ميزة النوع {Category}. لذلك، عدّلنا طريقة دمج الأوزان لتصبح كالتالي:

$$R_c(u, i) = \sum_{j \in D_{c,i} \& j \notin \text{Category}} w_c(u, j) + \sum_{j \in \text{Category}} f * w_c(u, j) \quad (23)$$

حيث  $f$  هي عامل تعظيم لميزة النوع، تبدأ قيمها من 1 وتزداد تدريجياً بمقدار 0.5 بحيث تقف عندما تنخفض قيمة التقييم. في الجدول 14 نتائج التجريب.

الجدول 14: نتائج تعظيم ميزة النوع على قيم التقييم باستخدام مقياسي التقييم Precision & Recall

| المسلسلات |           | الأفلام |           | العامل $f$ |
|-----------|-----------|---------|-----------|------------|
| Recall    | Precision | Recall  | Precision |            |
| 0.38      | 0.31      | 0.09    | 0.149     | 1          |
| 0.91      | 0.33      | 0.24    | 0.156     | 1.5        |
| 0.18      | 0.32      | 0.63    | 0.169     | 2          |
| 0.09      | 0.29      | 0.37    | 0.161     | 2.5        |

نلاحظ من الجدول 14 أن القيمة الأفضل لعامل تعظيم ميزة النوع هو "2" بالنسبة للأفلام و"1.5" بالنسبة للمسلسلات.

#### IV. تسوية قيم التقييم

لاحظنا مما سبق أن عدد الميزات في كل خدمة يختلف عن الخدمة الأخرى، كما أن قيم  $R_c(u, j)$  قد تكون في مجالات مختلفة بالنسبة لكل مستخدم. لذلك، نحتاج إلى تسوية قيم التقييم كما في المعادلة التالية:

$$\hat{R}_c(u, i) = \frac{(R_c(u, i) - mR_{u,c})}{MR_{u,c} - mR_{u,c}} \quad (24)$$

استخدمنا طريقة  $Min - Max$  لتسوية قيم التقييم، حيث  $mR_{u,c}$  تشير إلى أصغر قيمة تقييم للمستخدم  $u$  ضمن مجموعة الميزات  $c$  في مجموعة التدريب بينما  $MR_{u,c}$  تشير إلى أكبر هذه القيم.

#### 4-4 بنية النموذج المقترح الثاني MF&KNN

اقترحنا في هذا النموذج دمج عامل المصفوفة MF مع طريقة أقرب جار KNN. يعتبر عامل المصفوفة من أشهر طرق التصنيفية التعاونية، يُستخدم للتنبؤ بالقيم المفقودة ضمن مصفوفة التقييم  $R_{i,j}$ . تعتمد طريقة MF على شرح التقييمات عن طريق تمييز كل من العناصر والمستخدمين بعدد من العوامل الكامنة  $K$  مستنتجة من أنماط التقييم [80]. بشكل رياضي، تقوم هذه المصفوفة بتحليل مصفوفة التقييم  $R_{i,j}$  إلى جداء مصفوفتين  $U$  و  $P$  للمستخدمين والعناصر على التوالي، كلتا المصفوفتين ذات مرتبة  $K$ . من أشهر تقنيات عامل المصفوفة التي تعمل بطريقة موزعة وفعالة مع البيانات الضمنية هي ALS. تقوم ALS بربط كل مستخدم بشعاع  $u_{ik}$  وكل خدمة بشعاع  $p_{kj}$  حيث  $k$  تمثل عدد العوامل الكامنة التي يمكن استنتاجها من نموذج ALS والتي يمكن تحديدها قيمتها المثلى من خلال اختبار أصغر قيمة يمكن أن نصل إليها من خلال تابع التكلفة (Cost Function).

من أجل بناء نموذج MF، في البداية نملأ الشعاعين السابقين بقيم عشوائية، ثم نثبت أحد الشعاعين ونقوم بحساب قيم الشعاع الآخر بحيث يكون الفرق بين التصنيفات الموجودة والتصنيفات المتوقعة أصغر ما يمكن، من أجل ضبط هذه المرحلة نقوم بحساب (Cost Function) لكل تكرار تدريب، ثم نبدل بين الشعاعين ونكرر المرحلة إلى أن نملأ كافة التقييمات المفقودة. عند ذلك، يمكن التعبير عن تفاعلات المستخدمين مع العناصر بعلاقة خطية  $u_{ik} \times p_{kj}^T$ . إن الهدف من نموذج MF هو تعميم تلك التقييمات الموجودة بطريقة تساعد على التنبؤ بالتقييمات المفقودة. وبالتالي، على النموذج أيضاً أن يتجنب الإفراط في تجهيز البيانات "Overfitting" عن طريق حساب (Regularization Term)، عندها يمكننا تصور عمل ALS بأنها تقوم بحساب العوامل الكامنة الممثلة في عناصر  $u_i$  و  $p_j$  وذلك بتقليل نسبة الخطأ  $Error_{ij}$  كما في المعادلة (25).

$$Error_{ij} = \underbrace{\sum w_{i,j}}_{\text{Completion term}} \cdot \underbrace{(R_{i,j} - u_{ik} \times p_{kj}^T)}_{\text{Cost Function}} \quad (25)$$

Where  $w = \begin{cases} 1 & R \text{ is known} \\ 0 & R \text{ is unknown} \end{cases}$  Minimizes the difference between and the original ratings matrix

حيث *Completion term* هو شرط المرور على كافة عناصر المصفوفة، *Regularization Term* يمثل طريقة تنظيم النموذج "*L<sub>2</sub> norm*". علماً أنّ  $\lambda$  يمثل معامل التنظيم.

تُما سبق نستنتج معاملات نموذج ALS وهي  $K$ ،  $\lambda$ ، عدد تكرارات التدريب. يمكن تحقيق ذلك عن طريق واجهة برمجية تطبيقات التعلم الآلي *Mlib API* ضمن بيئة العمل الموزع *Spark*.

تمّ الإعتاد في تصميم نموذج ALS على محرك التنفيذ *Spark*، كأداة من أجل معالجة البيانات وتحديد السيات واختبار الموديل، كونه يحوي مكتبات من أجل تنفيذ جميع مراحل تحضير البيانات وتعلّم الآلة. تدعم مكتبة *Mlib* خوارزميات التعلم الآلي *Spark ML* ومنها *ALS*. نتيجة التجريب ظهر أنّ حذف المستخدمين الذين لديهم تفاعل واحد أو اثنين من شأنه ان يقلّل  $Error_{i,j}$  بشكل كبير يصل إلى 30%، حيث نسبة هؤلاء المستخدمين 40% بالنسبة للأفلام و 38% بالنسبة للسلسلات. يوضّح الجدول 15 القيم المختارة لنموذج *ALS*.

الجدول 15: قيم معاملات نموذج ALS لحساب التقييم

| المسلسلات | الأفلام | معلمات نموذج ALS |
|-----------|---------|------------------|
| 12        | 15      | $K$              |
| 0.01      | 0.01    | $\lambda$        |
| 13        | 15      | عدد مرات التدريب |
| 0.69      | 0.62    | RMSE             |

يمكن تلخيص مراحل تشكيل نموذج ALS&KNN [81] [2]:

- تحميل بيانات التقييم الضمنية المستخرجة من النموذج السابق CB ضمن مصفوفة التقييم  $R_{i,j}$ .
- إخراج المستخدمين ذوي التفاعل الواحد أو التفاعلين من المصفوفة السابقة.
- بناء نموذج ALS ضمن *Spark Mlib 2.3*.
- استخراج أعلى "10" خدمات من نتائج نموذج *ALS*.
- بالنسبة للمستخدمين الذين لديهم تفاعل واحد أو اثنين، نطبق عليهم نموذج KNN للعثور على أعلى "10" خدمات الأكثر تشابهاً مع تفاعلاتهم.

## 5-4 بنية النموذج المقترح الثالث NCF-A

في هذا النموذج استخدمنا بنية عصبية تعاونية (NCF) Neural Collaborative Filtering لمحاكاة الخصائص المحتملة للمستخدمين والعناصر، حيث تمّ استبدال المنتج الداخلي في عامل المصفوفة والتي استخدمت في النموذج السابق بشبكة عصبية متعددة الطبقات تدعى Multi layer Perceptron (MLP)، حيث يمكنها أن تقيس التفاعل بين المستخدم والعنصر بطريقة غير خطية مما يعطي هذا النموذج مرونة عالية [79].

تتكوّن خوارزمية التعلّم من أربعة مكونات أساسية: تابع التكلفة Cost Function، خوارزمية الأمثلة Optimization Algorithm، النموذج Model ومجموعة المعطيات Dataset. يمكن تقسيم عملية التعلّم لهذه الخوارزميات إلى قسمين التدريب Training والاختبار Testing. يتعلق التدريب بتوقع العلاقة بين الدخل والخرج من خلال نموذج يهدف تحسين معيار الأمثلة، وبالتالي التقليص من خطأ التدريب، بينما يعبر الاختبار عن مدى جودة أداء النموذج في المعطيات الجديدة غير المرئية سابقاً، وبالتالي يُقدّر خطأ التعميم.

• مجموعة المعطيات

فما يُمثل تفاعلات المستخدم  $u$  مع العنصر  $i$  على الشكل التالي:

$$y_{ui} = \begin{cases} 1 & \text{إذا كان هناك تفاعل بين المستخدم } u \text{ والخدمة } i \\ 0 & \text{غير ذلك} \end{cases} \quad (26)$$

فما بأخذ أربعة عينات سلبية لكل عينة إيجابية بشكل عشوائي من أجل تدريب مجموعة المعطيات. استخرجنا أعلى 10 عناصر كقائمة توصية واستخدمنا مقياسي HR و NDCG للحكم على أداء هذه القائمة في كل تكرار تدريب.

• النموذج Model

النموذج هنا هو شبكة عصبونية متعددة الطبقات MLP، تكون على شكل طبقات من العصبونات: طبقة دخل Input Layer، طبقة خرج Output Layer وطبقات مخفية Hidden Layers تتواجد بين طبقتي الدخل والخرج. يتميز كل اتصال بين عصبون وآخر بارتباطه بقيمة تدعى الوزن Weight وهي تعبر عن مدى أهمية الارتباط بين هذين العنصرين، يقوم العصبون بضرب كل قيمة دخل واردة من عصبونات الطبقة السابقة بأوزان الوصلات مع هذه العصبونات، ومن ثمّ جمع كافة نواتج الضرب، ثمّ يُخضع النتيجة لتابع تفعيل Activation Function " $\phi$ "، ويُعتبر ناتج تابع التفعيل خرجاً للعصبون والذي يُنقل إلى عصبونات الطبقة اللاحقة. يوجد عدة أنواع لتوابع التفعيل، توابع تفعيل خطية، شبه خطية، غير خطية، وتُستخدم توابع التفعيل هذه في الطبقات المخفية وطبقة الخرج. استخدمنا تابع التفعيل ReLU في الطبقات المخفية وتابع Sigmoid في طبقة الخرج لنتحكم بنتيجة النموذج  $\hat{y}_{ui}$  "0" أو "1". من أجل تعريف طبقات MLP " $z_L$ " تبدأ في طبقة الدخل، حيث يتألف شعاع الدخل من دمج أشعة التضمين لكل من المستخدم والعنصر كما في العلاقة:

$$z_1 = \phi_1(p_u, q_i) = \text{Concatenate}(p_u, q_i) = \begin{bmatrix} p_u \\ q_i \end{bmatrix} \quad (27)$$

يتبعها عدد من الطبقات المخفية، كما ذكرنا اخترنا تابع التفعيل ReLU في الطبقات المخفية وفق العلاقة التالية:

$$\phi_L(z_{X-1}) = \text{ReLU}(w_X z_{X-1} + b_X) \quad (28)$$

حيث  $w_X$  و  $b_X$  مصفوفة الأوزان وشعاع الانحياز في الطبقة  $X$  على التوالي.

نتوقع للمستخدم قيمة "0" أو "1" ضمن طبقة الخرج لذلك استخدمنا تابع التفعيل Sigmoid باستخدام المعادلة التالية:

$$\hat{y}_{ui} = \text{Sigmoid}(w_X \phi_X(z_{X-1})) \quad (29)$$

حيث  $X$  عدد طبقات الشبكة.

