

الجمهورية العربية السورية  
المعهد العالي للعلوم التطبيقية والتكنولوجيا  
قسم نظم المعلوماتية

أعدت هذه الأطروحة لنيل درجة الماجستير  
في نظم المعلومات ودعم القرار

بناء نظام توصية مدرك للوقت  
**Time-Aware Recommendation System**

إعداد

م. باسل مريم

إشراف

د. ياسر رحّال

د. مصطفى دقاق

تشرين الثاني 2022



# المعهد العالي للعلوم التطبيقية والتكنولوجيا

Higher Institute for Applied Science & Technology (HIAST)

مؤسسة سورية حكومية للتعليم العالي أحدثت في عام 1983م، بهدف إعداد أطر متميزة مؤهلة للبحث العلمي والتطوير في مجال العلوم التطبيقية والتقانة، لتساهم بفاعلية في التنمية العلمية والصناعية والاقتصادية في القطر.

يشكّل التأهيل الهندسي والدراسات العليا في المعهد العالي محور عمليّة إعداد الأطر المتخصّصة. يخرّج المعهد العالي مهندسين متميزين، بعد دراسة لمدة خمس سنوات، في اختصاصات الاتصالات والمعلوماتية والنظم الإلكترونيّة 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 عدة 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. أما في مرحلة الماجستير فيقبل المعهد العالي حملة الشهادات الجامعية الموازية للماجستير المطلوب، وذلك على أساس مفاضلة خاصة لاختيار الأفضل. كما يقدم المعهد للطلاب جواً متميزاً للدراسة والبحث بدءاً من كوادره المتفرغة عالية التأهيل ومناهجه المواكبة للتطورات العلمية، وانتهاءً بإمكانيات مختبراته المتميزة في القطر وبنيته 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 وصالات 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 باسل محمد مريم معدّ أطروحة الماجستير التي تحمل العنوان:

"نظام توصية مدرك للوقت يعتمد الترشيح التعاوني"

"Time-Aware Collaborative Filtering Recommendation System"

أصح بأن:

الأعمال والنتائج المعروضة في هذه الأطروحة هي نتيجة مجهودي الشخصي، وبتوجيه وتحت إشراف كامل من قبل المشرفين، وقد نسب ما عدا ذلك من معلومات ونتائج متعلقة بالبحث إلى مصادرها، وأشير إليها بشكل صريح في متن النص، وفي قائمة المراجع.

مجموعة البيانات المستخدمة جرى تحصيلها بشكل سليم، ومشروع، وجرى تعريفها بشكل علمي، وأكاديمي ضمن الأطروحة، ونسبت إلى مصدرها.



# كلمة شكر

تلوح في سماءنا دوماً نجوم بَرّاقة، لا يخفت بريقها عنّا لحظةً واحدةً، نترقّب إضاءتها بقلوب متلهفة، ونسعد بلمعانها في سماءنا كلّ ساعة، فاستحقتّ وبكلّ فخر أن يرفع اسمها في علينا.

أتوجّه بخالص الشكر والتقدير والعرفان لحضرات المشرفين الأفاضل الدكتور مصطفى الدقاق والدكتور ياسر رحّال لما قدّموه من توجيهات دقيقة في كل خطوة على طريق هذا البحث.

كما أخص بالذكر أعضاء الكادر التدريسي والإداري لما جستير نظم المعلومات ودعم القرار الذين لم يدّخروا جهداً في سبيل تقديم المعرفة خلال فترة دراستي.

وأختم بالشكر إلى المعهد العالي للعلوم التطبيقية والتكنولوجيا من دكاترة ومدّرّسين وإداريين وموظّفين الذين قدّموا كل الدعم الفني والتقني لنجاح هذا البحث.

م. باسل محمد مريم



## الإهداء

إلى معلّمتي ومربّيتي الأولى ... إلى أرق الألحان وأعذب الأنغام .... إلى الشمعة المقدّسة التي تنير  
ظلمات هذه الحياة .. إلى بلسم العمر

أمي العظيمة: المعلّمة صباح المحمد

إلى قدوتي وملهبي .. إلى من رحل عني ولم يرحل مني .. إلى من كان نبراس العلم ومرساة الأمان

أبي العزيز م. محمد مريم

إلى سندي ورفيق دربي ... إلى من لا يضيق قلبه مهما ضاقت بي الحياة .. إلى النبع الذي ارتوي منه  
الحب والقوة والعنفوان

أخي م. علي مريم

إلى بهجة القدر ... إلى من كان قلبها كقلوب الأمهات حناناً ورقّة .. إلى الأخت والصديقة الداعمة لي  
دوماً

زوجة أخي م. حلا قاسم

إلى النجوم في سمائي .. إلى من تشاطرت معهم كل مراحل الجامعة وشاركوني لحظات الحزن قبل  
الفرح .. إلى من يزداد تألقاً كلما ضاق هذا الكون.

أصدقائي ورفاق دربي



# جدول المحتويات

i.....	المَلْخص
iii .....	قائمة الأشكال
vii .....	قائمة الجداول
ix.....	قائمة المصطلحات والاختصارات
1.....	1. الفصل الأول
2 .....	1.1 مقدمة
3 .....	1.2 الإطار العام للبحث
3 .....	1.3 دوافع البحث
4 .....	1.4 إشكالية البحث
4 .....	1.5 فكرة الحل المقترح
7 .....	2. الفصل الثاني
8 .....	2.1 مقدمة
9 .....	2.2 آراء المستخدمين في نظم التوصية
9.....	2.2.1 آراء صريحة
9.....	2.2.2 آراء ضمنية
10.....	2.3 أنواع نظم التوصية (من وجهة نظر معمارية وخوارزمية)
10 .....	2.3.1 نظم التوصية المعتمدة على القواعد Rule-Based RS
10 .....	2.3.2 نظم التوصية المعتمدة على المحتوى CB-RS
12 .....	2.3.3 نظم التوصية القائمة على الترشيح التعاوني CF-RS
26.....	2.3.4 النموذج الهجين Hybrid Model
30.....	2.4 تقييم نظم التوصية
35 .....	3. الفصل الثالث
36.....	3.1 مقدمة
37.....	3.2 السياق

38	3.3 الدّراسة المرجعية.....
38	1.3.3 نموذج الترشيح التعاوني CF.....
41	2.3.3 نموذج التعلّم العميق.....
47	4. الفصل الرابع.....
48	4.1 مقدمة.....
48	4.2 مجموعة المعطيات Dataset.....
49	4.3 المعالجة المسبقة لمجموعة المعطيات Preprocessing.....
50	4.4 توزّع مجموعة المعطيات.....
52	4.5 حساب التقييم بحالة نموذج غير مدرك للوقت Time Free.....
53	4.6 النماذج المدركة للوقت والمعتمدة على الذاكرة Memory-Based.....
53	1.6.4 نموذج النافذة المتخامدة Damped Window.....
56	2.6.4 نموذج النافذة الزمنية المنزلقة Sliding Window.....
65	3.6.4 نموذج السياق الزمني Context-Aware RS.....
69	4.7 النموذج المدرك للوقت والمعتمد على التعلّم العميق Neural-TARS.....
77	4.8 تحليل النتائج.....
78	5. الفصل الخامس.....
79	5.1 الخاتمة والآفاق المستقبلية.....
80	6. المراجع.....

## الملخص

نظام التوصية هو فئة من أنظمة تصفية وتخصيص المعلومات؛ يقدم للمستخدم عناصر قد يكون مهتمًا بها وفقًا لتفضيلاته وسلوكه السابق بناءً على العديد من العوامل المختلفة، تتنبأ هذه الأنظمة بالعنصر الذي من المرجح أن يهتم المستخدم، وتستخدم من قبل شركات تكنولوجيا كبيرة مثل Amazon و Netflix و Youtube، لمساعدة مستخدميها على تحديد المنتجات أو الأفلام التي قد تكون مفضلة لهم. بشكل عام تستخدم أنظمة التوصية التقليدية على اختلاف أنواعها ملفات تعريف المستخدمين User Profile، والعناصر Item Profile، والتشابه بين المستخدمين Users Similarity، من أجل التنبؤ بتصنيفات العناصر غير المرئية.

إن أبرز التحديات التي تواجه معظم نظم التوصية التقليدية هي أن بيانات المستخدمين والعناصر وكذلك تفضيلات المستخدمين يتم تحديثها باستمرار بمرور الزمن، ولا تأخذ هذه النظم بالاعتبار تغيير التشابه بين المستخدمين، وبين العناصر، وتغير تفضيلات المستخدم نفسه مع الزمن. مما يجعلها قاصرة على تقديم توصيات دقيقة.

نقدم من خلال هذا البحث نموذجي توصية يستخدم الأول الترشيح التعاوني Time-Aware Collaborative Filtering Model بالإضافة إلى استغلال السياق الزمني للمستخدم وقياس تغير التشابه بين المستخدمين بمرور الزمن لتحسين دقة التنبؤ، ويستخدم النموذج الثاني عامل المصفوفة والشبكات العصبونية بالإضافة إلى استغلال السياق الزمني في عملية التوصية، جرى استخدام واختبار النموذجين على نفس مجموعة البيانات وأظهرت النتائج أن النموذجين المقترحين قدما توصية أكثر دقة من النماذج التقليدية التي لا تستخدم السياق الزمني في عملية التوصية.