• تابع التكلفة Cost Function

يقوم تابع التكلفة بحساب الفرق بين القيمة المقدرة  $\hat{y}_{ui}$  والقيمة الحقيقية  $y_{ui}$ . اخترنا طريقة التحسين النقطي pointwise loss لتقليل الخطأ كما في (23).

$$L_{sq} = \sum_{(u,i) \in Y \cup Y^-} w_{ui} (y_{ui} - \hat{y}_{ui})^2 \quad (30)$$

حيث تمثل  $Y$  قيم  $y_{ui}$  والتي تساوي "1"، بينما  $Y^-$  تمثل قيم  $y_{ui}$  والتي تساوي "0". هذه الخسارة التربيعية تتوافق مع البيانات ذات التوزيع الغاوسي، لكن البيانات المدخلة  $y_{ui}$  ذات توزيع ثنائي  $\{0, 1\}$ ، لذلك نحن بحاجة لتقييد  $\hat{y}_{ui}$  ضمن المجال  $[0, 1]$ . يمكن تحقيق ذلك باستخدام دالة احتمالية Logistic كوظيفة تنشيط Activation Function عند طبقة الإخراج  $\phi_{out}$ . في البداية نعرّف الوظيفة الاحتمالية المطلوبة كما يلي:

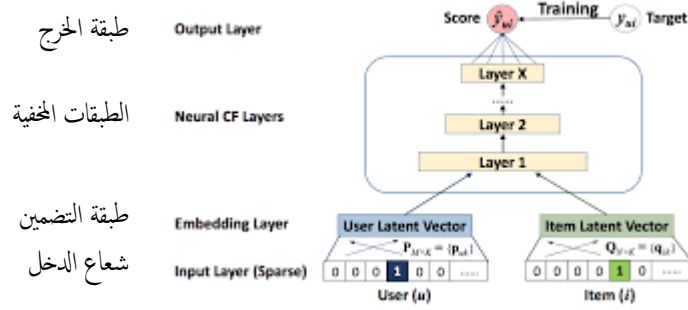
$$P(Y, Y^- | P, Q, \theta_f) = \prod_{(u,i) \in Y} \hat{y}_{ui} \prod_{(u,j) \in Y^-} (1 - \hat{y}_{uj}) \quad (31)$$

حيث  $P \in p_{uk}$ ،  $Q \in q_{ik}$ ،  $p_{uk}$  تمثل العوامل الكامنة للمستخدم  $u$ ،  $q_{ik}$  تمثل العوامل الكامنة للعنصر  $q$ .  $K$  عدد العوامل الكامنة،  $\theta_f$  يمثل معاملات النموذج لوظيفة التفاعل  $\hat{y}_{ui}$ . لأنّ هدفنا تقليل الخسارة، نأخذ اللوغاريتم السليبي كما يلي:

$$L = \sum_{(u,i) \in Y} \log \hat{y}_{ui} - \sum_{(u,j) \in Y^c} \log(1 - \hat{y}_{uj})$$

$$= - \sum_{(u,i) \in Y \cup Y^c} y_{ui} \log \hat{y}_{ui} + (1 - y_{ui}) \log(1 - \hat{y}_{uj}) \quad (32)$$

يبين الجدول 16 القيم المختارة لمعاملات نموذج MLP، والشكل 9 بنية شبكة MLP.



الشكل 9: بنية الشبكة العصبية متعددة الطبقات MLP

الجدول 16: معاملات نموذج MLP لحساب التنبؤ بتفضيل المستخدم

| القيمة    | الموسم                                   |
|-----------|--|
| 256       | حجم دفعة التدريب                         |
| 5         | عدد تكرارات التدريب                      |
| 16        | طول شعاع التضمين لكل من المستخدم والعنصر |
| [8,16,32] | الطبقات المخفية                          |
| 1         | عصبونات طبقة الخرج                       |
| Adam      | خوارزمية الأمثلة                         |

## 6-4 بنية النموذج المقترح الرابع NCF-D

في هذا النموذج أعادنا استخدام الشبكة العصبية السابقة NCF، لكن مع تعديل طبيعة البيانات المدخلة. استبدلنا المعادلة 22 بالمعادلة التالية:

$$y_{ui} = \begin{cases} 1 & \text{إذا كانت مدة مشاهدة الخدمة أكبر من العتبة} \\ 0 & \text{غير ذلك} \end{cases} \quad (33)$$



نلاحظ أننا عكسنا الوقت الذي يقضيه المستخدم وهو يشاهد عنصر ما كقياس غير مباشر للتقييم، وذلك بناءً على حد معين (500 ثانية للأفلام و1000 ثانية للمسلسل). نقول بملئ المصروفة السابقة بـ "1" إذا كانت مدة المشاهدة أكبر من الحد، و"0" عكس ذلك. نلاحظ في الشكل 10 توزيع مدة المشاهدة وفق عدد المسلسلات والأفلام التي تمت مشاهدتها. من أجل مرحلة التدريب نحتاج طريقة مختلفة للتعامل مع عدد العناصر التي لم تتم مشاهدتها بعد، لذلك نتبع الخطوات التالية:

- بالنسبة إلى المستخدمين الذين ليس لديهم عناصر "0"، قمنا بإضافة ضعف عدد العناصر الإيجابية بشكل عشوائي.
- بالنسبة إلى المستخدمين الذين لديهم عناصر "1" أقل من ضعف عدد العناصر "0"، قمنا بتنفيذ الإستراتيجية التالية:

– استخدمنا طريقة استخراج ميزة CountVectorizer من مكتبة scikit-Learn لتحويل كل عنصر إلى ناقل ميزة باستخدام مجموعة الكلمات (النوع، والكتاب، والمخرجين والممثلين)، واستخدمنا تشابه جيب التمام Cosine كطريقة لقياس التشابه بين عنصرين.

– أضفنا عناصر "0" بمقدار S حيث  $S = (2 \times \text{count items "1"} - \text{count items "0"})$  عن طريق اختيار عناصر S الأكثر تشابهاً مع العناصر "0" في مجموعة التدريب.

– بالنسبة إلى المستخدمين الذين لم نعتز على عناصر مشابهة لهم في مجموعة التدريب، أضفنا عناصر S بشكل عشوائي وذلك من ضمن العناصر التي لم تتم مشاهدتها بعد.



الشكل 10: توزيع المدة بناءً على عدد الأفلام والمسلسلات التي تمت مشاهدتها

## 7-4 مقاييس التقييم المطبقة

كما ذكرنا في القسم 4-2 من أجل تقييم أنظمة التوصية، اعتمدنا على المقاييس الستة التالية: HR، NDCG، متوسط النسب المئوية للتوصيات التي تم التقاطها بشكل صحيح (Mean of Percentage of correctly captured predictions) ندعوها اختصاراً Mean - PCCP، Diversity، Coverage و Novelty.

### HR & NDCG 1-7-4

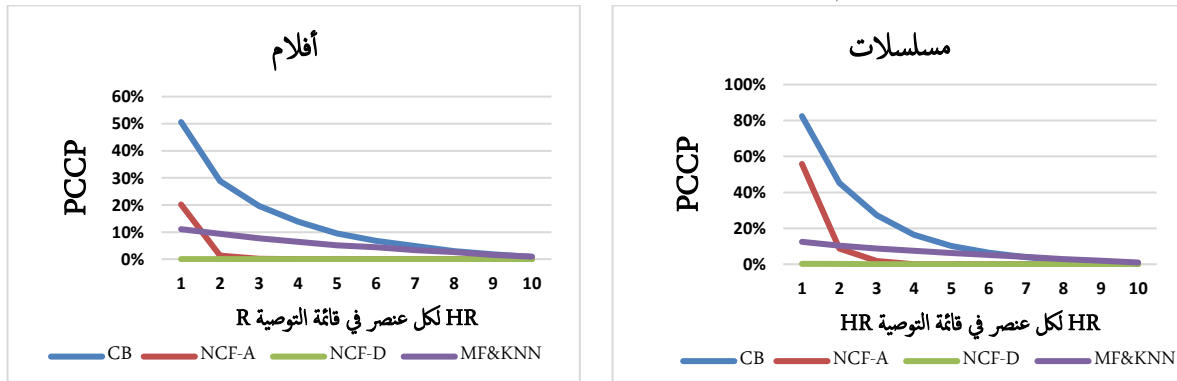
من أجل حساب كل من HR و NDCG، استخدمنا تقنية Leave-One-Out Cross-Validation (LOOCV) المستخدمة كثيراً في الأدبيات [79] [70] من أجل مقارنة الخوارزميات. لتحقيق تقنية LOOCV، استبعدنا آخر عنصر تمت مشاهدته لكل مستخدم وتحققنا فيما إذا كان مدرجاً ضمن قائمة العشرة الأوائل المتوقعة كما في المعادلة (19). نسمي هذا المقياس نسبة الوصول (HR). قمنا أيضاً بحساب موقع العنصر في القائمة المتوقعة وذلك يدعى (NDCG) كما في المعادلة (18). أما بالنسبة للعناصر المتبقية في قائمة مشاهدات المستخدم، تم استخدامها كمجموعة تدريب. يوضح الجدول (17) قيم (HR & NDCG) لطرق التوصية الأربعة. في طريقة NCF-D، سنرمز إلى آخر عنصر تمت مشاهدته فوق الحد الأدنى الذي حددناه مسبقاً "1" و "0" بخلاف ذلك.

الجدول 17: نتائج مقياسي التقييم الأول والثاني على مجموعتي معطيات البحث

| مسلسلات      |              | أفلام        |              | الخوارزمية المطبقة |
|--------------|--------------|--------------|--------------|--------------------|
| NDCG         | HR           | NDCG         | HR           |                    |
| 0.17         | 0.29         | 0.21         | 0.36         | CB                 |
| 0.06         | 0.12         | 0.12         | 0.25         | MF&KNN             |
| 0.51         | 0.80         | 0.66         | 0.85         | NCF-A              |
| (0.22, 0.13) | (0.60, 0.30) | (0.44, 0.24) | (0.66, 0.44) | NCF-D (1,0)        |

#### Mean- PCCP 2-7-4

يمثل Mean - PCCP النسبة المئوية للتوصيات، التي تحتوي على الأقل على عدد معين من الاقتراحات الناجحة. يشبه هذا المقياس عموماً مقياس HR السابق، ولكن بدلاً من استبعاد آخر عنصر واختباره، قمنا بالاختبار هنا على جميع معطيات الاختبار [76] المذكورة في الجدول 12. يمثل الشكل 11 عدد التوصيات الناجحة PCCP لكل خوارزمية في مجموعتي المعطيات وذلك من أجل كل عنصر في قائمة التوصية  $l_s$ ، اعتمدنا في هذه الأطروحة  $l_s = 10$ ، ثم أخذنا المتوسط Mean- PCCP لكل عناصر القائمة  $l_s$  كما في الجدول 18.



الشكل 11: عدد التوصيات الناجحة لكل خوارزمية في مجموعتي المعطيات

الجدول 18: نتائج مقياس التقييم الثالث على مجموعتي معطيات البحث

| Mean- PCCP |       | الخوارزمية المطبقة |
|------------|-------|--------------------|
| مسلسلات    | أفلام |                    |
| 19.50      | 13.96 | CB                 |
| 6.63       | 2.17  | NCF-A              |
| 6.01       | 5.24  | MF&KNN             |
| 0.05       | 0.003 | NCF-D              |

#### Diversity 3-7-4

استهدفت معظم الأبحاث بشكل أساسي تعزيز كفاءة أنظمة التوصية وتطوير تنوع قائمة التوصيات نسبيًا. لذلك، قمنا بتقييم تنوع العناصر في قائمة التوصيات بحيث اعتمدنا تعريف تنوع قائمة الاقتراحات  $f_D(l_s)$  في البحث [72] كما في المعادلة (30) على أنه اجالي متوسط الفرق لجميع أزواج العناصر  $v_z$  في قائمة التوصيات  $l_s$ ، علماً أن  $p=|l_s|$  و  $d(v_j, v_q)$  يمثل الاختلاف بين العنصرين  $v_j, v_q$  كما في المعادلة (20). يمكننا ملاحظة نتائج هذا المقياس في الجدول 19.

$$f_D(l_s) = \frac{1}{p(p-1)} \sum_{j \in l_s} \sum_{q \in l_s, j \neq q} d(v_j, v_q) \quad (34)$$



الجدول 19: نتائج المقياس الرابع على مجموعتي معطيات البحث

| مسلسلات                         |                             | أفلام                           |                             | الخوارزمية المطبقة |
|---------------------------------|-----------------------------|---------------------------------|-----------------------------|--------------------|
| Diversity based on all features | Diversity based on Category | Diversity based on all features | Diversity based on Category |                    |
| 0.51                            | 0.22                        | 0.83                            | 0.51                        | CB                 |
| 0.88                            | 0.67                        | 0.90                            | 0.75                        | NCF-A              |
| 0.52                            | 0.23                        | 0.86                            | 0.59                        | MF&KNN             |
| 0.90                            | 0.69                        | 0.93                            | 0.78                        | NCF-D              |

#### Coverage 4-7-4

يقيس Coverage نسبة تغطية العناصر المقترحة  $L$  بالنسبة لجميع عناصر التدریب  $m$  كما في المعادلة (31). يوضح الشكل 12 قيم هذا المقياس من أجل الخوارزميات الأربعة.

$$Coverage = \frac{L}{m} \quad (35)$$

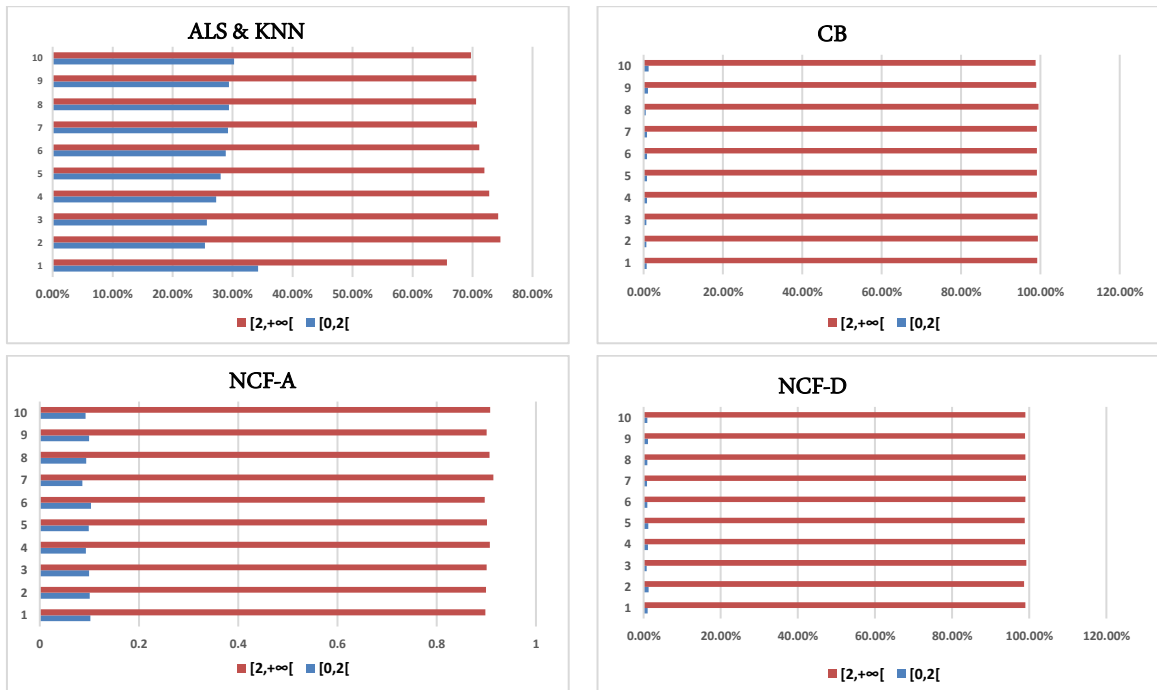


الشكل 12: نتائج المقياس الخامس على مجموعتي معطيات البحث

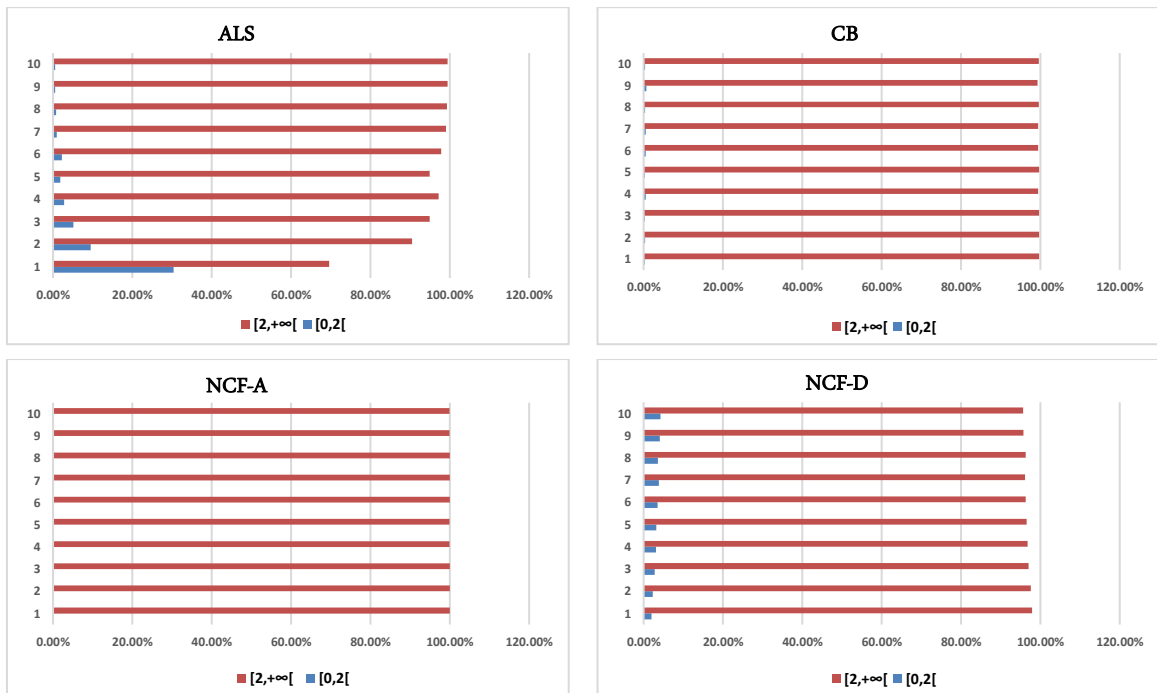
#### Novelty 5-7-4

يشير هذه المقياس إلى الابتكار أو الجودة في قائمة التوصية. نعتبر العنصر جديدًا إذا كان من الصعب العثور عليه في مجموعة معطيات معينة. تعتمد درجة الصعوبة في اكتشاف عنصر جديد على التصنيفات أو المشاهدات التي يتلقاها العنصر [73]. في بحثنا، سنستخدم لحساب الجودة على عدد المرات التي تمت فيها مشاهدة عنصر ما. عندما يكون عدد مرات مشاهدة العنصر المقترح ضمن المجموعة  $\{0, 1\}$  (أي تمت مشاهدة العنصر مرة واحدة أو لم تتم مشاهدته مطلقًا)، فهو عنصر جديد. يمثل الشكل 13 النسبة المئوية لعدد المستخدمين وفقًا لعدد مرات

المشاهدة وذلك من أجل كل عنصر ضمن قائمة الاقتراحات العشرة من أجل مجموعة معطيات المسلسلات، والشكل 14 من أجل مجموعة معطيات الأفلام.



الشكل 13: نتائج المقياس السادس على مجموعة معطيات المسلسلات



الشكل 14: نتائج المقياس السادس على مجموعة معطيات الأفلام

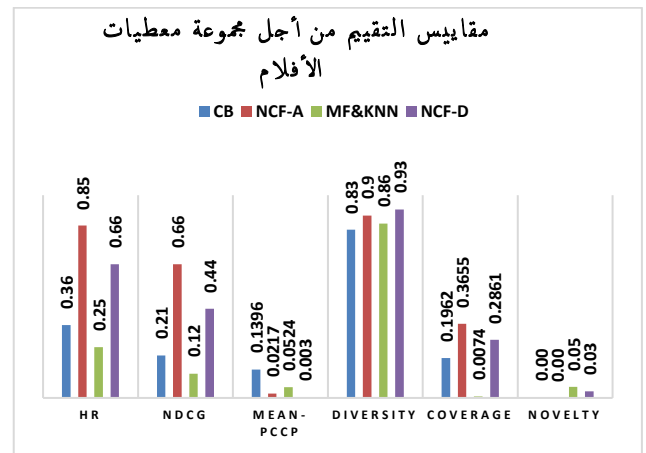

قمنا بحساب متوسط Novelty (Mean – Novelty) لكل خوارزمية مطبقة على مجموعتي المعطيات المستخدمة كما في الجدول 20.

الجدول 20: نتائج المقياس السادس على مجموعتي المعطيات المستخدمة

| Mean - Novelty |       | الخوارزمية المطبقة |
|----------------|-------|--------------------|
| مسلسلات        | أفلام |                    |
| 0.85%          | 0.42% | CB                 |
| 9.68%          | 0.03% | NCF-A              |
| 28.78%         | 5.46% | MF&KNN             |
| 1.03%          | 3.27% | NCF-D              |

## 8-4 تحليل النتائج

من أجل تحليل النتائج، قمنا بترتيب جودة الخوارزميات المطبقة وفق مقياس التقييم الستة على مجموعتي المعطيات المستخدمة. ووفقاً لحالة الاستخدام نختار الخوارزمية ذي الترتيب الأعلى. الشكل 15 يوضح قيم مقياس التقييم الستة في المجال [0,1] من أجل كل نموذج مطبق على مجموعتي المعطيات المدروسة. في الجدول 21، 22 قمنا بترتيب الخوارزميات المطبقة بالنسبة لمقاييس التقييم المدروسة من أجل مجموعة معطيات المسلسلات ثم الأفلام على التوالي.



الشكل 15: مقاييس التقييم الستة على مجموعتي المعطيات المستخدمة

الجدول 21: نتائج مقارنة مقاييس التقييم المطبقة على مجموعة بيانات المسلسلات

| HR & NDCG | Mean- PCCP | Coverage | Mean - Novelty | Diversity | ترتيب الخوارزميات |
|-----------|------------|----------|----------------|-----------|-------------------|
| NCF-A     | CB         | MF&KNN   | MF&KNN         | NCF-D     | أفضل              |
| NCF-D     | NCF-A      | NCF-D    | NCF-D          | NCF-A     | فوق الوسط         |
| CB        | MF&KNN     | NCF-A    | NCF-A          | MF&KNN    | وسط               |
| MF&KNN    | NCF-D      | CB       | CB             | CB        | أقل               |

الجدول 22: نتائج مقارنة مقاييس التقييم المطبقة على مجموعة معطيات الأفلام

| HR & NDCG | Mean- PCCP | Coverage | Mean of novelty | Diversity | ترتيب الخوارزميات |
|-----------|------------|----------|-----------------|-----------|-------------------|
| NCF-A     | CB         | NCF-A    | MF&KNN          | NCF-D     | أفضل              |
| NCF-D     | MF&KNN     | NCF-D    | NCF-D           | NCF-A     | فوق الوسط         |
| CB        | NCF-A      | CB       | CB              | MF&KNN    | وسط               |
| MF&KNN    | NCF-D      | MF&KNN   | NCF-A           | CB        | أقل               |

## الفصل الخامس: الخاتمة والآفاق المستقبلية

## 1-5 الخاتمة

مع استمرار نمو مواقع وتطبيقات الويب على الإنترنت، تصبح أنظمة التوصية مصادر قيمة بالنسبة للمستخدمين الذين يحاولون الحصول على ما يهتمون به من كمية المعلومات الهائلة المتاحة لهم. تهدف أنظمة التوصية بالعموم للتخفيف من مشكلة الحمل الزائد للمعلومات وتزويد المستخدمين باقتراحات وتوصيات بالعناصر بحيث تكون ذات طابع شخصي ومفيدة لهم، هذه الاقتراحات يمكن أن تساعد المستخدمين على اتخاذ قرارات أفضل عند اختيار المنتجات أو الخدمات التي من المحتمل أن تكون من اهتماماتهم أو ذات صلة باحتياجاتهم.

في هذه الأطروحة قمنا بتطبيق عدة نماذج توصية لمجموعتي معطيات تخص الأفلام والمسلسلات استناداً إلى طرق التوصية الأساسية، طرق التوصية المعتمدة على المحتوى، التصنيفية التعاونية والطريقة الهجينة، وذلك بالاعتماد على سجل مشاهدات المستخدمين دون وجود ميزة التقييم. قمنا بعكس اهتمام المستخدمين بالخدمات الموجودة بطرق عدة، إما بشكل مباشر كالنقر على الخدمة، أو بشكل غير مباشر كقياس مدة المشاهدة.

تطرقنا بعد ذلك إلى عدة مقاييس لاختبار جودة النماذج المطبقة. اخترنا مقاييس التقييم المتعلقة بتنوع الخدمات، شعبيتها، دقتها وجدتها، للمساعدة في اختيار إما أفضل نموذج أو طريقة الدمج المناسبة لحالة التطبيق.

لقد تطرقنا إلى عدد من الطرق لتقييم أداء أنظمة التوصية. بدأنا بمناقشة الأساليب القائمة على الدقة مثل HR و Mean- PCCP، ناقشنا أيضاً طريقة لتقييم كيفية قيام نموذجنا بترتيب العناصر باستخدام مناهج التصنيف مثل NDCG. بصرف النظر عن الأساليب الرياضية، تطرقنا أيضاً إلى طرق أخرى مثل التغطية والجدة والتنوع. أخيراً، قمنا بمقارنة النماذج المقترحة وتركنا لصاحب القرار اختيار الخوارزمية الأفضل له مع الأخذ في الاعتبار هدف العمل الذي يقوم بإنشاء النموذج من أجله. ولذلك بغض النظر عن الطريقة التي نستخدمها، علينا دائماً أن نبدأ بفهم عميق للمجال والمشكلة التي نحلها، لأن التقييم المفيد يعتمد دائماً على طرح السؤال الصحيح.

## 2-5 الآفاق المستقبلية

قمنا بمقارنة أداء النماذج المطبقة عن طريق تجريب منهجيات تقييم دون الاتصال بالإنترنت. لذلك، هدفنا إنتاج بيئة تجريبية جديدة تؤمن لنا إعادة اختبار النماذج المطبقة باستخدام منهجيات الاتصال بالإنترنت من أجل إعادة تحليل النتائج في الدراسات المستقبلية، والتركيز على هدف محدد من أهداف أنظمة التوصية لاختيار نموذج التوصية الأفضل أو النماذج التي من المفيد دمجها.

الملاحق

6-1: الملحق أ: المقالة الأولى

**Lama Mohsen Mansour<sup>1</sup>**

**Yasser Rahal, Mustapha Dakkak**

*Higher Institute for Applied Sciences and Technology, Damascus, Syria*

---

## Abstract

IPTV delivers television content over Internet Protocol (IP) networks. Videos On Demand (VOD) is the most popular IPTV, allowing users to freely select from a vast pool of program genres. Therefore, it is necessary to introduce innovative features to attract new users and retain existing ones. For this purpose, IPTV systems typically use VOD recommendation engines. The primary purpose of recommendation systems is to suggest user-relevant items from various items by producing a list of recommendations for each user. In this paper, we introduce an approach to recommendation systems in IPTV. We developed this approach on implicit feedback derived from users' interaction with movies/series sets, such as how many times they watched a movie and how long they have spent watching specific movies/series. For the previous factors, we tested a variety of recommendation algorithms, content-based, collaborative-based, and hybrid. Then applied the previously mentioned algorithms on real-life big data sets after introducing some modifications to the algorithms, then benchmarked the results on multiple performance metrics. We noticed that the applied changes achieved promising results.

*Keywords: Recommendation system (RS), implicit data, Big Data, Performance Metrics, Videos On Demand (VOD), Internet Protocol Television (IPTV).*

---

## 1. Introduction

Nowadays, IPTV offers an extensive range of movies content. On the one hand, the more channels we have, the higher the chance of each viewer finding movies or series of their preference; on the other hand, it poses severe challenges in navigating through the program grid [1]. A common approach to building such a user preference model is either explicitly or implicitly eliciting user feedback. Explicit feedback, such as rating scales, provides a direct mechanism for users to express their interests in items. The RS itself generates implicit feedback using the interpretation it makes about the user's behavior. What constitutes implicit feedback depends on the application domain. Usually, it will be one or multiple observable and measurable parameters that arise from the user's interactions with the RS [2]. There are majorly three categories of RSs: Content-based, Collaborative, and Hybrid approaches, a content-based RS analyses the user's past behavior and keeps track of patterns to predict and suggest items that match these patterns [3]. Suggestions are calculated based on characteristics of the item, such as category, actor, etc. Collaborative filtering suggests items based on the preferences of users with similar tastes and interests using correlation-based similarity [4] or generative model [5], clustering [6], Matrix factorization [7] [8], and deep learning [9] [10]. Both content-based and collaborative-based filtering have their drawbacks. To avoid this. Researchers suggested a hybrid approach to combine two or more recommendation strategies in different ways to benefit from their complementary advantages [2]. This paper presents various recommendation methods and compares them based on distinct metrics to highlight multiple options according to the application need. Moreover, it is imperative to offer innovative features to attract new users and retain existing ones. In practice, a good recommendation engine does not offer popular and well-known titles. Still, it can instead identify compelling titles among less popular items that would otherwise be hard to find [11] [12]. Furthermore, to evaluate the recommendation model, it is essential to know how many items are suggested [13].