# Abstract

A recommendation system is a subcategory of information filtering systems; Offering the user items he or she might be interested in according to their past preferences and behavior based on many different factors. These systems predict the most likely item of interest to the user, and they are used by large tech companies such as Netflix, Amazon and Youtube to help their users decide which products or movies might be their favorites. In general, traditional recommendation systems of all kinds use User-Profile and Item-Profile as well as User Similarities in order to predict ratings of invisible items.

The main challenges facing most traditional recommendation systems are that the user data and items, as well as user preferences, are constantly updated over time. and these systems do not take into account the change in similarities between users, as well as between items, and the change in preferences of the user himself over time. This makes them limited to providing accurate recommendations.

In this research, we present two recommendation models, the first model uses Time-Aware Collaborative Filtering in addition to exploiting the user's temporal context and measuring the change of similarity between users over time to improve prediction accuracy, and the second model uses the Matrix Factorization by taking advantage of neural networks in addition to exploiting the temporal context in the recommendation process, The two models were used and tested on the same dataset, and the results showed that the two proposed models provided a more accurate recommendations than the traditional models that do not use temporal context in the recommendation process.

**Keywords:** Recommendation System, Collaborative Filtering, Content-Based, Time-Aware Recommendation Systems, Decay Function, Sliding Window, Machine Learning, Deep Learning, Matrix Factorization, Embeddings, Deep Neural Networks.

## قائمة الأشكال

- الشكل (1): حجم الفيديوهات التي تُرفع على منصّة Youtube الشهيرة كل دقيقة مقاسًا بالساعات لغاية شهر شباط 2020..... 2
- الشكل (2): الترشيح التعاوني المعتمد على المستخدم UB-RS..... 13
- الشكل (3): تشابه المتجهات في فضاء ثلاثي الأبعاد (تمثيل المستخدمين كشعاع بثلاث إحداثيات تمثل تقييم مسبق من المستخدمين لثلاثة عناصر ضمن نظام التوصية)..... 15
- الشكل (4): الترشيح التعاوني المعتمد على العنصر..... 18
- الشكل (5): الذيل الطويل لشعبية العناصر..... 19
- الشكل (6): تمثيل مصفوفة تقييم العناصر Rating Matrix كمصفوفتي ميزات العناصر والمستخدمين..... 22
- الشكل (7): عامل المصفوفة باستخدام تحليل القيمة المفردة..... 23
- الشكل (8): محدودية MF في تمثيل العلاقات..... 24
- الشكل (9): بنية نموذج الترشيح التعاوني العصبوني NCF..... 25
- الشكل (10): نظام توصية هجين موزون..... 27
- الشكل (11): نظام توصية هجين يعتمد التبديل..... 28
- الشكل (12): دمج بعض الخصائص القائمة على المحتوى في النموذج التعاوني..... 28
- الشكل (13): دمج الخصائص التعاونية في النموذج القائم على المحتوى Features Combination..... 29
- الشكل (14): نموذج متعدد الأبعاد لتوصية المستخدم  $\times$  العنصر  $\times$  الوقت..... 37
- الشكل (15): قيم متوسط الخطأ المطلق MAE من أجل قيم مختلفة لمعامل الحساسية  $\lambda$  والتشابه Similarity..... 39
- الشكل (16): قيم متوسط الخطأ المطلق MAE من أجل عدّة نوافذ وعدّة عتبات لمعيار التشابه..... 39
- الشكل (17): قيم متوسط الخطأ المطلق MAE من أجل السياق الزمني (الوقت من الإسيوع)..... 40
- الشكل (18): نموذج التوصية المدرك للسياق CARS..... 41
- الشكل (19): تمثيلات السياق الكامنة. (a) سياق كامن غير مهيكّل (b) سياق الكامن الهرمي..... 43

- الشكل (20): تعزيز نموذج الترشيح التعاوني العصبوني NCF بإضافة المعلومات السياقية المضمّنة... 44
- الشكل (21): تعزيز نموذج عامل المصفوفة العصبوني Neu-MF بإضافة المعلومات السياقية المضمّنة  
45.....
- الشكل (22): توزيع أنواع الأفلام ضمن مجموعة البيانات..... 50
- الشكل (23): توزيع التقييمات بالنسبة للوقت من اليوم..... 50
- الشكل (24): توزيع التقييمات بالنسبة لفصول السنة..... 51
- الشكل (25): توزيع التقييمات بالنسبة لوقت الإِسبوع (يوم عمل - يوم عطلة)..... 51
- الشكل (26): توزيع التقييمات بالنسبة لسنوات التقييم..... 52
- الشكل (27): مقارنة بين نموذج النافذة المتخادمة والنموذج غير المدرك للوقت باختيار عتبة التشابه  
Threshold = 0.3 واختيار  $\text{Sigma} = 0.98$  من أجل عدة قيم للحساسية..... 54
- الشكل (28): مقارنة بين نموذج النافذة المتخادمة والنموذج غير المدرك للوقت باختيار عتبة التشابه  
Threshold = 0.4 واختيار  $\text{Sigma} = 0.98$  من أجل عدة قيم للحساسية..... 54
- الشكل (29): مقارنة بين نموذج النافذة المتخادمة والنموذج غير المدرك للوقت باختيار عتبة التشابه  
Threshold = 0.5 واختيار  $\text{Sigma} = 0.98$  من أجل عدة قيم للحساسية..... 55
- الشكل (30): مقارنة النافذة الزمنية المنزقة مع نموذج غير مدرك للوقت باستخدام نافذة ذات أطوال متغيرة  
بدءاً من سنة ولغاية 15 سنة..... 57
- الشكل (31): مصفوفة التشابه بين المستخدمين ضمن نافذة طولها سنة واحدة..... 59
- الشكل (32): مصفوفة التشابه بين المستخدمين ضمن نافذة طولها 20 سنة..... 59
- الشكل (33): تغيير التشابه بين المستخدمين ذوي المعرفين 45 و 68..... 60
- الشكل (34): تغيير التشابه بين المستخدمين ذوي المعرفين 30 و 64..... 60
- الشكل (35): مقارنة قيم MAE بين نموذج النافذة المنزقة بتشابه متغير على عدّة سنوات (1-8) والنموذج  
غير المدرك للوقت ضمن نافذة طولها سنة واحدة..... 61
- الشكل (36): مقارنة قيم MAE بين نموذج النافذة المنزقة بتشابه متغير على عدّة سنوات (2-8) والنموذج  
غير المدرك للوقت ضمن نافذة طولها سنتين..... 62

الشكل (37): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغيّر على عدّة سنوات (3-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 3 سنوات.....	63
الشكل (38): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغيّر على عدّة سنوات (4-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 4 سنوات.....	64
الشكل (39): تمثيل الوقت بشكل هرمي كميزة متعدّدة الأبعاد.....	65
الشكل (40): مقارنة قيم MAE بين نموذج السياق الزمني ونموذج غير مدرك للوقت من أجل عتبة تشابه 0.3.....	66
الشكل (41): مقارنة قيم MAE بين نموذج السياق الزمني ونموذج غير مدرك للوقت من أجل عتبة تشابه 0.4.....	67
الشكل (42): مقارنة قيم MAE بين نموذج السياق الزمني ونموذج غير مدرك للوقت من أجل عتبة تشابه 0.5.....	68
الشكل (43): السياق الزمني في مجموعة المعطيات المستخرج من الطابع الزمني Timestamp لكل تقييم.....	69
الشكل (44): استخراج الأنواع بشكل منفرد.....	69
الشكل (45): توزّع ميزات الأفلام ضمن مجموعة المعطيات.....	70
الشكل (46): بنية نموذج عامل المصفوفة القياسي.....	72
الشكل (47): تابع الخسارة في نموذج GMF بالنسبة لعدد تكرارات التدريب في كل من مجموعتي التدريب والاختبار.....	73
الشكل (48): بنية نموذج Neural-MF.....	74
الشكل (49): تابع الخسارة في نموذج Neural-MF بالنسبة لعدد تكرارات التدريب في كل من مجموعتي التدريب والاختبار.....	74
الشكل (50): ترميز التسمية للسياق الزمني في نموذج Neural-TARS.....	75
الشكل (51): بنية نموذج التوصية المدرك للوقت العصبوني Neural-TARS.....	76
الشكل (52): تابع الخسارة في نموذج Neural-MF بالنسبة لعدد تكرارات التدريب في كل من مجموعتي التدريب والاختبار.....	76

الشكل (53): مقاييس التقييم (دقة الترتيب) لكل نموذج على مجموعة المعطيات المستخدمة.....77

الشكل (54): مقاييس التقييم (دقة التنبؤ) لكل نموذج على مجموعتي التدريب والاختبار لكل نموذج....77

## قائمة الجداول

- الجدول (1): مصفوفة الارتباك Confusion Matrix لنظام توصية ..... 31
- الجدول (2): توصيف مجموعات البيانات المستخدمة ..... 45
- الجدول (3): مقارنة نتائج النماذج المطبقة مع النماذج التقليدية بدون إضافة السياق Context ..... 46
- الجدول (4): توصيف مجموعة البيانات المستخدمة ..... 48
- الجدول (5): معالجة الأفلام ذات عدد التقييمات المنخفضة ..... 49
- الجدول (6): معالجة المستخدمين ذوي عدد التقييمات المنخفضة ..... 49
- الجدول (7): مقارنة نموذج النافذة المتخادمة المدرك للوقت مع نموذج غير مدرك للوقت بأخذ عتبة تشابه 0.3 ..... 55
- الجدول (8): مقارنة نموذج النافذة المتخادمة المدرك للوقت مع نموذج غير مدرك للوقت بأخذ عتبة تشابه 0.4 ..... 55
- الجدول (9): مقارنة نموذج النافذة المتخادمة المدرك للوقت مع نموذج غير مدرك للوقت بأخذ عتبة تشابه 0.5 ..... 56
- الجدول (10): مقارنة قيم MAE بين نموذج النافذة المنزلقة والنموذج غير المدرك للوقت بأخذ عدة أطوال للنافذة ..... 57
- الجدول (11): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (1-8) والنموذج غير المدرك للوقت ضمن نافذة طولها سنة واحدة ..... 61
- الجدول (12): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (2-8) والنموذج غير المدرك للوقت ضمن نافذة طولها سنتين ..... 62
- الجدول 13: مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (3-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 3 سنوات ..... 63
- الجدول (14): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (4-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 4 سنوات ..... 64