Corresponding authors

Email address: lama.mansour@hiast.edu.sy (Lama Mansour).

## 2. Related Work

Two different directions of RSs have evolved, content-based filtering and collaborative filtering. Content-based RSs typically use movie features and users' viewing profiles to recommend items similar to the items the user has interacted with before. Researchers in [14] introduced a method to deal with implicit feedback and build a content-based movie RS that can use different feature sets: name, actor, director, category, and writer features. They established a feature set based on the particular user's past behavior and assigned a weight for each feature. They also produce a user's implicit rating for a movie based on the movie's duration that the user viewed. Furthermore, to predict a movie rating, they merge the user-specific weights of the movie's features using a particular feature set. We follow the previous approach with a few modifications in the rating prediction method to make it more logical. We reevaluate the results with different evaluation methods, thoroughly discussed in the next section. We typically obtained collaborative filtering predictions about user interests by grouping users with similar tastes [15]. We use collaborative filtering methods such as the nearest neighbor (NNH) algorithm combined with the Pearson correlation or cosine similarity to calculate the predicted values. In terms of sparse rating, the NNH approach usually experiences difficulties in finding the right match. In addition, the algorithm complexity tends to increase with the number of users and the number of items [15]. To overcome these difficulties, we adopted matrix factorization such as ALS, which projects users and items into a shared latent space using techniques such as Singular Value Decomposition (SVD), Non-negative Matrix Factorization (NMF), and others [16]. It represents a user or an item by a vector of latent features, and a user's interaction with an item is modeled as the inner product of their latent vectors [17]. These techniques (collaborative-Based and Content-Based) have their setbacks, such as the cold-start problems in collaborative filtering and content-based filtering. We can try many hybrid techniques used in RSs to increase recommendation accuracy and reduce errors to deal with these setbacks. The most used algorithm is the NNH combined with the matrix factorization [15]. Therefore, we depended on the combination between ALS and NNH using the rating built-in [14] and designed the parallel implementation process of the recommendation algorithm based on the Spark platform [18]. However, the attention is increasingly shifting towards implicit data and creating a model that can predict the score of unobservable items from the (user, item) interaction matrix, which can be filled with 1 if the user  $u$  interaction with the item  $i$  is observed and 0 otherwise. We followed the approach used in [17] in which the researchers found that the Neural Collaborative Filtering (NCF) framework offers better recommendation performance than Matrix factorization. However, we found another perspective if the objective of the RS is to recommend unexpected items [11]. We know that an excellent recommender system makes both relevant and valuable recommendations; many papers focus on understanding the performance of RSs. In [19], the researchers compared standard recommendation algorithms using Root Mean Square Error (RMSE), Normalized Discounted Cumulative Gain (NDCG), and item coverage. In [20], the researchers assessed evaluation metrics such as recall, F-measure, accuracy, novelty, and Global satisfaction on various recommendation methods. Our research differs from previous works in that it involves six evaluation methods applied to four different recommendation algorithms.

## 3. Experiments

### 3.1. Dataset

We experimented with a real dataset extracted from the IPTV application called ISHOW that contains multiple items, including movies and series. Our experiments used 11 months of log data, the first 10 months for the training, and the last month for the test phase. The characteristics of the dataset are summarized in Table 1 and Table 2.

**Table 1. Statistics of the training dataset**

| Dataset name | Interaction# | Item# | User# | Sparsity |
|--------------|--------------|-------|-------|----------|
| Movies       | 829314       | 12864 | 64376 | 99.89%   |
| Series       | 738365       | 1576  | 87549 | 99.46%   |

**Table 2. Statistics of the testing dataset**

| Dataset name | Interaction# | Item# | User# |
|--------------|--------------|-------|-------|
| Movies       | 108064       | 11795 | 8722  |
| Series       | 143987       | 1199  | 28125 |

In Fig. 1, we noted the number of users according to watched movies and series.




Fig. 1 The count of interactive users according to the count of watched series then movies.

### 3.2. Building Several Types of Recommender Systems

We experimented with various RS algorithms with some new modifications, and then we defined the evaluation protocol. Finally, we analyzed the results.

#### 3.2.1. Rating calculation based on content-based RS using feature sets called an acronym CB

We repeated the same approach in [5], where the researchers generated the rating by summarizing the feature weights of the contents from the user's perspective but based on questionnaires, we found that the category feature is the most important. So, we gave it more weight  $i \in \{1, 1.5, 2, 2.5\}$  as in Equation (1).

$$Rate(U, S) = \sum_{F=1}^{NF} W(U, F) + \left( \sum_{F=cat}^{CAT} i * W(U, F) \right) \quad (1)$$

Where, U indicates to the user, S indicates to item, cat indicates the category, NF is the feature set for each item, whose feature set  $\in \{\text{heroes, directors, writers, categories}\}$ , and  $W(U, F)$  indicates the weight of feature F in the feature set NF.

Table 3 shows the recommendation performance (recall, precision) for movies and series.

Table 3. The recommendation performance

| Weight | Movies    |        | Series    |        |
|--------|-----------|--------|-----------|--------|
|        | Precision | Recall | Precision | Recall |
| i=1    | 0.149     | 0.09   | 0.31      | 0.38   |
| i=1.5  | 0.156     | 0.24   | 0.33      | 0.91   |
| i=2    | 0.169     | 0.63   | 0.32      | 0.18   |
| i=2.5  | 0.161     | 0.37   | 0.29      | 0.09   |

We noticed that the recommendation performance is better when  $i=2$  for movies, but the series is better when

### **3.2.2. Combination of matrix factorization and classical collaborative filtering (nearest neighbor) called an acronym MF&KNN**

Matrix factorization is the most recent solution for sparse data problems, although it has become widely known since Netflix Prize Challenge [21]. Alternating Least Square (ALS) is a matrix factorization algorithm, and it runs itself in a parallel way. ALS is implemented in Apache Spark ML and built for a large-scale collaborative filtering problem. ALS is doing a pretty good job at solving the scalability and sparseness of the rating data, and it's simple and scales well to massive datasets.

We adopted the approach in [15]. So, we tried the ALS approach used in spark. mllib. Our workflow is following [2], [22]:

- i. We load extracted rating data from the previous method rating calculation based on content using feature sets.
- ii. To reduce the effect of outliers, we removed all users that have only a single or two actions. They will not help us learn any meaningful relationships, though, which is what we want.
- iii. Build the recommendation model using ALS that is built-in spark 2.3 on the training data <sup>1</sup>.
- iv. Generate top 10/50 movie recommendations for each user.
- v. For users who have only a single or two actions, we can instead run a KNN search over the product matrix to find movies/series most similar to those of users.

### **3.2.3. Neural Collaborative Filtering based on actions called an acronym NCF-A**

We applied the NCF method as mentioned in [17], we filled the (user, item) interaction matrix with 1 if the user  $u$ 's interaction with the item  $i$  is observed, and 0 otherwise, we initiated the training set for every item that the user watched, we added four negative items the user hasn't watched randomly, regarding testing set for every user we added 100 items, 99 one of them, the user has never watched it before, and one is the last item the user watched to measure hit ratio (HR), and normalized discounted cumulative gain (NDCG) metrics. Users who have watched only one item will be excluded from the training and testing set.

### **3.2.4. Neural Collaborative Filtering based on duration called an acronym NCF-D**

We added some modifications to the NCF method making use of the time that the user spent on an item as an indirect measure of his feedback based on a specific threshold (500 seconds for movies and 1000 seconds for series), we filled the (user, item) interaction matrix with 1 if the watched duration of the user  $u$  to the item  $i$  is more than it, and 0 otherwise. Fig. 2 represents the duration distribution based on the number of watched movies and series.

To deal with the negative feedback, we follow the following steps:

- For users with zero negative items, we added twice the count of positive items randomly.
- For users whose count of positive items less than twice the negative items count, we did the following strategy:
  - i. We used the CountVectorizer feature extraction method from the scikit-learn library to turn every item into a feature vector using the bag of words from (genre, writers, directors, actors), and we used the cosine similarity to measure the similarity between two items
  - ii. We added negative items with the count  $S = (2 \times \text{positive count items} - \text{negative count items})$  by taking the top  $S$  items most similar to the negative items in the training set.
  - iii. For the users whose items we didn't find similar ones, we added  $S$  items randomly.




Fig. 2 The duration distribution based on the number of watched movies then series

### 3.3. Evaluation Protocols

This section investigates our experiments using multiple evaluation dimensions, covering coverage, novelty, diversity, NDCG, HR, and percentage of correctly captured predictions.

#### 3.3.1. HR and NDCG

We adopted the leave-one-out procedure, which has been widely used in the studies [23] [24] [25]. We excluded the last watched item for each user and checked whether it's included in the predicted top 10 list. We call this the Hit Ratio (HR) metric. We also calculated the item's location in the predicted list as a normalized discounted cumulative gain (NDCG) metric [26]. As for the remaining items in the watched list, we use them as a training set [10].

Table 4 shows (HR & NDCG) for the four-recommendation method. In the *NCF-D* method, we will symbolize the last watched item with 1 over the threshold and 0 otherwise.

Table 4. Evaluation metric results 1

| Recommendation method | Movies       |              | Series       |              |
|-----------------------|--------------|--------------|--------------|--------------|
|                       | HR           | NDCG         | HR           | NDCG         |
| <i>CB</i>             | 0.36         | 0.21         | 0.29         | 0.17         |
| <i>MF&amp;KNN</i>     | 0.25         | 0.12         | 0.12         | 0.06         |
| <i>NCF-A</i>          | 0.85         | 0.66         | 0.80         | 0.51         |
| <i>NCF-D (1,0)</i>    | (0.66, 0.44) | (0.44, 0.24) | (0.60, 0.30) | (0.22, 0.13) |

#### 3.3.2. Percentage of correctly captured predictions

It represents the percentage of the recommendations, which has at least a given number of successful recommendations. This metric is generally similar to the HR approach, the main difference is that we maintained all elements of training and after recommending each user's top 10 list, we calculated the percentage of the recommendations that appeared in the user's watched list [14].

Table 5 shows the mean of successful recommendations for each recommendation method called an acronym Mean- PCCP.

Fig. 3 represents the successful recommendations counts for each algorithm on the two datasets.

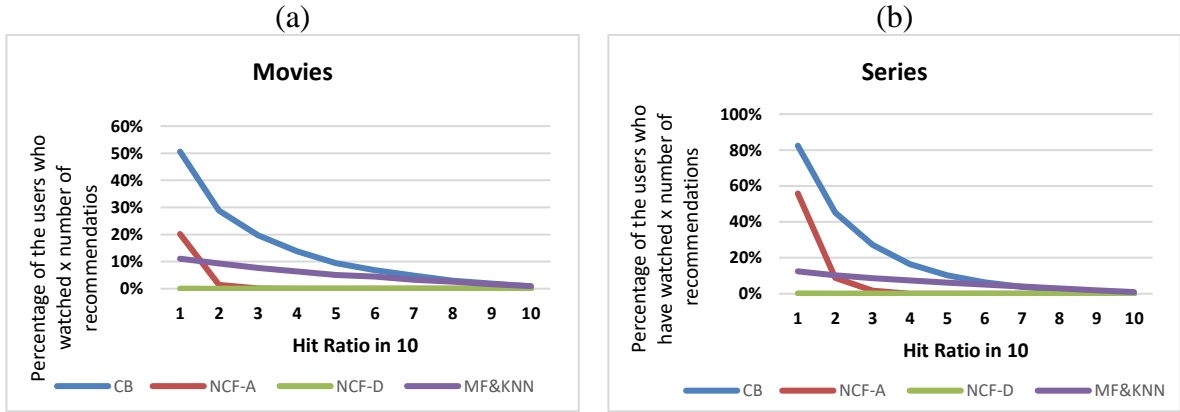


Fig. 3 Hit counts for each algorithm on the two datasets

Table 5. Evaluation metric results 2

| Recommendation method | Mean- PCCP |        |
|-----------------------|------------|--------|
|                       | Movies     | Series |
| CB                    | 13.96      | 19.50  |
| NCF-A                 | 2.17       | 6.63   |
| MF&KNN                | 5.24       | 6.01   |
| NCF-D                 | 0.003      | 0.05   |

### 3.3.3. Diversity measures

Most researches aimed mainly on enhancing the efficiency of recommender systems and relatively on developing the utility of the recommendation list. Therefore, we assessed the diversity of items on the recommendation list.

We adopted the definition of set diversity [11] to model diversity as the aggregate, or, identically, an average difference of all pairs of items in the set. Specifically, given a distance function,  $d: I \times I \rightarrow \mathbb{R}$ , such that  $d(i, j)$  is the distance or difference between elements  $i, j \in I$ , the diversity  $f_D(R)$  is the average dissimilarity of all pairs of elements contained in  $R$  as in Equation (2).

$$f_D(R) = \frac{1}{p(p-1)} \sum_{i \in R} \sum_{j \in R, j \neq i} d(i, j) \quad (2)$$

Where  $p=|R|$ . Here we assume that this distance function is symmetric ( $d(i, j) = d(j, i)$ ).

Table 6 shows the diversity value based on category, then all features for the four recommendation methods.


**Table 6. Evaluation metric results 3**

| Recommendation method | Movies                           |                                 | Series                           |                                 |
|-----------------------|----------------------------------|---------------------------------|----------------------------------|---------------------------------|
|                       | Diversity based on Category only | Diversity based on all features | Diversity based on Category only | Diversity based on all features |
| <i>CB</i>             | 0.51                             | 0.83                            | 0.22                             | 0.51                            |
| <i>NCF-A</i>          | 0.75                             | 0.90                            | 0.67                             | 0.88                            |
| <i>MF&amp;KNN</i>     | 0.59                             | 0.86                            | 0.23                             | 0.52                            |
| <i>NCF-D</i>          | 0.78                             | 0.93                            | 0.69                             | 0.90                            |

### 3.3.4. Coverage

Item coverage measures the proportion of items a recommender system can recommend from the entire item space [27].

Fig. 4 shows item coverage of recommendation lists produced by different recommender systems for series then movies.



**Fig. 4** Item coverage of recommendation lists produced by different recommender systems for series then movies.

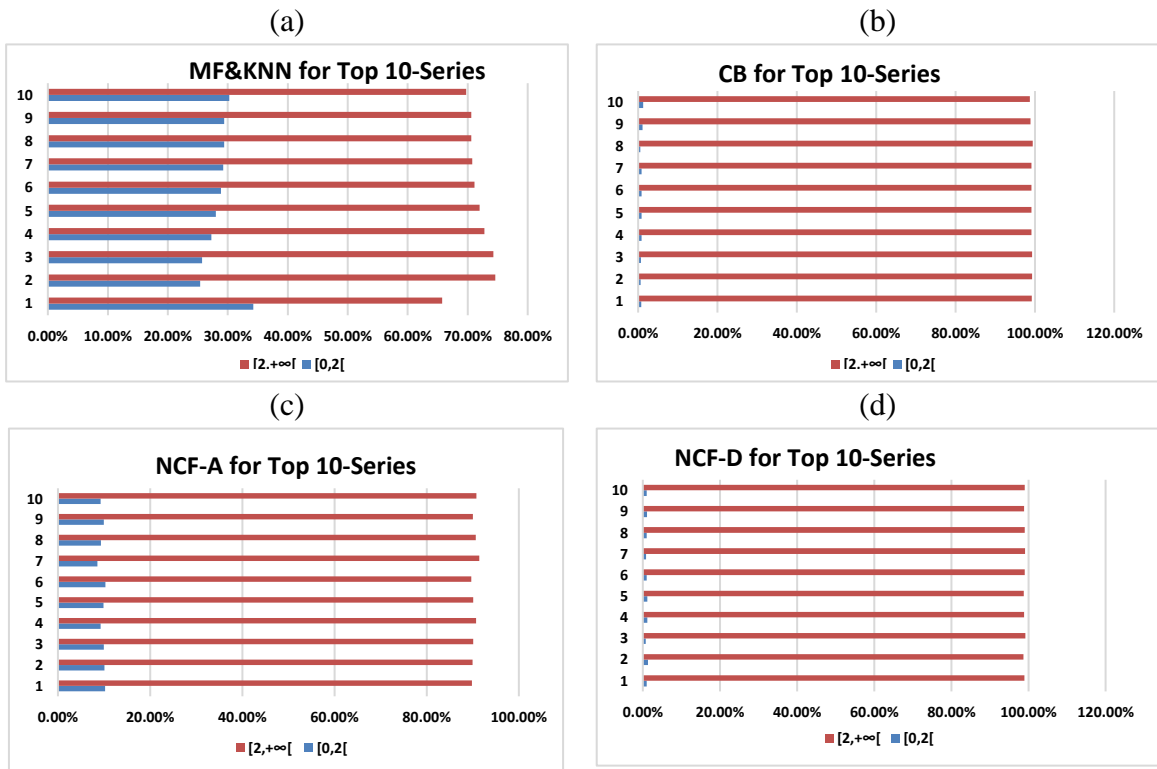
### 3.3.5. Novelty

An item will be considered novel if it is difficult to find in a given dataset. The degree of difficulty in discovering a new item will depend on the ratings that an item receives [28]. In our case, we will rely on the number of times that an item has been watched. Wherever the viewership of recommended items is less (the item is watched once or never watched  $\{0, 1\}$ ), it is better to be recommended.

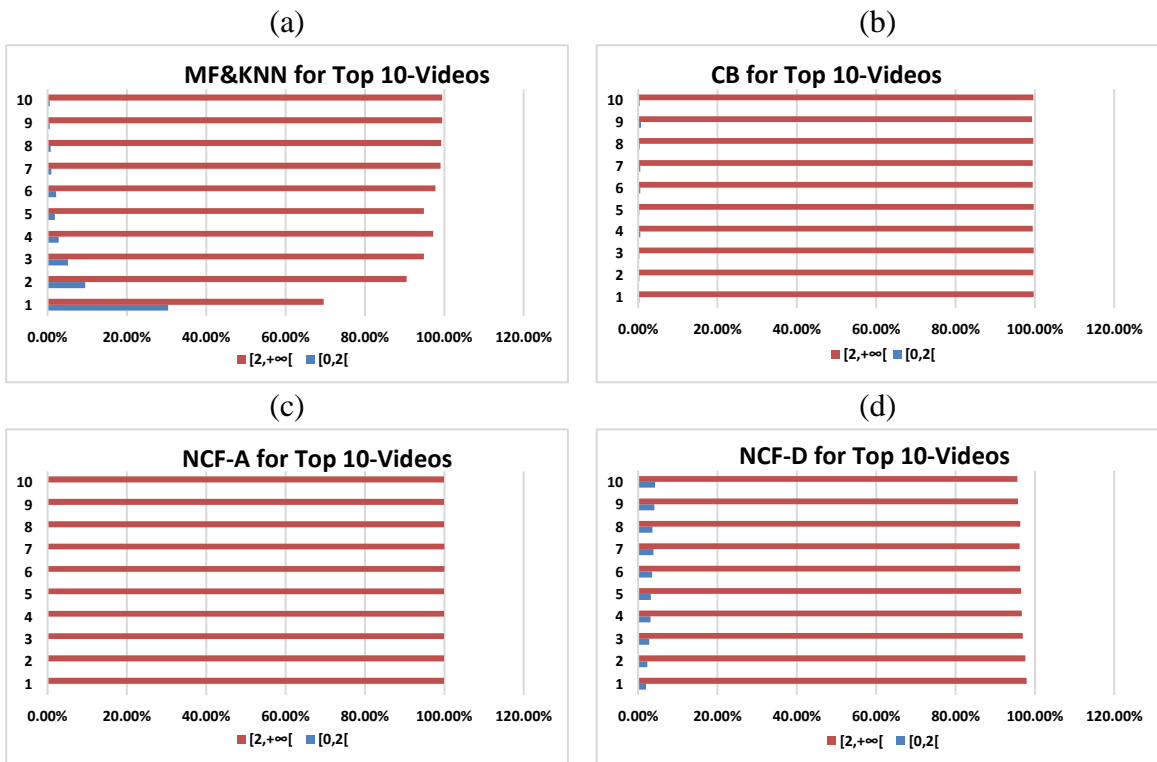
Fig. 5 represents the percentage of recommended items viewership by total users for each recommended item in the top 10 for the series.

Fig. 6 represents the percentage of recommended items viewership by total users for each recommended item in the top 10 for movies.

In table 14 shows, the novelty metric as mean for series and movies based on applied recommendation methods.



**Fig. 5** The percentage of recommended items viewership ( $[0, 2[$ ,  $[2, +\infty [$ ) by total users for each recommended item in the top 10 for series by each recommendation method.



**Fig. 6** represents the percentage of recommended items viewership ( $[0, 2[$ ,  $[2, \infty [$ ) by total users for each recommended item in the top 10 for movies by each recommendation method.

**Table 7. Evaluation metric results 4**

| Recommendation method | Mean of novelty |        |
|-----------------------|-----------------|--------|
|                       | Movies          | Series |
| <i>CB</i>             | 0.42%           | 0.85%  |
| <i>NCF-A</i>          | 0.03%           | 9.68%  |
| <i>MF&amp;KNN</i>     | 5.46%           | 28.78% |
| <i>NCF-D</i>          | 3.27%           | 1.03%  |

**3.4. Results analysis**

Although no algorithm is significantly better (or worse) than all the other in terms of quality dimensions, we can at least identify a partial order [20], as outlined in Table 8, Table 9 for series then movies.

**Table 8. Partial Ordering of RSs for the various evaluation methods on series**

|                    | HR<br>NDCG        | & Mean-<br>PCCP   | Coverage          | Mean<br>of novelty | Diversity         |
|--------------------|-------------------|-------------------|-------------------|--------------------|-------------------|
| Maxima             | <i>NCF-A</i>      | <i>CB</i>         | <i>MF&amp;KNN</i> | <i>MF&amp;KNN</i>  | <i>NCF-D</i>      |
| Upper-Intermediate | <i>NCF-D</i>      | <i>NCF-A</i>      | <i>NCF-D</i>      | <i>NCF-D</i>       | <i>NCF-A</i>      |
| Intermediate       | <i>CB</i>         | <i>MF&amp;KNN</i> | <i>NCF-A</i>      | <i>NCF-A</i>       | <i>MF&amp;KNN</i> |
| Minimal            | <i>MF&amp;KNN</i> | <i>NCF-D</i>      | <i>CB</i>         | <i>CB</i>          | <i>CB</i>         |

**Table 9. Partial Ordering of RSs for the various evaluation methods on movies**

|                    | HR<br>NDCG        | & Mean-<br>PCCP   | Coverage          | Mean<br>of novelty | Diversity         |
|--------------------|-------------------|-------------------|-------------------|--------------------|-------------------|
| Maximal            | <i>NCF-A</i>      | <i>CB</i>         | <i>NCF-A</i>      | <i>MF&amp;KNN</i>  | <i>NCF-D</i>      |
| Upper-Intermediate | <i>NCF-D</i>      | <i>MF&amp;KNN</i> | <i>NCF-D</i>      | <i>NCF-D</i>       | <i>NCF-A</i>      |
| Intermediate       | <i>CB</i>         | <i>NCF-A</i>      | <i>CB</i>         | <i>CB</i>          | <i>MF&amp;KNN</i> |
| Minimal            | <i>MF&amp;KNN</i> | <i>NCF-D</i>      | <i>MF&amp;KNN</i> | <i>NCF-A</i>       | <i>CB</i>         |

According to this ordering, *NCF-A* is the most optimal algorithm in terms of relevance (i.e., the algorithm with the best-perceived relevance) for two datasets. On the contrary, *MF&KNN* is the least optimal algorithm for them.

The second column of the table shows the partial ordering according to Mean-PCCP. *CB* is the algorithm that mostly matched users' interests in general for the two datasets, while *MF&KNN* showed fewer matches to users' interests in them.

The third column of the table shows the partial ordering according to the coverage. MF&KNN is the most optimal algorithm for the series. However, the most optimal algorithm for movies is NCF-A, whereas the least optimal algorithm for series and movies are CB and MF&KNN, respectively.

The fourth column of the table shows the partial ordering according to the novelty. MF&KNN is the most optimal algorithm for two datasets, while the least optimal algorithm for series and movies are CB and NCF-A, respectively.

The last column of the table shows the partial ordering according to the diversity. NCF-D is the maximal algorithm for the two datasets, while CB is the minimal algorithm.

## Conclusion

In general, we choose the recommendation method according to the application context. This paper experimented with four different types of RS methods to highlight the best use-cases for each method. Furthermore, we presented their differences based on multiple factors, adopting an offline evaluation approach. Therefore, we suggest using an online evaluation approach to test the RSs we previously mentioned and re-analyze the results in future studies.

## Acknowledgments

Syriatel telecom Co-sponsored this research. We thank our colleagues Mr. Murid (Syriatel CEO), Mr. Ayman (Syriatel CTO), Mr. Adham (Research & Development Manager), who provided insight that aided the research. In addition, we thank Wessam Abo Zayed for his great ideas in the data processing.

## References

- [1] E. Bonilla, M. Stier, S. Niccolini, and M. Brunner, "Automated Real-Time Recommendations for IPTV," Nov. 2009, pp. 1–6. doi: 10.1109/icc.2009.5305951.
- [2] G. Jawaheer, M. Szomszor, and P. Kostkova, "Comparison of Implicit and Explicit Feedback from an Online Music Recommendation Service," in *Proceedings of the 1st International Workshop on Information Heterogeneity and Fusion in Recommender Systems*, 2010, pp. 47–51. doi: 10.1145/1869446.1869453.
- [3] Peter. Brusilovsky, Association for Computing Machinery., and S. ACM Conference on Recommender Systems (4th: 2010: Barcelona, *Content-based movie recommendation system using genre correlation*. In *Smart Intelligent Computing and Applications*. Association for Computing Machinery, 2010.
- [4] R. H. Singh, S. Maurya, T. Tripathi, T. Narula, and G. Srivastav, "Movie Recommendation System using Cosine Similarity and KNN," *International Journal of Engineering and Advanced Technology (IJEAT)*, no. 9, pp. 2249–8958, 2020, doi: 10.35940/ijeat.E9666.069520.
- [5] S. Biswas, L. V. S. Lakshmanan, and S. B. Roy, "Combating the Cold Start User Problem in Model Based Collaborative Filtering," *ArXiv*, vol. abs/1703.00397, 2017.
- [6] N. F. AL-Bakri and S. H. Hashim, "Collaborative Filtering Recommendation Model Based on k-means Clustering," *Al-Nahrain Journal of Science*, vol. 22, no. 1, pp. 74–79, Mar. 2019, doi: 10.22401/ANJS.22.1.10.
- [7] Y. He, C. Wang, and C. Jiang, "Correlated Matrix Factorization for Recommendation with Implicit Feedback," *IEEE Transactions on Knowledge and Data Engineering*, vol. 31, no. 3, pp. 451–464, Mar. 2019, doi: 10.1109/TKDE.2018.2840993.
- [8] M. Patil, S. Brid, and S. Dhebar, "COMPARISON OF DIFFERENT MUSIC RECOMMENDATION SYSTEM ALGORITHMS".
- [9] M. Fu, H. Qu, Z. Yi, L. Lu, and Y. Liu, "A Novel Deep Learning-Based Collaborative Filtering Model for Recommendation System," *IEEE Transactions on Cybernetics*, vol. 49, no. 3, pp. 1084–1096, 2019, doi: 10.1109/TCYB.2018.2795041.