الجدول (15): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغيّر على عدّة سنوات (5-8)	
والنموذج غير المدرك للوقت ضمن نافذة طولها 5 سنوات	64.....
الجدول (16): مقارنة قيم MAE لنموذج السياق زمني من أجل عدّة سياقات زمنية باستخدام عتبة تشابه	
0.3	67.....
الجدول (17): مقارنة قيم MAE لنموذج السياق زمني من أجل عدّة سياقات زمنية باستخدام عتبة تشابه	
0.4	67.....
الجدول (18): مقارنة قيم MAE لنموذج السياق زمني من أجل عدّة سياقات زمنية باستخدام عتبة تشابه	
0.5	68.....
الجدول (19): معلمات نموذج GMF لتنبؤ تقييم المستخدم لعنصر ما	72.....
الجدول (20): قيم معايير تقييم النموذج السابق	73.....
الجدول (21): قيم تابع الكلفة في مجموعتي التدريب والاختبار	73.....
الجدول (22): قيم تابع الكلفة في مجموعتي التدريب والاختبار في نموذج Neural-MF	74.....
الجدول (23): قيم معايير تقييم نموذج Neural-MF	75.....
الجدول (24): قيم تابع الكلفة في مجموعتي التدريب والاختبار في نموذج Neural-TARS	76.....
الجدول (25): قيم معايير التقييم في نموذج Neural-TARS	76.....

## قائمة المصطلحات والاختصارات

المصطلح	المعنى باللغة الإنكليزية	المعنى باللغة العربية
AP	Average Precision	متوسط الدقة
CARS	Context-Aware Recommendation System	نظام توصية مدرك للسياق
CB-RS	Content-Based Recommendation System	نظام توصية معتمد على المحتوى
CF	Collaborative Filtering	الترشيح التعاوني
CF-RS	Collaborative Filtering Recommendation System	نظام توصية يعتمد الترشيح تعاوني
Clustering		العنقدة
CTR	Click-Through Rate	نسبة النقر إلى الظهور
DCG	Discounted Cumulative Gain	الربح التراكمي المخصص
DSSW	Dynamic Similarity Sliding Window	النافذة المنزلقة مع تشابه متغير
DW	Damped Window	النافذة المتخامدة
GMF	Generalized Matrix Factorization	عامل المصفوفة القياسي (المعمّم)
IB-CF	Item-Based Collaborative Filtering	الترشيح التعاوني المعتمد على العنصر
KNN	K-Nearest Neighbors	خوارزمية أقرب جار
Latent Factors		العوامل الكامنة
LSA	Latent Semantic Analysis	التحليل الدلالي الكامن
MAE	Mean Absolute Error	متوسط الخطأ المطلق
MAP	Mean Average Precision	
MF	Matrix Factorization	عامل المصفوفة
MLP	Multi-Layer Perceptron	شبكة عصبونية متعددة الطبقات
MRR	Mean Reciprocal Rank	متوسط مقلوب الترتيب
NCF	Neural-CF	نموذج الترشيح التعاوني العصبوني
NDCG	Normalized Discounted Cumulative Gain	الربح التراكمي المخصص المسوّى


نموذج عامل المصفوفة العصبوني	Neural Matrix Factorization	NeuMF or Neural-MF
متوسط الخطأ المطلق المسوي	Normalized Mean Absolute Error	NMAE
شبكة عصبونية	Neural Network	NN
معامل ارتباط بيرسون	Pearson Correlation Coefficient	PCC
نظام تخصيص	Personalization System	PS
	Rectified Linear Unit	Relu
جذر متوسط الخطأ التربيعي	Root Mean Square Error	RMSE
نظام توصية	Recommendation System	RS
النافذة المنزلقة مع تشابه ثابت	Static Similarity Sliding Window	SSSW
تحليل القيمة المفردة	Singular Value Decomposition	SVD
النافذة المنزلقة	Sliding Window	SW
نظام توصية مدرك للوقت	Time-Aware Recommendation System	TARS
نظام توصية غير مدرك للوقت	Time-Free Recommendation System	TFRS
الترشيح التعاوني المعتمد على المستخدم	User-Based Collaborative Filtering	UB-CF
ملف المستخدم الشخصي	User-Profile	UP

## الفصل الأول

يقدم هذا الفصل تعريفًا  
بالإطار العام ودافع وإشكالية البحث

## 1.1 مقدمة

أدى التطور التكنولوجي الكبير الذي نتج عنه ظهور الأجهزة المحمولة الذكية Smart Phones، وسهولة الوصول للشبكة العنكبوتية World Wide Web إلى زيادة عدد زوار الإنترنت بشكل كبير، رافقه تدفق هائل للبيانات التي يتم تقديمها كمحتوى عبر الشبكة، سواء من التجارة الإلكترونية Amazon أو منصات البث Netflix و Youtube وغيرها (يظهر الشكل 1 حجم الفيديوهات التي تُرفع على منصة Youtube كل دقيقة مقاسًا بالساعات لغاية شهر شباط 2020 بحسب موقع Statista)؛ ما جعل المستخدم أمام عددٍ هائلٍ من الخيارات، وأصبح العثور على المعلومات المطلوبة، والوصول إليها بالطريقة المثلى أمرًا بالغ الأهمية للعديد من الشركات ومراكز البحث؛ لذلك ظهرت الحاجة لنظم التوصية التي تُعنى بتصفية المعلومات ذات الصلة، وترتيبها حسب الأولوية، وتقديمها بكفاءة للمستخدم، من أجل التخفيف من مشكلة الحمل الزائد للمعلومات Information Overload. تعمل هذه النظم بشكل أساسي من خلال البحث في حجم كبير من المعلومات التي يتم إنشاؤها بشكل ديناميكي على الشبكة، ومن ثم تزويد المستخدمين بمحتوى وخدمات مخصصة Personalized Contents، ونظرًا لأهمية نظم التوصية فقد طرحت شركة Netflix\* عام 2009 مسابقتها الشهيرة، وهي عبارة عن مسابقة مفتوحة لأفضل خوارزمية تصفية تعاونية Collaborative Filtering (CF) للتنبؤ بتقييمات المستخدمين للأفلام، استنادًا إلى التصنيفات السابقة على مجموعة بيانات تتألف من تقييمات لحوالي 17,770 فيلمًا بواسطة 2,649,430 مستخدم وكانت جائزة المسابقة مليون دولار أمريكي [1]. حقق الفوز في المسابقة فريق BellKor Pragmatic Chaos حيث قاموا بتدريب أكثر من 100 نموذج، متضمنة الانحدار الخطي وكثيرات الحدود Linear and Polynomial Regression، إضافة للشبكات العصبونية Neural Networks والتعزيز Boosting، متفوقًا على خوارزمية الشركة نفسها بحوالي 10%. لكن الحل المقترح الذي قدّمه كان شديد التعقيد ولم يوضع قيد الإنتاج، إلا أنه لفت النظر إلى الكثير من الأمور التي جعلت من أنظمة التوصية التقليدية قاصرة، وغير قادرة على إعطاء نتائج دقيقة والتي سنذكرها تبعاً في البحث.



الشكل (1): حجم الفيديوهات التي تُرفع على منصة Youtube الشهيرة كل دقيقة مقاسًا بالساعات لغاية شهر شباط 2020

\* هي شركة ترفيهية أمريكية أسسها Reed Hastings و Marc Randolph في 29 أغسطس 1997، في سكوتس فالي، كاليفورنيا. تتخصص في تزويد خدمة البث الحي والفيديو حسب الطلب وتوصيل الأقراص المدمجة عبر البريد. في عام 2013، توسعت الشركة بإنتاج الأفلام والبرامج التلفزيونية، وتوزيع الفيديو عبر الإنترنت.

## 1.2 الإطار العام للبحث

يندرج هذا البحث ضمن إطار توسيع نظم التوصية التقليدية، وزيادة دقة نتائجها، من خلال استغلال السياق الزمني للمستخدمين في عملية التوصية، ودمج المعلومات الزمنية أثناء المعالجة، مما يؤدي إلى تعزيز قياس التشابه الحي بين المستخدمين وبين العناصر على حد سواء، كما نضيف أيضًا وظيفة وزن الوقت في خطوة توقع تفضيلات المستخدم لتحسين دقة التنبؤ.