- [10] S. Rendle, W. Krichene, L. Zhang, and J. Anderson, “Neural Collaborative Filtering vs. Matrix Factorization Revisited,” in *RecSys 2020 - 14th ACM Conference on Recommender Systems*, Sep. 2020, pp. 240–248. doi: 10.1145/3383313.3412488.
- [11] N. Hurley and M. Zhang, “Novelty and Diversity in top-N recommendation-Analysis and evaluation,” *ACM Transactions on Internet Technology*, vol. 10, no. 4, Mar. 2011, doi: 10.1145/1944339.1944341.
- [12] K. Pripužić *et al.*, “Building an IPTV VoD recommender system: An experience report DL-Tags: DLT and Smart Tags for decentralized, privacy-preserving and verifiable supply chain management View project Building an IPTV VoD Recommender System: An Experience Report,” 2013. [Online]. Available: <https://www.researchgate.net/publication/256437748>
- [13] X. Yin *et al.*, “Time Context-Aware IPTV Program Recommendation Based on Tensor Learning,” in *2018 IEEE Global Communications Conference (GLOBECOM)*, 2018, pp. 1–6. doi: 10.1109/GLOCOM.2018.8647211.
- [14] M. Uluyagmur, Z. Cataltepe, and E. Tayfur, “Content-based movie recommendation using different feature sets,” in *Proceedings of the world congress on engineering and computer science*, 2012, vol. 1, pp. 17–24.
- [15] M. Ilhami and Suharjito, “Film recommendation systems using matrix factorization and collaborative filtering,” in *2014 International Conference on Information Technology Systems and Innovation, ICITSI 2014 - Proceedings*, Feb. 2014, pp. 1–6. doi: 10.1109/ICITSI.2014.7048228.
- [16] Y. Koren, R. Bell, and C. Volinsky, “Matrix Factorization Techniques for Recommender Systems,” *Computer*, vol. 42, no. 8, pp. 30–37, 2009, doi: 10.1109/MC.2009.263.
- [17] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T. S. Chua, “Neural collaborative filtering,” in *26th International World Wide Web Conference, WWW 2017*, 2017, pp. 173–182. doi: 10.1145/3038912.3052569.
- [18] B. Kupisz and O. Unold, “Collaborative filtering recommendation algorithm based on Hadoop and Spark,” in *2015 IEEE International Conference on Industrial Technology (ICIT)*, 2015, pp. 1510–1514.
- [19] A. Said and A. Bellogín, “Comparative recommender system evaluation: Benchmarking recommendation frameworks,” in *RecSys 2014 - Proceedings of the 8th ACM Conference on Recommender Systems*, Oct. 2014, pp. 129–136. doi: 10.1145/2645710.2645746.
- [20] P. Cremonesi, F. Garzotto, S. Negro, A. V. Papadopoulos, and R. Turrin, “LNCS 6948 - Looking for ‘Good’ Recommendations: A Comparative Evaluation of Recommender Systems,” 2011.
- [21] Y. Koren, “The BellKor Solution to the Netflix Grand Prize,” 2009. [Online]. Available: [www.netflixprize.com/leaderboard](http://www.netflixprize.com/leaderboard)
- [22] S. Reddy, S. Nalluri, S. Kuniseti, S. Ashok, and B. Venkatesh, “Content-based movie recommendation system using genre correlation,” in *Smart Innovation, Systems and Technologies*, 2019, vol. 105, pp. 391–397. doi: 10.1007/978-981-13-1927-3\_42.
- [23] S. A. Stein, G. Weiss, Y. Chen, and D. D. Leeds, “A College Major Recommendation System,” *Fourteenth ACM Conference on Recommender Systems*, 2020.
- [24] G. Stamatelatos, G. Drosatos, S. Gyftopoulos, H. Briola, and P. S. Efraimidis, “Point-of-interest lists and their potential in recommendation systems,” *Information Technology and Tourism*, vol. 23, no. 2, pp. 209–239, Jun. 2021, doi: 10.1007/s40558-021-00195-5.
- [25] O. Jeunen, “Revisiting offline evaluation for implicit-feedback recommender systems,” in *RecSys 2019 - 13th ACM Conference on Recommender Systems*, Sep. 2019, pp. 596–600. doi: 10.1145/3298689.3347069.

- [26] H. Xiao, Y. Chen, and X. Shi, "Multi-Perspective Neural Architecture for Recommendation System," Jul. 2018, [Online]. Available: <http://arxiv.org/abs/1807.09751>
- [27] Y. Chung, N. R. Kim, C. Y. Park, and J. H. Lee, "Improved neighborhood search for collaborative filtering," *International Journal of Fuzzy Logic and Intelligent Systems*, vol. 18, no. 1, pp. 29–40, Mar. 2018, doi: 10.5391/IJFIS.2018.18.1.29.
- [28] M. Mendoza and N. Torres, "Evaluating content novelty in recommender systems," *Journal of Intelligent Information Systems*, vol. 54, no. 2, pp. 297–316, Apr. 2020, doi: 10.1007/s10844-019-00548-x.

2-6 الملحق ب: المعطيات المستخدمة

## أ- نتائج استخدام API خاصة لاستخراج ميزات المسلسلات

| Source Name               | Genre                         | Director          | Writer  | Actors  |
|---------------------------|-------------------------------|-------------------|---|---|
| ضبعة ضابطة الجزء الأول    | Family , Comedy , Adventure , | Laith Hijo        | Mamdouh Hamada  | Nedal Segri , Bassem Yakhour , Tolay Haroon           |
| لو                        | Drama , , ,                   | Samer El Barqawi  | bilal shhadat   | Abed Fahed , Nadin Naseb Njeim , Youssef El Khal      |
| ليس سرايا                 | Drama , Romance , ,           | AL-Mothanna Sobah | Fady Koshkashgy   | Abbas Al Nouri , Salloum Haddad , Karis Bashar        |
| أحلام كبيرة               | Drama , , ,                   | Hatem Ali         | Amal Hanna  | Samar Sami , Bassam Kousa , Norman Asaad              |
| في ال لا لالاند           | Comedy                        | Ahmed El Gendy    | Hisham Gamal  | Samir Ghanem , Donia Samir Ghanem , Hamdy Al-Merghany |
| الندم                     | Drama , , ,                   | Laith Hijo        | Hassan Samy Youssef   | Salloum Haddad , Samar Sami , Bassem Yakhour          |
| مسلسليكو                  | Comedy                        | Ahmed El Mehdi    | Ayman Bahgat Amar   | Mohamed Henidy , Mahmoud Yousuf , Diaa Abdulkhalig    |
| نيلى وشريهان              | Comedy                        | Ahmed El Gendy    | Karim Youssef   | Donia Samir Ghanem , Amy Samir Ghanem , Bayyumy Fouad |
| ولاد البلد                | Musical , Comedy , ,          | Ismail Farouk     | Sayed El Sobky  | Saad El Soghayar , Dina , Mohamed Lotfy               |
| The Walking Dead Season 5 | Drama, Horror, Thriller       | N/A               | Frank Darabont, Angela Kan Norman Reedus, Melissa McBride, Danaï Gurira, Lauren Cohan |   |
| The Walking Dead Season 6 | Drama, Horror, Thriller       | N/A               | Frank Darabont, Angela Kan Norman Reedus, Melissa McBride, Danaï Gurira, Lauren Cohan |   |
| The Walking Dead Season 7 | Drama, Horror, Thriller       | N/A               | Frank Darabont, Angela Kan Norman Reedus, Melissa McBride, Danaï Gurira, Lauren Cohan |   |
| The Walking Dead Season 8 | Drama, Horror, Thriller       | N/A               | Frank Darabont, Angela Kan Norman Reedus, Melissa McBride, Danaï Gurira, Lauren Cohan |   |
| الخيز الحرام              | Drama , , ,                   | Tamer Ishak       | Marwan Kawouk   | Abbas Al Nouri , Bassem Yakhour , Salma El Masry      |
| عشرة عبيد صغار            | Crime , Thriller , Mystery ,  | Elie F. Habib     | Agatha Christie   | Rita Harb , Takla Chamoun , Brigitte Yaghi            |
| الغان                     | Drama , , ,                   | Muhammed Maarouf  | Marwan Kawouk   | Fayez Kazak , Yahya Beyazi , Jamal El Ali             |
| حارة الطنابير             | Drama , Comedy , ,            | Fadi Salim        | Marwan Kawouk   | Salma El Masry , Nizar Abu Hajar , Ayman Reda         |
| خواتم                     | Romance , Drama , ,           | Nagi Teameh       | Nadia El Ahmar  | Abdel Moneim Amiry , Karis Bashar , Kinda Hanna       |
| طاحون الشر الجزء الأول    | Drama , , ,                   | Nagi Teameh       | Marwan Kawouk   | Bassam Kousa , Sabah Al-Jazayeri , Rafiq Subaie       |
| أحمد وكريستينا            | Drama , Romance , ,           | Samir El Habashy  | Claudia Marshallian   | Sabine , George Shahlouh , Youssef Haddad             |
| ما يتخلص حكاياتنا         | Drama . . .                   | Tamer Ishak       | Mowaffaq Masoud   | Ahmad AlAhmad . Nadine Tahsine Bek . Shadi Zeidan     |

## ب- نتائج استخدام API خاصة لاستخراج ميزات الأفلام

| ID    | Source Name                      | Genre                                       | Director                       | Writer                              | Actors   |
|-------|----------------------------------|---|--------------------------------|-------------------------------------|--|
| 3053  | إن ريك ليامرصاد                  | Crime , Drama , Thriller                    | Mohamed Hassib                 | Bashir El Deek                      | Mahmoud Yassine , Hussein Fahmy , Yoursa                   |
| 19023 | الوحد                            |   | Ali Abdelkhalq                 | Fathy Aboufadel                     | Nabila Obeid , Nour El Sherif , Kamal El Shennawy          |
| 20638 | Memphis Belle                    | Action, Drama, War                          | Michael Caton-Jones            | Monte Merrick                       | Matthew Modine, Eric Stoltz, Tate Donovan, D.B. Sweeney    |
| 26165 | What We Do in the Shadows        | Comedy, Horror                              | Jemaine Clement, Taika Waititi | Jemaine Clement, Taika Waititi      | Jemaine Clement, Taika Waititi, Jonny Brugh, Cori Gonzalez |
| 19709 | Full Metal Jacket                | Drama, War                                  | Stanley Kubrick                | Stanley Kubrick (screenplay by), Mi | Matthew Modine, Adam Baldwin, Vincent D'Onofrio, R. Lee    |
| 19961 | The Crazies                      | Horror, Thriller                            | Breck Eisner                   | Scott Kosar (screenplay), Ray Wri   | Timothy Olyphant, Radha Mitchell, Joe Anderson, Danielle   |
| 19732 | Pee-wee's Big Adventure          | Adventure, Comedy, Family                   | Tim Burton                     | Phil Hartman, Paul Reubens, Mich    | Paul Reubens, Elizabeth Daily, Mark Holton, Diane Salinger |
| 22904 | The Garden of Words              | Animation, Drama, Romance                   | Makoto Shinkai                 | Makoto Shinkai                      | Miyu Irino, Kana Hanazawa, Fumi Hirano, Gou Maeda          |
| 22244 | Cobain: Montage of Heck          | Drama                                       | Nanouk Leopold                 | Stienette Bosklopper                | Bas Keizer, Naomi Velissariou, Wim Opbrouck, Dana Marit    |
| 12333 | This Means War                   | Action, Comedy, Romance                     | McG                            | Timothy Dowling (screenplay), Sim   | Reese Witherspoon, Chris Pine, Tom Hardy, Til Schweiger    |
| 12026 | Empire State                     | Action, Crime, Thriller                     | Dito Montiel                   | Adam Mazer                          | Liam Hemsworth, Michael Angarano, Dwayne Johnson, Pa       |
| 21321 | The Thirteenth Floor             | Mystery, Sci-Fi, Thriller                   | Josef Rusnak                   | Daniel F. Galouye (book), Josef Rus | Craig Bierko, Armin Mueller-Stahl, Gretchen Mol, Vincent   |
| 13089 | Bridget Jones's Baby             | Comedy, Drama, Romance                      | Sharon Maguire                 | Helen Fielding (screenplay), Dan M  | Renée Zellweger, Gemma Jones, Jim Broadbent, Sally Phil    |
| 34277 | All Is Lost                      | Action, Adventure, Drama                    | J.C. Chandor                   | J.C. Chandor                        | Robert Redford   |
| 16196 | The Losers                       | Action, Adventure, Crime, Mystery, Thriller | Sylvain White                  | Peter Berg (screenplay), James Van  | Jeffrey Dean Morgan, Zoe Saldana, Chris Evans, Idris Elba  |
| 36043 | Dawn of the Dead                 | Action, Horror                              | Zack Snyder                    | George A. Romero, James Gunn (scr   | Sarah Polley, Ving Rhames, Jake Weber, Mekhi Phifer        |
| 21872 | العمر أيام                       | Musical , Drama , Drama                     | Youssef Issa                   | Youssef Issa                        | Shokry Sarhan , Maha Sabry , Zizi El Badrawi               |
| 23819 | الأمة الطروب                     | Drama ,                                     | Helmy Rafla                    | Aboul Seoud Al Ibiary               | Laila Fawzy , Kamal El Shennawy , Abdelsalam El Nabolsi    |
| 46417 | Ruth the Musical                 | Musical                                     | Jay Moussa-Mann                | Jay Moussa-Mann                     | David Aryn , Daniel Bakken , Michael Bakken , Zoe Birkbeck |
| 46015 | The Decline of Western Civilizat | Documentary, Music                          | Penelope Spheeris              | N/A                                 | Steven Tyler, Joe Perry, Alice Cooper, Gene Simmons        |