## 1.3 دوافع البحث

نظام التوصية هو نوع من أنظمة التخصيص (PS) Personalized System، وتقاس جودة نظام التوصية في تخصيص المحتوى والتوصية بالعناصر اعتمادًا على قدرته على استنتاج ما يتطلبه المستخدم، بناءً على التفاعلات السابقة أو الحالية مع العناصر ضمن النظام، إضافةً إلى استنتاج أوجه التشابه الحقيقي مع مستخدمين آخرين، ومقدار الثقة بالعناصر التي يوصي بها النظام للمستخدمين، وقدرته على التعامل مع العناصر أو المستخدمين الجدد في النظام؛ لذلك يُنظر لمهمة تخصيص العناصر على أنها مشكلة تنبؤ (يجب أن يحاول النظام التنبؤ بمستوى اهتمام المستخدم بعناصر معينة وترتيبها وفقًا لقيمها المتوقعة). من وجهة نظر معمارية وخوارزمية، تنقسم أنظمة التوصية إلى خمسة أنواع: النوع الأول هو **نظم التوصية المستندة إلى القواعد (Rule-Based Recommendation System (Rule-Based RS)** التي تعتمد على قواعد قرار، يتم إنشاؤها في الغالب بشكل يدوي في البداية من قبل خبراء في المجال الذي يُستخدم فيه النظام، Domain Expert، لذا يعتمد هذا النوع بشكل كبير على المجال (E-Commerce, Video Broadcasting)، وتُستخدم هذه القواعد للتوصية بالعناصر للمستخدمين، ومن ثم يتعلم النظام، ويقوم بتعديلات ديناميكية عليها بحسب التفاعل بين المستخدمين والعناصر، وردود أفعال المستخدمين Users Feedback على هذه العناصر [2]. فيما يعتمد النوع الثاني وهو **نظم التوصية المعتمدة على المحتوى (Content-Based (CB-RS)** بشكل أساسي على العناصر التي تفاعل معها المستخدم في السابق (أبدى إعجابها)، بحيث يقوم هذا النوع باستخراج مجموعة من الميزات التي تميز عنصر ما، واستخدامها لتحديد العناصر المشابهة بحسب هذه الميزات، على سبيل المثال إذا أبدى المستخدم إعجابًا بفيلم Iron Man فعلى الأرجح سيبدى إعجابًا بالأفلام التي بطلها Tony Stark أو أفلام الأبطال الخارقين Super Hero [3]. أما النوع الثالث وهو **نظم التوصية القائمة على الترشيح التعاوني (Collaborative-Filtering (CF-RS)** فيعتمد على إيجاد المستخدمين المشابهين للمستخدم المستهدف Target User الذين لهم اهتمامات ذات صلة باهتماماته، عن طريق مقارنة ملفات المستخدمين مع ملف هذا المستخدم، على سبيل المثال مستخدمين أبدوا إعجابًا بعناصر مشابهة أو ببعض العناصر التي أعجب بها هذا المستخدم سابقًا، ومن ثم يحصل المستخدم على توصيات لعناصر موجودة في ملفات المستخدمين المشابهين لم يتم بتصنيفها من قبل (غير مرئية له) [4,5]. فيما يقترح النوع الرابع من نظم التوصية وهو **نظم التوصية المعتمدة على المعرفة (Knowledge-Based RS)** العناصر بناءً على الاستنتاجات حول احتياجات المستخدم وتفضيلاته، و تتضمن هذه الاستنتاجات غالبًا معرفة وظيفية صريحة، مثل سؤال المستخدم عن تفضيلاته مسبقًا [6]. والنوع الخامس والأخير هو **نظم التوصية الهجينة Hybrid RS** الذي يتضمن اثنين أو أكثر من الأساليب المذكورة سابقًا لتحسين أداء التوصيات والتغلب على مشاكل استخدام كل نظام على حدى [7].

## 4.1 إشكالية البحث

تستخدم أنظمة التوصية التقليدية ملفات تعريف المستخدمين والعناصر، من أجل التنبؤ بتصنيفات العناصر غير المرئية. أول مشكلة لفتت إليها مسابقة Netflix هي أن معظم نظم التوصية التقليدية تستخدم تفضيلات المستخدم الثابتة Static Preferences، ولا تأخذ بالاعتبار تغيّر تفضيلات المستخدم المستهدف بمرور الوقت، سواء على المدى القريب Short-Term، أو المدى البعيد Long-Term، وكما هو معروف تتطوّر وتتغيّر احتياجات المستخدم، والنمط الذي يفضله من المعلومات بمرور الوقت Dynamic Preferences، خاصةً إذا أخذنا في الاعتبار فترة زمنية طويلة، وهذا التغيير يمكن أن يكون بسلاسة Drifting أو تحوّل بشكل جذري Shifting، حيث أنه في الواقع، يميل معظم المستخدمين إلى تغيير أذواقهم بشكل متكرر، وتنشأ التغيّرات في تفضيلات المستخدمين من أسباب جوهرية مثل تحوّل الشخصية والنضج المعرفي والفكري، أو أسباب عابرة وظرفية مثل التغيّرات الموسمية في شعبية العنصر، أو اختلاف المزاج Mood الذي يكون عليه المستخدم، إضافة إلى الحالة الاجتماعية له، على سبيل المثال في مجال الأفلام، يمكن للمستخدم تغيير سلوك التصنيف الخاص به، أو تفضيله لنوع الفيلم على لغته، أو البدء في تفضيل الدراما على الكوميديا أو النوع الحركي على الرومنسي. من وجهة نظر أخرى قد يكون لمهندس برمجيات خلال أيام العمل تفضيلاً لقراءة أخبار التكنولوجيا، وآخر التحديثات في مجال لغات البرمجة، بينما قد يكون مهتماً خلال عطلة نهاية الأسبوع بقراءة مقالات عن الطهي أو مجلات ترفيهية. غالباً يؤدي تجاهل هذه الانحرافات الزمنية في نمذجة تفضيلات المستخدمين إلى تقديم توصيات غير مفيدة أو أقل دقة.

## 5.1 فكرة الحل المقترح

تعتمد فكرة استغلال العامل الزمني في عملية التوصية على التمييز بين نوعين من تأثير الوقت على تفضيلات المستخدم وهما:

➤ التوصيات المعتمدة على الحداثة Fresh-Based Recommendations

➤ التوصيات المعتمدة على السياق الزمني Time Context-Based Recommendations

نعتمد في الحل على أربع مقاربات رئيسية، تستند أول ثلاث مقاربات إلى الترشيح التعاوني حيث استخرجنا في المقاربة الأولى المستخدمين المشابهين للمستخدم الهدف، ومن ثم أخذنا بالاعتبار عامل الوقت Timestamp الذي قام المستخدم فيه بتقييم العنصر، ونقارنه مع الوقت الحالي من حيث طول المدّة، يعبر طول المدّة عن مدى حداثة أو عمر التقييم، ومن ثم نضيف وزن للتقييم، بحسب المسافة الزمنية عن الوقت الحالي للمستخدم الهدف، باستخدام تابع انحلال زمني معيّن Time Decay Function. و اعتمدنا في المقاربة الثانية على مفهوم التشابه المدرك للزمن Time-Aware Similarity في إيجاد المستخدمين المتشابهين باستخدام مفهوم النافذة الزمنية المنزلقة Sliding Window، أما في المقاربة الثالثة فاعتمدنا على بناء شجرة السياق الزمني، وإيجاد التشابه بين المستخدمين بالاعتماد على هذه الشجرة Time Context-Based Similarity. وقمنا في المقاربة الرابعة والأخيرة ببناء نظام يعتمد على عامل المصفوفة Matrix Factorization (MF)، والتعلّم العميق Neural-TARS Recommendation System، الذي يقوم بشكل رئيسي باستخراج الميزات الضمنية لكل من المستخدمين والعناصر، وإضافة السياق الزمني أثناء تدريب الشبكة العصبونية لتحسين دقة التنبؤ.

جرى تنفيذ المقاربات الأربع على نفس مجموعة البيانات، واستخدمنا لتقييم أداء هذه المقاربات عدّة معايير مثل معيار الدقّة التنبؤية، ومعايير دقّة الترتيب.



## الفصل الثاني

نستعرض في هذا الفصل الإطار النظري الذي يندرج ضمنه البحث، بدءاً من تعريف نظم التوصية ومعمارياتها، وصولاً إلى آخر ماتوصلت إليه الأبحاث في هذا المجال

## 1.2 مقدمة

في عام 1992 قام كل من Belkin and Croft بتحليل ومقارنة عملية استرجاع المعلومات Information Retrieval بعملية تصفية المعلومات Information Filtering، ويشير استرجاع المعلومات إلى اختيار البيانات من مجموعة بيانات ثابتة، بينما تشير تصفية المعلومات إلى اختيار المعلومات ذات الصلة، أو رفض المعلومات غير ذات الصلة من دفق بيانات واردة. تهتم أنظمة الاسترجاع عمومًا بتلبية احتياجات المستخدم من المعلومات لمرة واحدة، بناء على استعلام Query معين كما في محرّكات البحث، بينما يتم تطبيق أنظمة التصفية للحصول على المعلومات الخاصة باهتمامات المستخدم على المدى الطويل، بناء على الملفات الشخصية لهم (User Profile (UP، وكما هو معروف تعتبر عملية استرجاع المعلومات التقنية الأساسية لمحرك البحث، بينما يعتمد نظام التوصية بشكل أساسي على تقنية تصفية (ترشيح) المعلومات [8]. قام كل من Goldberg بنفس العام، بالتعاون مع مجموعة من الباحثين بتقديم أول دراسة لنظام تصفية معلومات يعتمد على الترشيح التعاوني من خلال التقييم البشري [9]. واعتماداً على هذه الدراسة، قام بعض الباحثين من معهد ماساتشوستس للتكنولوجيا (MIT) وجامعة مينيسوتا (UMN) بتطوير نظام توصية للأخبار News RS والتي عرف فيما بعد باسم GroupLens الشهير، وكان المكوّن الرئيسي لهذا النظام هو نموذج ترشيح تعاوني بين المستخدم والمستخدم User-User CF. أسس البروفيسور John Riedl مختبراً للبحوث في UMN، أطلق عليه اسم GroupLens، وهو أول مختبر رائد في دراسات وأبحاث نظم التوصية [10]. قدّمت شركة Net Perceptions لأول مرة محرك توصية تسويقي في عام 1996 [11]. وفي خريف عام 1997، أطلق مختبر أبحاث GroupLens مشروع MovieLens وقام بتدريب الإصدار الأول من نموذج التوصية باستخدام مجموعة بيانات EveryMovie. وبعد ذلك، تم إصدار العديد من مجموعات بيانات MovieLens بشكل مستمر خلال الفترة من 1998 إلى 2019، وأصبحت واحدة من أكثر مجموعات البيانات شيوعاً للدراسات المتعلقة بالتوصية. ومنذ 1996، شهدت الدراسات الأكاديمية، والتطبيقات العملية الصناعية لنظم التوصية تقدماً كبيراً، بالتوازي مع تطوّر شبكة الإنترنت حول العالم.