## ت- جداول البيانات التي اعتمدنا عليها في البحث

1. **SERVICES**: هذا الجدول يتضمن جميع الخدمات المقدمة في تطبيق ال ISHOW من مسلسلات، أفلام

ومسرحيات

| SERVICE_ID      | SERVICE_NAME               | SERVICE_DESCRIPTION   | SERVICE_TYPE | IS_MOVIE |
|-----------------|----------------------------|---|--------------|----------|
| 59e304bd0636995 | عربيات                     | مسلسل سوري كوميدي، يتألف من لوحات متعددة تحكي قصص مختلفة بطابع كوميدي.<br>بطولة: أيمن رضا، باسم ياخور، فارس الطلو، ناجي جبر، لورا أبو أسعد<br>إخراج: شادي علي   | vod          | 0.00     |
| 59e3068a1693563 | مسلسليكو                   | فوازير رمضانية بتقنية ثلاثي الأبعاد يمثل فيها 30 شخصية من أبطال المسلسلات العربية<br>و التركية<br>بطولة : محمد هنيدي ، مادلين مطر ، حسناء سيف الدين<br>تأليف: أيمن بهجت قمر<br>إخراج: احمد المهدي   | vod          | 2.00     |
| 59ce6e258df9282 | Syria TV                   | Syria TV also known as Syrian Satellite Channel is a satellite television channel .owned by RTV Syria and broadcast throughout the world on various satellites .The television station is based in Damascus, Syria since 1995<br>قناة سورية دراما محطة تلفزيونية مملوكة للحكومة ومقرها دمشق، سوريا منذ 1 كانون الثاني 2009، وهي قناة تعرض المسلسلات الدرامية السورية القديمة والجديدة | live         | 0.00     |
| 59ce6e649628313 | Syrian Drama - سوريا دراما | ,Syrian Drama TV is a government owned television station based in Damascus Syria since 1 January 2009. It is a channel that presents the Syrian drama series old and new one   | live         | 0.00     |
| 59956099b241628 | Action                     |   | vod          | 1.00     |

حيث:

ID: المعرف المخصص لهذا الجدول

SERVICE\_ID: يمثل المعرف المخصص لكل SERVICE (موجود ضمن جدول WTB\_SERVICE)

SERVICE\_NAME: تتضمن اسم الخدمة (اذا كانت مسلسلات) بينما تتضمن النوع TAG اذا كانت

أفلام

SERVICE\_DESCRIPTION: تتضمن توصيف لمحتوى الخدمة "مثل أسماء الأبطال و المخرج و.."

SERVICE\_TYPE: تتضمن نوع الخدمة "Live" للقنوات و "Vod" من أجل بقية الخدمات (أفلام –

مسلسلات)

IS\_MOVIE: لها عدة خيارات: (هذه الخيارات تتحقق من نوع vod)

0- الأفلام القصيرة Short Movie

1- الأفلام Movie

2- المسلسلات Series

2. VIDEOS: هذا الجدول يتضمن جميع خدمات vod المقدمة في تطبيق ال ISHOW

| VIDEO_ID | VIDEO_NAME  | VIDEO_TITLE                               | VIDEO_DESCRIPTION  | VIDEO_DURATION |
|----------|---|---|--|----------------|
| 42       | pete-s.dragon.2016.720p.bluray.x264--5Byts.ag-5D.mp4                          | Pete's Dragon                             | <p>بروي الفيلم قصة معامرات صبي يتم يدعى "بيت" وصديقه التنين المفضل لديه "إليوت"</p> <p>أداء الأصوات: روبرت ريدفورد، أوكاس فيغلي.</p> <p>إخراج: دايفيد لاوري</p> <p>سنة الإصدار: 2016</p> <p>The film tells the story of the adventures of an orphan boy named "Pete" and his favorite "dragon friend" Eliot</p> <p>Cast: Oakes Fegley, Robert Redford</p> <p>Directed By: David Lowery</p> <p>Released Date: 2016</p>  | 1:42:45        |
| 44       | star.wars.episode.1.the.phantom.menace.1999.1080p.brrip.x264.bokutox.yify.mp4 | Star Wars: Episode I - The Phantom Menace | <p>يخطط اتحاد التجار الأشرار للإستيلاء على عالم نابو المسالم بطبيعته، فيتم إرسال الفارسان كي جون جين وأودي وان كينوي للتعدي لخطط قادة اتحاد الأشرار، ولكنهما يتفشلان من المواجهة ويتمكنوا من الهروب بمساعدة صديقهم الجديد جانجان، وينطلقان بسرعة إلى نابو لتعذيب الملكة أميدالا.</p> <p>بطولة: إيوان ماك غريغور، ليام نيسون، ناتالي بورتمان</p> <p>إخراج: جورج لوكاس</p> <p>سنة الإصدار: 1999</p> <p>The Guild of Evil Merchants plans to take over the peaceful Nabu world by its nature. The two knights Qui-Gon Jinn and Obi-Wan Kenobi are sent to counter the plans of the leaders of the Union of the Villains, but they fail in confrontation and escape with the help of their new friend Gungan and rush to Napo to warn Queen Amidala.</p> <p>Cast: Ewan McGregor, Liam Neeson, Natalie Portman</p> <p>Directed By: George Lucas</p> <p>Release Date: 1999</p> | 2:16:10        |

حيث:

VIDEO\_Id : يمثل المعرف المميز لكل فيديو

VIDEO\_NAME : اسم الفيديو

VIDEO\_TITLE : اسم Vod

VIDEO\_DESCRIPTION : تتضمن توصيف لمحتوى الفيديو

VIDEO\_DURATION : تتضمن المدة الكاملة للفيديو (بالشكل التالي "ساعات: دقائق: ثواني")

3. VIDEO\_SERVICES : هذا الجدول تكمن أهميته في الربط بين الجدولين السابقين " كل VIDEO ينتمي

لـ "SERVICE"

| VIDEO_ID | SERVICE_ID      |
|----------|-----------------|
| 42       | 59956099b241628 |
| 44       | 59956099b241628 |

حيث:

VIDEO\_ID : المعرف الخاص لكل فيديو (الموجود في جدول VIDEOS)

SERVICE\_ID : المعرف الخاص لكل خدمة (الموجود في جدول SRVICES)

4. VIDEO\_TAGS : هذا الجدول يتضمن نوع VIDEOS : "يوجد Category/TAG في جدول ال

Services ولكنه غير كاف في حال كان ل VIDEO الواحد يحوي أكثر من TAG

| VIDEO_ID | TAG       |
|----------|-----------|
| 42       | Action    |
| 42       | Adventure |
| 42       | Comedy    |
| 44       | Action    |
| 44       | Adventure |
| 44       | Fantasy   |

5. WTB VIEW ARCHIVED: هذا الجدول يتضمن جميع Actions المستخدم المتعلقة بخدمات vod في

تطبيق ال ISHOW

| USER  | SERVICE_ID      | OBJECT_NAME  | TOTAL   |
|-------|-----------------|--|---------|
| ##### | 59956099b241628 | pete-s.dragon.2016.720p.bluray.x264--5Byts.ag-5D.mp4 | 856.00  |
| ##### | 59cf74003ea7632 | pete-s.dragon.2016.720p.bluray.x264--5Byts.ag-5D.mp4 | 1969.00 |

حيث:

USER: تمثل معرف الشخص المستخدم الذي يتفاعل مع الفيديو

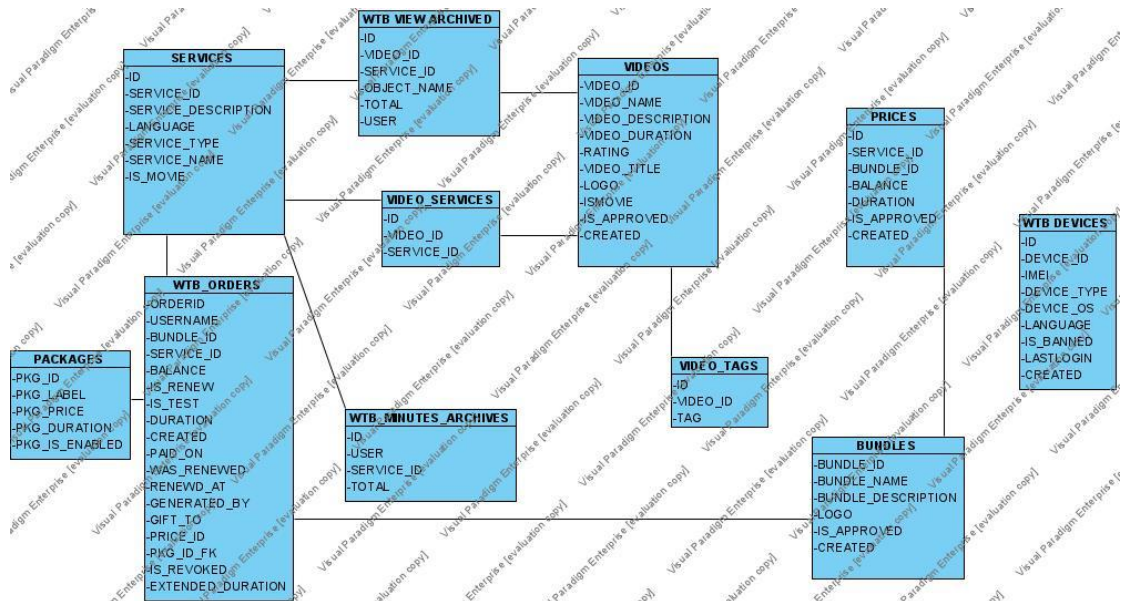
SERVICE\_ID: المعرف الخاص لكل SERVICE

OBJECT\_NAME: تتضمن اسم ال VIDEO (تكافئ VIDEO\_NAME في جدول VIDEOS)

TOTAL: تمثل مدة مشاهدة المستخدم لهذا الفيديو

قمنا بتجميع جميع جداول بيانات تطبيق ISHOW المستخدمة والغير مُستخدمة ضمن مخطط الصفوف " Class

Diagram" في الشكل 16.



الشكل 16: مخطط صفوف جداول بيانات تطبيق "ISHOW"

## المراجع

- [1] J. Davidson *et al.*, “The YouTube video recommendation system,” Dec. 2010, pp. 293–296. doi: 10.1145/1864708.1864770.
- [2] Peter. Brusilovsky, Association for Computing Machinery., and S. ACM Conference on Recommender Systems (4th : 2010 : Barcelona, *Content-based movie recommendation system using genre correlation. In Smart Intelligent Computing and Applications*. Association for Computing Machinery, 2010.
- [3] R. H. Singh, S. Maurya, T. Tripathi, T. Narula, and G. Srivastav, “Movie Recommendation System using Cosine Similarity and KNN,” *International Journal of Engineering and Advanced Technology (IJEAT)*, no. 9, pp. 2249–8958, 2020, doi: 10.35940/ijeat.E9666.069520.
- [4] G. Jawaheer, M. Szomszor, and P. Kostkova, “Comparison of Implicit and Explicit Feedback from an Online Music Recommendation Service,” in *Proceedings of the 1st International Workshop on Information Heterogeneity and Fusion in Recommender Systems*, 2010, pp. 47–51. doi: 10.1145/1869446.1869453.
- [5] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, “Item-based Collaborative Filtering Recommendation Algorithms,” *Proceedings of ACM World Wide Web Conference*, vol. 1, Dec. 2001, doi: 10.1145/371920.372071.
- [6] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, “Evaluating collaborative filtering recommender systems,” *ACM Transactions on Information Systems (TOIS)*, vol. 22, no. 1, pp. 5–53, 2004.
- [7] Y. Hu, Y. Koren, and C. Volinsky, “Collaborative filtering for implicit feedback datasets,” in *2008 Eighth IEEE International Conference on Data Mining*, 2008, pp. 263–272.
- [8] G. Jawaheer, M. Szomszor, and P. Kostkova, “Characterisation of explicit feedback in an online music recommendation service,” in *Proceedings of the fourth ACM conference on Recommender systems*, 2010, pp. 317–320.
- [9] G. Adomavicius and A. Tuzhilin, “Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions,” *IEEE transactions on knowledge and data engineering*, vol. 17, no. 6, pp. 734–749, 2005.
- [10] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom, and J. Riedl, “GroupLens: An open architecture for collaborative filtering of netnews,” in *Proceedings of the 1994 ACM conference on Computer supported cooperative work*, 1994, pp. 175–186.
- [11] U. Shardanand and P. Maes, “Social information filtering: Algorithms for automating ‘word of mouth,’” in *Proceedings of the SIGCHI conference on Human factors in computing systems*, 1995, pp. 210–217.
- [12] R. Burke, “Hybrid recommender systems: Survey and experiments,” *User modeling and user-adapted interaction*, vol. 12, no. 4, pp. 331–370, 2002.