## 2.2 آراء المستخدمين في نظم التوصية

تُعرّف آراء المستخدمين في نظام التوصية على أنها مدخلات تعبر عن اهتمام مستخدم بالعنصر، وهي الركيزة الأساسية التي يستند عليها نظام التوصية في تقديم الاقتراحات للمستخدمين. تصنّف آراء المستخدمين إلى نوعين وفقاً لكيفية الحصول عليها.

### 1.2.2 آراء صريحة

يتطلب هذا النوع مشاركة المستخدم النشطة، ويحصل نظام التوصية عليها من المستخدم بشكل مباشر. على سبيل المثال في الأنظمة التي تعتمد على المعلومات الديموغرافية أو الشخصية، قد يتخذ تفاعل المستخدم شكل المشاركة في استطلاعات عبر شبكة الإنترنت في وقت تسجيل الدخول Sign Up، أو تقديم معلومات شخصية ومالية أثناء عملية الشراء في موقع تجارة الكترونية E-Commerce (لندمج مع البيانات الديموغرافية غير المتصلة بالإنترنت)، وللآراء الصريحة عدّة أشكال، أكثرها شيوعاً التقييم كنقاط أو نجوم (5-Points Likert Scale) مثل مواقع التجارة الإلكترونية، حيث يعبر المستخدم بدقة أكبر عن مدى إعجابه بالعنصر، وهناك أشكال ثانية منها التعبير عن (إعجاب - عدم إعجاب)، ويكثر هذا النمط في مواقع التواصل الاجتماعي (Facebook - Youtube)، حيث يعبر المستخدم بقيمة واحدة عن مدى تفضيله لعنصر ما.

### 2.2.2 آراء ضمنية

تتمثل ميزة استخدام الآراء الضمنية في تحديد سمات المستخدم، في أنها تزيل العبء المرتبط بتحصيل المعلومات الشخصية من المستخدم، كما أنها متوقّرة دوماً ويسهل الحصول عليها؛ حيث يجمع النظام بنفسه البيانات ذات الصلة، بناءً على سلوك وتفاعل المستخدمين الملحوظ، ومن ثم يستنتج المعلومات الخاصة بالمستخدم. يسمّى هذا بالتنميط الضمني Implicit Profiling، وتعني قدرة النظام على تتبع ومراقبة سلوك المستخدم، من أجل تحديد أنماط التصفح أو الشراء. يمكن جمع البيانات الضمنية من المستخدم نفسه Client-Side أو من المخدم Server-Side.

بشكل عام تكون الآراء الصريحة أكثر دقة من الآراء الضمنية. حيث يعتمد نظام تحصيل الآراء الضمني على تطبيق الأدوات والمنهجيات المستندة إلى المجال المطبق Domain Relevant، لالتقاط وتفسير الملاحظات الضمنية، وعادةً ما يلاحظ النظام سلوك مستخدم ما، ويضع استنتاجات حول اهتمامات المستخدم بناءً على هذا السلوك. على سبيل المثال، في نظم التوصية الموسيقية مثل Last.fm، إذا استمع المستخدم إلى مقطع صوتي خمس مرّات، يستنتج النظام أن المستخدم لديه اهتمام بهذا النوع من المقاطع الصوتية. من وجهة نظر مختلفة في الآراء الصريحة النموذجية، سيقدّم المستخدم تصنيفات للعناصر على مقياس Likert وعادةً ما ينتقل مقياس التصنيف من "يعجبني كثيراً" إلى "لا يعجبني". وبالتالي فإن الآراء الصريحة تلتقط تفضيلات المستخدم الإيجابية والسلبية. من ناحية أخرى، يمكن أن تكون الآراء الضمنية إيجابية فقط. على سبيل المثال، إذا لم يستمع المستخدم إلى مقطع صوتي، لا يعني ذلك أنه لا يحب هذا المقطع أو هذا النوع من الموسيقى.

## 2.3 أنواع نظم التوصية (من وجهة نظر معمارية وخوارزمية)

### 1.3.2 نظم التوصية المعتمدة على القواعد Rule-Based RS

يعتمد هذا النوع على قواعد قرار يتم إنشاؤها يدويًا أو تلقائيًا، ومن ثم تُستخدم للتوصية بالعناصر للمستخدمين، ينتشر هذا النوع في نظم التوصية المتعلقة بالتجارة الإلكترونية E-Commerce، التي تسمح لخبراء المجال بتحديد القواعد، والتي غالبًا ما تستند إلى العوامل الديموغرافية، أو النفسية، أو الشخصية، على سبيل المثال، في موقع شراء الملابس، يوصي الخبراء بتوصية ملابس معينة في شرق آسيا تختلف عن أوروبا أو الولايات المتحدة؛ لذلك يعتمد هذا النوع بشكل كبير على المجال الذي يوضع فيه نظام التوصية. كما يستند هذا النوع من التخصيص، مثل معظم الأنظمة المستندة إلى القواعد، بشكل كبير على هندسة المعرفة، لبناء قواعد وفقًا للخصائص المحددة للمجال أو أبحاث السوق، وتنبثق العيوب الأساسية لتقنيات التوصية المستندة إلى القواعد (دون ذكر مشكلة عنق الزجاجة الموجودة في هندسة المعرفة) من الأساليب المستخدمة لإنشاء ملفات تعريف المستخدمين، حيث عادةً ما يكون الإدخال هو الوصف الشخصي للمستخدمين أو اهتماماتهم المسبقة المبنية على معرفة بالبيئة الديموغرافية، لذا يكون النظام عرضة بشكل كبير للتحيز، إضافة على ذلك، غالبًا ما تكون ملفات المستخدمين ثابتة، مما يؤدي إلى تدهور أداء النظام بمرور الوقت مع تقدم هذه الملفات [2].

### 2.3.2 نظم التوصية المعتمدة على المحتوى CB-RS:

يُشار إلى هذا النوع أحيانًا بالتصفية المعرفية، ويعتمد على توصيف العناصر المستخدمة في عملية التوصية Item Description، حيث يتم تمثيل العناصر أو المنتجات التي تفاعل معها المستخدم في الماضي باستخدام مجموعة من الميزات أو الواصفات التي تميّز عنصر ما عن سواه، ومن ثم يقوم النظام بإنشاء ملف تعريف المستخدم UP، للتعبير عن نوع العنصر الذي يحبه (ملف تعريف الخيارات المفضلة User-Preferred Choices)، يتضمن ميزات العناصر التي أبدى اهتمامًا سابقًا بها. الافتراض الرئيسي للتصفية القائمة على المحتوى هو أن المستخدم سيحب بدرجة ما عنصرًا مشابهًا لعنصر أحبه في الماضي، تتضمن مهمة إنشاء التوصيات مقارنة الميزات المستخرجة من العناصر غير المرئية أو غير المصنفة مع أوصاف المحتوى في ملف تعريف المستخدم؛ حيث يوصى المستخدم بالعناصر التي تعتبر مشابهة بدرجة كافية لملف تعريفه [3]. في معظم أنظمة التوصية المستندة إلى المحتوى، لا سيّما تلك المستخدمة في الويب وتطبيقات التجارة الإلكترونية، تكون واصفات العناصر عبارة عن ميزات نصية مستخرجة من صفحات الويب أو أوصاف المنتج، لذلك تعتمد هذه الأنظمة اعتمادًا وثيقًا على تقنيات استرجاع المعلومات [12]. وتصفية المعلومات [8]. عادةً يتم تمثيل ملفات تعريف المستخدمين والعناصر باستخدام متجهات حدود موزونة بالاعتماد على تقنية TF-IDF ومنه يمكن استخراج تنبؤات اهتمام المستخدم بعنصر معين بناءً على حساب أوجه التشابه بين المتجهات، إما باستخدام مقاييس التشابه المعيارية (سنتكلم عنها لاحقاً) أو باستخدام الأساليب الاحتمالية مثل تصنيف Bayes الاحتمالي، وتكون ملفات المستخدمين والعناصر مستقلة بطبيعتها أي أنها مبنية فقط من العناصر التي تفاعل معها المستخدم دون ارتباط مع عناصر أو مستخدمين آخرين؛ ومن أهم ميزات هذا النوع من التوصية هو أنه جيد للتوصية بالعناصر التي لم يتم تصنيفها من قبل أي مستخدم في النظام New Items. لكن يعاني هذا النوع من عدّة قيود وهي:

## 1. التخصيص الزائد للمحتوى Over-Specialization:

بسبب آلية عمل نظم التوصية المعتمدة على المحتوى، فإن العنصر الموصى به للمستخدم يعتمد فقط على العناصر المعروفة مسبقًا والمحددة ضمن ملف تعريف المستخدم، مما يؤدي إلى بقاء المستخدم ضمن دائرة العناصر المشابهة للعناصر التي تم تصنيفها مسبقًا فقط، دون اكتشاف أي عناصر جديدة أو خيارات أخرى متاحة قد تكون مفيدة للمستخدم [13]. وتُعرف أيضاً بمشكلة الافتقار للمصادفة "Lack of Serendipity" وهي ميل نظم التوصية لتقديم محتوى يفتقر للإبداع دون تقديم توصيات جديدة مبتكرة ومفاجئة. أشار Eli Pariser في كتابه "The Filter Bubble" إلى هذه المشكلة، الموجودة في وسائل التواصل الاجتماعي Social Media، وأطلق عليها اسم "Filter Bubble" وتنتج عن عمليات البحث المخصصة، عندما تخمن خوارزمية البحث ضمن موقع وب بشكل انتقائي المعلومات التي يرغب المستخدم في رؤيتها، بناءً على معلومات سابقة حوله (مثل الموقع وسلوك النقر السابق وسجل البحث). ونتيجة لذلك يفصل المستخدمون عن المعلومات التي لا تتفق مع وجهات نظرهم، مما يؤدي إلى عزلهم فعلياً في فقاعاتهم الثقافية أو الإيديولوجية [14]. تقدم الخوارزميات الجينية حلاً جزئياً لهذه المشكلة، حيث قدّم [15] نظام توصية عصري يعتمد الخوارزميات الجينية للتغلب على مشكلة التخصيص الزائد في هذا النوع من نظم التوصية.

## 2. البداية أو الإقلاع البارد لمستخدم جديد New User Cold-Start:

في هذا النوع من نظم التوصية يجب جمع عدد كبير من التصنيفات لإنشاء ملف المستخدم ضمن النظام، والذي يمكنه التعرف على تفضيلات المستخدم؛ ونظرًا لعدم توفر بيانات سابقة في المستخدم الجديد، فإن النظام غير قادر على تقديم اقتراحات جديدة بالثقة له [15].

## 3. التحليل المقيّد للمحتوى Limited Content Analysis:

نظرًا لكون تمثيل المحتوى في هذا النوع من نظم التوصية يتم من خلال السمات الذاتية، والتي غالبًا ما تستخرج بالاعتماد على تقنيات استرجاع المعلومات، لذا يجب أن تحتوي العناصر التي تتم معالجتها على معلومات كافية لاستخدامها في التمييز بين التي يحبها، أو لا يحبها المستخدم. كما أن تمثيل هذه العناصر باستخدام الميزات النصية المستخرجة مثل معيار TF-IDF، قد لا تكون عملية دائمًا نظرًا للطبيعة غير المتجانسة للبيانات (صورة - مقطع فيديو - نص)، وهناك مشكلة تمثيل عنصرين مختلفين بنفس مجموعة الميزات (على سبيل المثال، تمثيل المقالات البحثية بنفس مجموعة الكلمات الرئيسية أو المفتاحية سيؤدي إلى صعوبة تمييز المكتوبة جيدًا عن المكتوبة بشكل سيء). غالبًا ما يؤدي التحليل المقيّد للمحتوى إلى مشكلة التخصيص الزائد للمحتوى التي دُكرت سابقًا [16].

### 3.3.2 نظم التوصية القائمة على الترشيح التعاوني CF-RS

وتعرف بأنها نظم تصفية وتقييم العناصر بالاعتماد على آراء الآخرين، تُرجع جذور مصطلح التصفية التعاونية لأكثر من عقدين بقليل، إلا أن فكرة التصفية التعاونية تنبع من شيء كان البشر يفعلونه لقرون، وهو مشاركة الآراء مع الآخرين، حيث وقف الناس لسنوات، في المكاتب وناقشوا الكتب التي قرؤوها، والمطاعم التي ارتادوها، والأفلام التي شاهدوها، ثم استخدموا هذه المناقشات لتكوين آراء. على سبيل المثال، عندما يقول عدد كافٍ من زملاء Amy أنهم أحبوا أحدث إصدار من الأفلام، فقد ترغب أن تطلع عليها أيضًا. وبالمثل إذا وجد الكثير منهم أنها ليست جيدة بالمشاهدة، فقد تقرر إنفاق أموالها في مكان آخر.

بشكل أساسي يعتمد هذا النوع على جمع وتحليل البيانات المتعلقة بسلوك المستخدم السابق User Behavior، المتضمن أنشطة المستخدم عبر الإنترنت (مثل تعليقاتهم وتقييماتهم وتفضيلاتهم)، وبناءً على هذه المعلومات، يقوم بإيجاد أوجه التشابه بينه وبين المستخدمين الآخرين، للتنبؤ بالتقييمات المفقودة وبالتالي تقديم توصيات مناسبة [17]. أول نظام يعتمد الترشيح التعاوني هو نظام Tapestry، الذي تم تطويره في Xerox PARC، الخطوة الأولى لتحقيق التصفية التعاونية ضمنه هي بدمج آراء المستخدم الصريحة في قاعدة بيانات الرسائل، ونظام البحث [9]، قام Tapestry بتخزين محتويات الرسائل، جنبًا إلى جنب مع البيانات الوصفية حول المؤلفين والقراء. كما سمح لأي مستخدم بتخزين التعليقات التوضيحية حول الرسائل مثل ("محتوى مفيد"، "يجب الاطلاع عليه") أصبح هذا النموذج يُعرف باسم التصفية التعاونية القائمة على السحب النشط Pull Active، لأنه تقع على عاتق المستخدم الذي يرغب في الحصول على توصيات، سحب هذه التوصيات من قواعد البيانات بشكل مباشر (آراء المستخدمين وتعليقاتهم).

بعد فترة وجيزة من ظهور Tapestry، طور Ehrlich و Maltz [18] نظام توصية يعتمد الدفع النشط Push Active، سهّل على الشخص الذي يقرأ مستند تقديم هذا المستند إلى الآخرين الذين يجب أن يطلعوا عليه. وأصبح هذا النوع شائعًا، حيث يعمل العديد من الأشخاص اليوم على قراءة الكتب والمقالات من جميع أنحاء العالم، ومن ثم إرسالها إلى من يعتقدون أنهم سيفضّلون هذه الكتب. بشكل أساسي يتمثل أحد قيود أنظمة التصفية التعاونية النشطة، في أنها تتطلب مجتمعا من الأشخاص الذين يعرفون بعضهم البعض. كما تتطلب أنظمة السحب النشطة Pull Active أن يعرف المستخدم من يثق في آرائه؛ بينما تتطلب أنظمة الدفع النشط Push Active أن يعرف المستخدم لمن قد يكون محتوى معينًا مثيرًا للاهتمام. شكّلت كل من GroupLens [10,4] في مجال مقالات مجموعات أخبار Usenet، و Ringo [19] في مجال الموسيقى والفنانين الموسيقيين، ومرشح الفيديو من Bellcore [20] في مجال الأفلام، أوائل الأنظمة التي استخدمت الترشيح التعاوني بشكل صريح.

تصنف خوارزميات الترشيح التعاوني إلى صنفين:

✚ خوارزميات الترشيح التعاوني غير الاحتمالية Non-Probabilistic Algorithms

1. الترشيح التعاوني المعتمد على الذاكرة Memory-Based CF أو المعتمد على الجوار

Neighborhoo d-Based

2. الترشيح التعاوني المعتمد على النموذج Model-Based CF

✚ خوارزميات الترشيح التعاوني الاحتمالية Probabilistic Algorithms

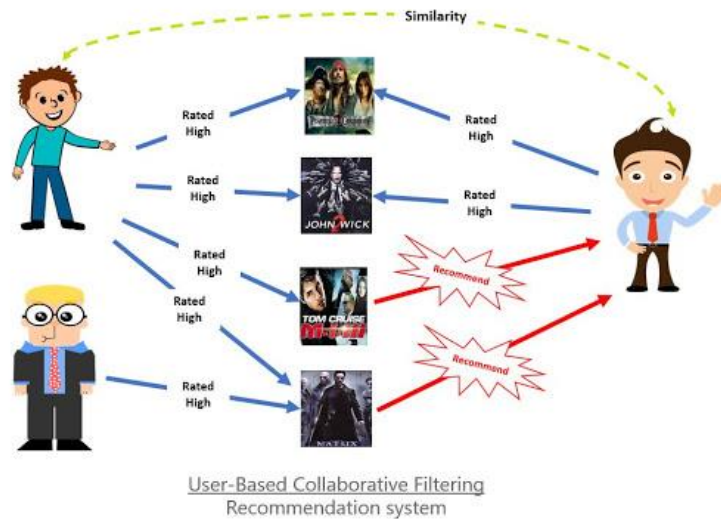
### 1.3.3.2 الترشيح التعاوني المعتمد على الذاكرة

وهي النوع الأكثر شيوعاً من نظم التوصية، ونعني بالذاكرة الذاكرة الرئيسية لأداة الحوسبة، أو أي نوع من وحدات التخزين العاملة التي قد يمتلكها الحاسب. تكون قاعدة بيانات عناصر المستخدم بأكملها في الذاكرة، ومن ثم يتم استخدامها مباشرة لإنشاء التوصية، اعتمدت بشكل واسع في التطبيقات التجارية. تُقسّم طرق الترشيح التعاوني المعتمد على الذاكرة إلى نوعين رئيسيين هما: الترشيح التعاوني المعتمد على المستخدم، والترشيح التعاوني المعتمد على العنصر. بشكل عام يأخذ الترشيح المعتمد على المستخدم مستخدماً معيناً، وتبحث عن مستخدمين مشابهين لذلك المستخدم بناءً على تشابه التفضيلات فيما بينهم، وتوصي بالعناصر التي يحبها هؤلاء المستخدمين المماثلون. في المقابل، ستأخذ تصفية العناصر عنصراً، وتبحث عن المستخدمين الذين أحبوا هذا العنصر، ومن ثم تبحث عن العناصر الأخرى التي أحبها أيضاً هؤلاء المستخدمين أو المستخدمين المماثلون؛ يأخذ هذا النوع كدخل عناصر والمخرجات تكون عناصر أخرى كتوصيات. يمكن تلخيص النوعين بالشكلين التاليين:

- ➡ الترشيح التعاوني المعتمد على العنصر: "المستخدمون الذين أحبوا هذا العنصر أيضاً أحبوا ..."
- ➡ الترشيح التعاوني المعتمد على المستخدم: "المستخدمون المشابهون لك أحبوا أيضاً ..."

### 1.1.3.3.2 الترشيح التعاوني المعتمد على المستخدم UB-CF

أنتجت الخوارزميات المبكرة للترشيح التعاوني تنبؤات للمستخدمين بناءً على تفضيلات لمستخدمين مشابهين، الشكل (2). نسمي هؤلاء المستخدمين المتشابهين بالجيران. إذا كان المستخدم  $n$  مشابهاً للمستخدم  $u$ ، فإننا نقول إن  $n$  هو جار ل  $u$ . تولّد الخوارزميات المستندة إلى المستخدم تنبؤاً لعنصر ما  $i$  بواسطة تحليل تقييمات  $i$  من المستخدمين في المنطقة المجاورة له. قدّمت خوارزمية K-Nearest Neighbors [10]، وهي خوارزمية تعلم كسولة Lazy، تعمل على فصل نقاط البيانات إلى عدة مجموعات، ومن ثم تقدّم التوصيات بالاعتماد على تفضيلات أقرب  $K$  جار للمستخدم، باستخدام معايير التشابه (التي سنذكرها لاحقاً) لا تضع KNN أي افتراضات بشأن توزيع البيانات الأساسي.



الشكل (2): الترشيح التعاوني المعتمد على المستخدم UB-RS

## معايير التشابه

المفتاح الرئيسي لعمل خوارزميات الترشيح التعاوني هو إيجاد معيار للتشابه بين المستخدمين، إضافة إلى نمذجة رياضية لاستخدام التشابه في حساب التنبؤات بالعناصر التي لم يتم تصنيفها، تم اقتراح العديد من توابع التشابه، لقياس كل من التشابه بين المستخدمين، أو العناصر، للعثور على KNN. يشار إلى هذه التوابع أحياناً باسم معاملات الارتباط. يمكن تلخيص هذه المعايير كما يلي:

### 1. المسافة الإقليدية The Euclidean distance

يتم تمثيل كل مستخدم بإحداثياته الديكارتية ويمثل كشعاع (متجه) في فضاء عناصر ذو بعد  $N$ ، التي تعبر عن التقييمات التي عبر عنها للعناصر (ونفس الشيء بالنسبة للعنصر الذي يتم تمثيله في فضاء مستخدمين ذو بعد  $N$ ) [21]، ويرمز لها بالرمز  $d$  من المستخدم  $u$  إلى المستخدم  $v$  (أو من عنصر  $i$  إلى عنصر  $j$ )، وهي طول مقطع الخط بين المستخدمين (أو العناصر) في الفضاء الإقليدي. والمسافة بين مستخدمين (أو عنصرين) هي القيمة المطلقة للفرق العددي لإحداثياتهم في الفضاء وتعطى بالعلاقة (1).

$$d(u, v) = \sqrt{\sum_{i \in I_u \cap I_v} (r_{ui} - r_{vi})^2} \quad (1)$$

I.  $I_u \cap I_v$ : تشير إلى مجموعة العناصر التي تم تصنيفها من قبل كل من  $u$  و  $v$ .

II.  $r_{ui}, r_{vi}$ : تشير إلى تصنيف المستخدم  $u$  و  $v$  للعنصر  $i$  على الترتيب.

### 2. مسافة منهاتن Manhattan Distance

يتم تمثيل كل مستخدم كما في المسافة الإقليدية، وتحسب مسافة منهاتن بين مستخدمين  $u$  و  $v$  على أنها التنظيم الأول بين شعاعي  $u$  و  $v$  [21]، وتعطى بالعلاقة (2).

$$d(u, v) = \sum_{i \in I_u \cap I_v} |r_{ui} - r_{vi}| \quad (2)$$

### 3. مؤشر Jaccard:

يحسب مؤشر Jaccard المشار إليه بالرمز  $J$ ، التشابه والتنوع بين مجموعتين. يُعرّف معامل Jaccard بين مجموعتين متناهيتين، على أنه عدد عناصر تقاطع المجموعتين على عدد عناصر الاجتماع. وهذا يعني أنه يقاس نسبة عدد العناصر المشتركة بين المجموعتين إلى العدد الإجمالي للعناصر في كلتا المجموعتين. يأخذ الفهرس  $J$  قيمة بين 0 و 1، وكلما اقترب الفهرس من 1، كانت المجموعتان أكثر تشابهاً [21] ويعطى مؤشر Jaccard بالعلاقة (3).

$$J(u, v) = \frac{|I_u \cap I_v|}{|I_u \cup I_v|} \quad (3)$$

I.  $I_u \cap I_v$ : تشير إلى مجموعة العناصر التي تم تصنيفها من قبل كل من  $u$  و  $v$ .

II.  $I_u \cup I_v$ : تشير إلى اجتماع مجموعة العناصر التي صنّفها  $u$  مع مجموعة العناصر التي صنّفها  $v$ .

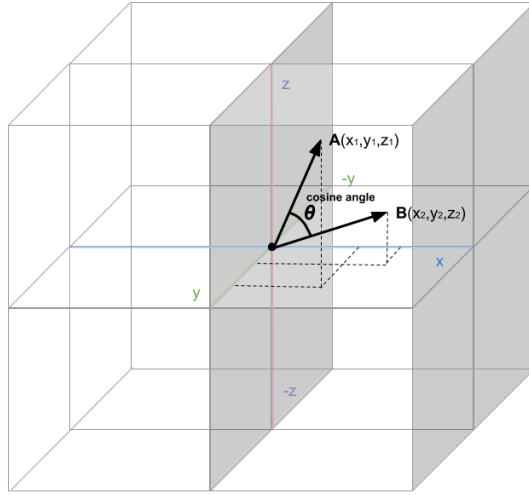
III.  $||$ : تشير إلى cardinality وهو عدد عناصر المجموعة. بالاستناد إلى جبر المجموعات

$$J(u, v) = \frac{|I_u \cap I_v|}{|I_u| + |I_v| - |I_u \cap I_v|} \quad \text{يمكن أن يكتب مؤشر Jaccard بالشكل:}$$

#### 4. تشابه المتجهات - جيب التمام (Cosine Similarity) Vector similarity

في هذه التقنية أيضًا، يتم تمثيل المستخدم كمتجه، كما في معيار المسافة الإقليدية، ويعبّر عن التشابه بجيب التمام بين متجهين يمثلان مستخدمين (أو عنصرين) الشكل (3). ويأخذ القيم في المجال [0,1]، حيث تشير القيمة 1 إلى تشابه تام بينهما، أما القيمة 0 فتعني عدم وجود أي ارتباط؛ يعطى التشابه بالعلاقة (4) كما يلي [22]:

$$\text{Cos}(\mathbf{u}, \mathbf{v}) = \frac{\sum_{i \in I_u \cap I_v} r_{ui} \cdot r_{vi}}{\sqrt{\sum_{i \in I_u} r_{ui}^2} \sqrt{\sum_{i \in I_v} r_{vi}^2}} \quad (4)$$



الشكل (3): تشابه المتجهات في فضاء ثلاثي الأبعاد (تمثيل المستخدمين كشعاع بثلاث إحداثيات تمثل تقييم مسبق من المستخدمين لثلاثة عناصر ضمن نظام التوصية)

#### 5. معامل ارتباط بيرسون (Pearson Correlation Coefficient (PCC):

اقترح هذا المقياس كارل بيرسون (1895 م)، لقياس العلاقات الخطية، وأصبح مستخدمًا على نطاق واسع في مجال الإحصاء. يأخذ PCC قيمه في المجال [-1,1] يشير 1 إلى ارتباط إيجابي قوي، يشير -1 إلى ارتباط سلبي قوي، و 0 إلى عدم وجود ارتباط على الإطلاق [10] Resnick et al.، وله الصيغة الممثلة بالعلاقة (5):

$$\text{PCC}(\mathbf{u}, \mathbf{v}) = \frac{\sum_{i \in I_u \cap I_v} (r_{ui} - \bar{r}_u) \cdot (r_{vi} - \bar{r}_v)}{\sqrt{\sum_{i \in I_u} (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_{i \in I_v} (r_{vi} - \bar{r}_v)^2}} \quad (5)$$

$\bar{r}_u, \bar{r}_v$ : تعبر عن متوسط التقييمات لكل من المستخدمين  $u$  و  $v$ .