- [13] N. J. Belkin and W. B. Croft, "Information filtering and information retrieval: Two sides of the same coin?," *Communications of the ACM*, vol. 35, no. 12, pp. 29–38, 1992.
- [14] M. Balabanović and Y. Shoham, "Fab: content-based, collaborative recommendation," *Communications of the ACM*, vol. 40, no. 3, pp. 66–72, 1997.
- [15] D. Billsus and M. J. Pazzani, "User modeling for adaptive news access," *User modeling and user-adapted interaction*, vol. 10, no. 2, pp. 147–180, 2000.
- [16] B. Sheth and P. Maes, "Evolving agents for personalized information filtering," in *Proceedings of 9th IEEE Conference on Artificial Intelligence for Applications*, 1993, pp. 345–352.
- [17] M. A. Hameed, O. al Jadaan, and S. Ramachandram, "Collaborative filtering based recommendation system: A survey," *International Journal on Computer Science and Engineering*, vol. 4, no. 5, p. 859, 2012.
- [18] Y. Koren, "Factorization meets the neighborhood: a multifaceted collaborative filtering model," in *Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2008, pp. 426–434.
- [19] X. Su and T. M. Khoshgoftaar, "A survey of collaborative filtering techniques," *Advances in artificial intelligence*, vol. 2009, 2009.
- [20] J. A. Konstan, B. N. Miller, D. Maltz, J. L. Herlocker, L. R. Gordon, and J. Riedl, "Grouplens: Applying collaborative filtering to usenet news," *Communications of the ACM*, vol. 40, no. 3, pp. 77–87, 1997.
- [21] W. Hill, L. Stead, M. Rosenstein, and G. Furnas, "Recommending and evaluating choices in a virtual community of use," in *Proceedings of the SIGCHI conference on Human factors in computing systems*, 1995, pp. 194–201.
- [22] U. Shardanand and P. Maes, "Social information filtering: Algorithms for automating 'word of mouth,'" in *Proceedings of the SIGCHI conference on Human factors in computing systems*, 1995, pp. 210–217.
- [23] G. Linden, B. Smith, and J. York, "Amazon.com recommendations: Item-to-item collaborative filtering," *IEEE Internet computing*, vol. 7, no. 1, pp. 76–80, 2003.
- [24] L. Terveen, W. Hill, B. Amento, D. McDonald, and J. Creter, "PHOAKS: A system for sharing recommendations," *Communications of the ACM*, vol. 40, no. 3, pp. 59–62, 1997.
- [25] J. B. D. CarlKadie, "Empirical analysis of predictive algorithms for collaborative filtering," *Microsoft Research Microsoft Corporation One Microsoft Way Redmond, WA*, vol. 98052, 1998.
- [26] S. Sen and P. Tripathi, "Content-Based Movie Recommendation System Using Genre Correlation".
- [27] S. Biswas, L. V. S. Lakshmanan, and S. B. Ray, "Combating the cold start user problem in model based collaborative filtering," *arXiv preprint arXiv:1703.00397*, 2017.
- [28] G. Karypis, "Evaluation of item-based top-n recommendation algorithms," in *Proceedings of the tenth international conference on Information and knowledge management*, 2001, pp. 247–254.

- [29] A. Abdul-Rahman and S. Hailes, “Supporting trust in virtual communities,” in *Proceedings of the 33rd annual Hawaii international conference on system sciences*, 2000, pp. 9–pp.
- [30] H. Yildirim and M. S. Krishnamoorthy, “A random walk method for alleviating the sparsity problem in collaborative filtering,” in *Proceedings of the 2008 ACM conference on Recommender systems*, 2008, pp. 131–138.
- [31] K. Miyahara and M. J. Pazzani, “Collaborative filtering with the simple bayesian classifier,” in *Pacific Rim International conference on artificial intelligence*, 2000, pp. 679–689.
- [32] A. Hernando, J. Bobadilla, and F. Ortega, “A non negative matrix factorization for collaborative filtering recommender systems based on a Bayesian probabilistic model,” *Knowledge-Based Systems*, vol. 97, pp. 188–202, 2016.
- [33] M. Yan, W. Shang, and Z. Li, “Application of SVD technology in video recommendation system,” in *2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS)*, 2016, pp. 1–5.
- [34] X. Guan, C.-T. Li, and Y. Guan, “Matrix factorization with rating completion: An enhanced SVD model for collaborative filtering recommender systems,” *IEEE access*, vol. 5, pp. 27668–27678, 2017.
- [35] X. Guan, C.-T. Li, and Y. Guan, “Enhanced SVD for collaborative filtering,” in *Pacific-Asia conference on knowledge discovery and data mining*, 2016, pp. 503–514.
- [36] M. G. Vozalis and K. G. Margaritis, “A recommender system using principal component analysis,” in *Published in 11th Panhellenic Conference in Informatics*, 2007, pp. 271–283.
- [37] H. Zarzour, F. Maazouzi, M. Soltani, and C. Chemam, “An improved collaborative filtering recommendation algorithm for big data,” in *IFIP International Conference on Computational Intelligence and Its Applications*, 2018, pp. 660–668.
- [38] A. Mnih and R. R. Salakhutdinov, “Probabilistic matrix factorization,” *Advances in neural information processing systems*, vol. 20, 2007.
- [39] N. Sherif and G. Zhang, “Collaborative filtering using probabilistic matrix factorization and a Bayesian nonparametric model,” in *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)*, 2017, pp. 391–396.
- [40] G. Li and W. Ou, “Pairwise probabilistic matrix factorization for implicit feedback collaborative filtering,” *Neurocomputing*, vol. 204, pp. 17–25, 2016.
- [41] J. Bobadilla, R. Bojorque, A. H. Esteban, and R. Hurtado, “Recommender systems clustering using Bayesian non negative matrix factorization,” *IEEE Access*, vol. 6, pp. 3549–3564, 2017.
- [42] M. H. Aghdam, M. Analoui, and P. Kabiri, “Collaborative filtering using non-negative matrix factorisation,” *Journal of Information Science*, vol. 43, no. 4, pp. 567–579, 2017.

- [43] M. H. Aghdam, M. Analoui, and P. Kabiri, “A novel non-negative matrix factorization method for recommender systems,” *Applied Mathematics & Information Sciences*, vol. 9, no. 5, p. 2721, 2015.
- [44] M. Wasid and R. Ali, “An improved recommender system based on multi-criteria clustering approach,” *Procedia Computer Science*, vol. 131, pp. 93–101, 2018.
- [45] L. Xiaojun, “An improved clustering-based collaborative filtering recommendation algorithm,” *Cluster computing*, vol. 20, no. 2, pp. 1281–1288, 2017.
- [46] J. Zhang, Y. Lin, M. Lin, and J. Liu, “An effective collaborative filtering algorithm based on user preference clustering,” *Applied Intelligence*, vol. 45, no. 2, pp. 230–240, 2016.
- [47] H. Zarzour, Z. Al-Sharif, M. Al-Ayyoub, and Y. Jararweh, “A new collaborative filtering recommendation algorithm based on dimensionality reduction and clustering techniques,” in *2018 9th international conference on information and communication systems (ICICS)*, 2018, pp. 102–106.
- [48] M. Jamali and M. Ester, “Trustwalker: a random walk model for combining trust-based and item-based recommendation,” in *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2009, pp. 397–406.
- [49] S. Lee, S. Song, M. Kahng, D. Lee, and S. Lee, “Random walk based entity ranking on graph for multidimensional recommendation,” in *Proceedings of the fifth ACM conference on Recommender systems*, 2011, pp. 93–100.
- [50] C.-F. Tsai and C. Hung, “Cluster ensembles in collaborative filtering recommendation,” *Applied Soft Computing*, vol. 12, no. 4, pp. 1417–1425, 2012.
- [51] N. F. AL-Bakri and S. H. Hashim, “Collaborative Filtering Recommendation Model Based on k-means Clustering,” *Al-Nahrain Journal of Science*, vol. 22, no. 1, pp. 74–79, 2019.
- [52] X. He, H. Zhang, M.-Y. Kan, and T.-S. Chua, “Fast matrix factorization for online recommendation with implicit feedback,” in *Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval*, 2016, pp. 549–558.
- [53] Y. Hu, Y. Koren, and C. Volinsky, “Collaborative filtering for implicit feedback datasets,” in *2008 Eighth IEEE International Conference on Data Mining*, 2008, pp. 263–272.
- [54] S. Rendle, C. Freudenthaler, Z. Gantner, and L. Schmidt-Thieme, “BPR: Bayesian personalized ranking from implicit feedback,” *arXiv preprint arXiv:1205.2618*, 2012.
- [55] Y. Wu, C. DuBois, A. X. Zheng, and M. Ester, “Collaborative denoising auto-encoders for top-n recommender systems,” in *Proceedings of the ninth ACM international conference on web search and data mining*, 2016, pp. 153–162.
- [56] M. Fu, H. Qu, Z. Yi, L. Lu, and Y. Liu, “A novel deep learning-based collaborative filtering model for recommendation system,” *IEEE transactions on cybernetics*, vol. 49, no. 3, pp. 1084–1096, 2018.


- [57] S. Rendle, W. Krichene, L. Zhang, and J. Anderson, “Neural collaborative filtering vs. matrix factorization revisited,” in *Fourteenth ACM Conference on Recommender Systems*, 2020, pp. 240–248.
- [58] M. J. Pazzani, “A framework for collaborative, content-based and demographic filtering,” *Artificial intelligence review*, vol. 13, no. 5, pp. 393–408, 1999.
- [59] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, “Application of dimensionality reduction in recommender system—a case study,” 2000.
- [60] J. L. Herlocker, J. A. Konstan, A. Borchers, and J. Riedl, “An algorithmic framework for performing collaborative filtering,” in *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, 1999, pp. 230–237.
- [61] J. Bennett, S. Lanning, and others, “The netflix prize,” in *Proceedings of KDD cup and workshop*, 2007, vol. 2007, p. 35.
- [62] T. Miranda *et al.*, “Combining content-based and collaborative filters in an online newspaper,” 1999.
- [63] T. Tran and R. Cohen, “Hybrid recommender systems for electronic commerce,” in *Proc. Knowledge-Based Electronic Markets, Papers from the AAAI Workshop, Technical Report WS-00-04*, AAAI Press, 2000, vol. 40.
- [64] I. Soboroff and C. Nicholas, “Combining content and collaboration in text filtering,” in *Proceedings of the IJCAI*, 1999, vol. 99, pp. 86–91.
- [65] A. I. Schein, A. Popescul, L. H. Ungar, and D. M. Pennock, “Methods and metrics for cold-start recommendations,” in *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*, 2002, pp. 253–260.
- [66] M. K. Condli, D. D. Lewis, D. Madigan, and C. Posse, “Bayesian mixed-E cts models for recommender systems,” in *ACM SIGIR*, 1999, vol. 99.
- [67] G. Shani and A. Gunawardana, “Evaluating recommendation systems,” in *Recommender systems handbook*, Springer, 2011, pp. 257–297.
- [68] S. A. Stein, G. M. Weiss, Y. Chen, and D. D. Leeds, “A College Major Recommendation System,” in *Fourteenth ACM Conference on Recommender Systems*, 2020, pp. 640–644.
- [69] G. Stamatelatos, G. Drosatos, S. Gyftopoulos, H. Briola, and P. S. Efraimidis, “Point-of-interest lists and their potential in recommendation systems,” *Information Technology & Tourism*, vol. 23, no. 2, pp. 209–239, 2021.
- [70] O. Jeunen, “Revisiting offline evaluation for implicit-feedback recommender systems,” in *Proceedings of the 13th ACM Conference on Recommender Systems*, 2019, pp. 596–600.
- [71] Y. Chung, N. Kim, C. Park, and J.-H. Lee, “Improved neighborhood search for collaborative filtering,” *International Journal of Fuzzy Logic and Intelligent Systems*, vol. 18, no. 1, pp. 29–40, 2018.
- [72] N. Hurley and M. Zhang, “Novelty and diversity in top-n recommendation–analysis and evaluation,” *ACM Transactions on Internet Technology (TOIT)*, vol. 10, no. 4, pp. 1–30, 2011.

- [73] M. Mendoza and N. Torres, “Evaluating content novelty in recommender systems,” *Journal of Intelligent Information Systems*, vol. 54, no. 2, pp. 297–316, 2020.
- [74] K. Ikawa *et al.*, “Evaluation of a TV Programs Recommendation using the EPG and Viewer’s Log Data,” *Adjunct Proceedings EuroITV*, pp. 182–185, 2010.
- [75] F. S. da Silva, L. G. P. Alves, and G. Bressan, “PersonalTVware: A proposal of architecture to support the context-aware personalized recommendation of TV programs,” in *Proc. of 7th Eur. Conf. Interactive TV and Video*, 2010, pp. 39–42.
- [76] M. Uluyagmur, Z. Cataltepe, and E. Tayfur, “Content-based movie recommendation using different feature sets,” in *Proceedings of the world congress on engineering and computer science*, 2012, vol. 1, pp. 17–24.
- [77] Y. Koren, R. Bell, and C. Volinsky, “Matrix factorization techniques for recommender systems,” *Computer*, vol. 42, no. 8, pp. 30–37, 2009.
- [78] M. Ilhami and others, “Film recommendation systems using matrix factorization and collaborative filtering,” in *2014 International Conference on Information Technology Systems and Innovation (ICITSI)*, 2014, pp. 1–6.
- [79] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T.-S. Chua, “Neural collaborative filtering,” in *Proceedings of the 26th international conference on world wide web*, 2017, pp. 173–182.
- [80] Y. Koren, “The bellkor solution to the netflix grand prize,” *Netflix prize documentation*, vol. 81, no. 2009, pp. 1–10, 2009.
- [81] G. Jawaheer, M. Szomszor, and P. Kostkova, “Comparison of implicit and explicit feedback from an online music recommendation service,” in *proceedings of the 1st international workshop on information heterogeneity and fusion in recommender systems*, 2010, pp. 47–51.

**Syrian Arab Republic**

**Higher Institute for Applied Sciences and**

**Technology Department of Information Systems**



A Thesis Submitted for Master's  
Degree in Decision Support Systems

**A Recommendation System Based on Implicit Data for  
Internet Protocol Television (IPTV)**

Submitted By

**Eng. Lama Mohsen Mansour**

Supervised by

**Dr. Yasser Rahal**

**Dr. Mustapha Dakkak**

**December 2021**