## 6. صيغة المعلومات المتبادلة (صيغة Shannon):

وفقًا لـ Shannon، فإن المعلومات المتبادلة (MI) هي مقياس شائع الاستخدام في مجال نظرية المعلومات (Shannon [23]). في حالتنا، يتم استخدام MI لحساب الاعتماد الإحصائي بين مستخدمين  $u$  و  $v$  ([24] Vinh et al). للقيام بذلك، يتم تمثيل المستخدم كمتجه في الإحداثيات الديكارتية بأساس العناصر التي تم تقييمها من قبله، ويتم تمثيل العنصر كمتجه في الإحداثيات الديكارتية بأساس المستخدمين الذين قيموا هذا العنصر. صيغة MI التي تمثل الارتباط بين مستخدمين  $u$  و  $v$  هي كما في العلاقة (6):

$$MI(u, v) = \sum_{i \in I_u} \sum_{i \in I_v} P(r_{ui}, r_{vi}) \log \frac{P(r_{ui}, r_{vi})}{P(r_{ui})P(r_{vi})} \quad (6)$$

•  $P(X)$ : يعبر عن التوزيع الاحتمالي لمتغير عشوائي  $X$  يأخذ قيمه في مجموعة  $X = \{x_1, x_2, \dots, x_n\}$

### حساب التشابه Ratings Prediction

من أجل التنبؤ بتقييم المستخدم لعنصر ما، تم اقتراح العديد من المقاييس. المقياس الأكثر استخدامًا في هذا المجال هو طريقة المجموع الموزون [31]، كما هو موضح في العلاقة (7):

$$\tilde{r}(u, i) = \frac{\sum_{v \in N_u^i} Sim_{uv} * (r_{vi})}{\sum_{v \in N_u^i} |Sim_{uv}|} \quad (7)$$

•  $N_u^i$ : تعبر عن مجموعة الجيران (المستخدمين) الأكثر تشابهًا، تكون قيمها فوق عتبة معينة Threshold وفق معيار تشابه معين، أي تعبر عن Top-N الأكثر تشابهًا مع المستخدم  $u$ ، الذين قاموا بتقييم العنصر  $i$ ، ويعبر  $v$  عن مستخدم ينتمي إلى  $N_u^i$  بينما  $Sim_{uv}$  تعبر عن قيمة التشابه بين  $u$  و  $v$  باستخدام إحدى معايير التشابه السابقة.

قدّم [26] طريقة الوسطي المركزي لحساب التقييم وفق العلاقة (8):

$$\tilde{r}(u, i) = \bar{r}(u, i) + \frac{\sum_{v \in N_u^i} Sim_{uv} * (r_{vi} - \bar{r}_{vi})}{\sum_{v \in N_u^i} |Sim_{uv}|} \quad (8)$$

يعاني الترشيح التعاوني المعتمد على المستخدم من عدّة سلبيات نذكر منها:

### 1. تناثر البيانات Data Sparsity

في معظم نظم التوصية، لا يقوم المستخدمون عمليًا بتقييم كل العناصر في النظام، حيث يتركز عدد كبير من المستخدمين على عدد قليل من العناصر (في تطبيقات التجارة الإلكترونية يشتري المستخدمون النشطون أقل من 1% من العناصر)، بالتالي لايمسّ المستخدمون كمية كافية من العناصر. نسّمّي هذا الفراغ من تفاعل المستخدم مع العناصر بمشكلة التشتت (تناثر البيانات). توجد عدة طرق لحل هذه المشكلة سنأتي على ذكرها لاحقًا.

## 2. التوسعية Scalability

تؤدي زيادة عدد المستخدمين والعناصر في نظم التوصية، إلى زيادة عدد الجيران  $K$ ، الذين نعتبرهم (الأكثر تشابهاً)، لكن ستعاني خوارزمية الترشيح التعاوني المعتمدة على المستخدم من مشاكل توسع، تتمثل بحاجتها لموارد حاسوبية كبيرة لمعالجة الكم الهائل من البيانات، وتصبح غير قادرة على الاستجابة الفورية بالزمن الحقيقي وتقديم توصيات دقيقة للمستخدمين.

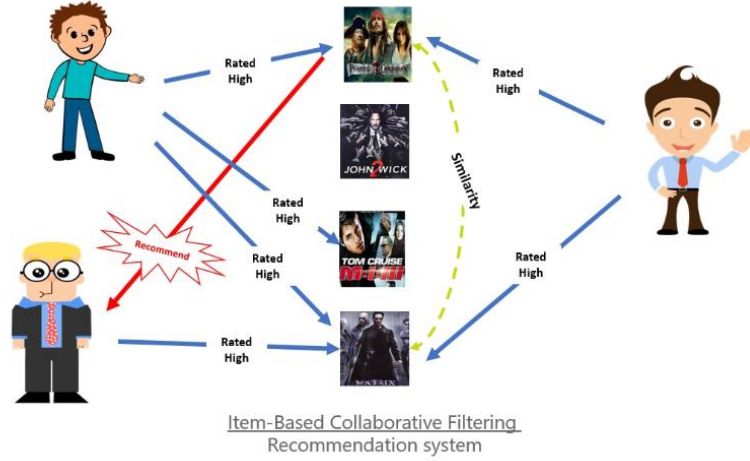
### 3. البداية أو الإقلاع البارد لمستخدم وعنصر جديدين Cold Start:

**مستخدم جديد:** في حالة المستخدمين الجدد، ستكون المعلومات قليلة عنهم ضمن النظام والتي يمكن مقارنتها بالمستخدمين الآخرين مما ينتج عنه توصية غير دقيقة لهم.

**عنصر جديد:** مثل حالة مستخدم جديد، ستفتقر العناصر الجديدة إلى التقييمات اللازمة لإنشاء توصية دقيقة لها.

#### 2.1.3.3.2 الترشيح التعاوني المعتمد على العنصر IB-CF

أظهر الترشيح التعاوني المعتمد على المستخدم فعالية كبيرة في حساب التقييمات، لكن مشكلة التوسع التي يعاني منها نظراً للكلفة الزمنية الكبيرة في تقديم التوصيات، جعلت من هذه التقنية غير قادرة على تلبية احتياجات الشركات إلا في حالة الموارد الحاسوبية الكبيرة؛ (في حالة KNN من أجل عدد مستخدمين  $N$  وعدد عناصر  $M$  يكون التعقيد الزمني لبناء النموذج المعتمد على الذاكرة، بفرض قيم التشابه غير محسوبة مسبقاً من رتبة  $O(K * N^2 * M)$ ، والتعقيد الزمني لحساب التنبؤ  $O(K * N * M)$  لكل المستخدمين، لذلك تم اقتراح تقنية الترشيح التعاوني المعتمد على العنصر [28,27]، وبعد استخدامها من قبل Amazon [29]، أصبحت شائعة الاستخدام اليوم. بشكل رئيسي، يبحث النهج المعتمد على العنصر في مجموعة العناصر التي قام المستخدم المستهدف بتقييمها، ويحسب مدى تشابهها مع العنصر الهدف Target Item، ثم يختار  $K$  أكثر عنصر تشابهاً  $\{i_1, i_2, \dots, i_m\}$ ، بالإضافة إلى قيم تشابههم مع العنصر الهدف  $\{s_{i_1}, s_{i_2}, \dots, s_{i_m}\}$ . على الرغم من أن هذه الطريقة تبحث في مجموعة العناصر، إلا أنها لا تشبه طريقة الترشيح القائمة على المحتوى، حيث يعتمد الترشيح القائم على المحتوى على البحث في ميزات العناصر نفسها، على العكس من الترشيح التعاوني القائم على العنصر، الذي يبحث عن العناصر المشابهة بالاعتماد على تقييم المستخدم لهذه العناصر بدلاً من ميزاتها. الشكل (4):



الشكل (4): الترشيح التعاوني المعتمد على العنصر

الفكرة الأساسية في حساب التشابه بين عنصرين  $i$  و  $j$  هي عزل المستخدمين الذين صنفوا هذين العنصرين أولاً، ثم تطبيق معيار تشابه معين من المعايير المذكورة سابقاً، لحساب التشابه بين هذين العنصرين  $S_{i,j}$  بالاعتماد على تقييم المستخدمين، نعرّف على سبيل المثال معيار PCC بين عنصرين وفق العلاقة (9):

$$PCC(i, j) = \frac{\sum_{u \in U_{i,j}} (R_{ui} - \bar{R}_i) \cdot (R_{uj} - \bar{R}_j)}{\sqrt{\sum_{u \in U_{i,j}} (R_{ui} - \bar{R}_i)^2} \sqrt{\sum_{u \in U_{i,j}} (R_{uj} - \bar{R}_j)^2}} \quad (9)$$

وتكون قيم التشابه وفق PCC في المجال  $[-1, 1]$  تعبر 1 عن ارتباط إيجابي تام و -1 عن ارتباط سلبي تام كما في حالة المستخدمين تماماً. في الخطوة اللاحقة، يتم إيجاد أكثر  $K$  عنصر مشابه، ثم يتم حساب التقييم وفق طريق المجموع الموزون العلاقة (10):

$$\tilde{r}(u, j) = \frac{\sum_{i \in N_u^j} Sim_{ij} * (r_{ui})}{\sum_{i \in N_u^j} |Sim_{ij}|} \quad (10)$$

I.  $N_u^j$ : تعبر عن مجموعة العناصر الأكثر تشابهاً مع العنصر  $i$ ، والتي قيمها المستخدم  $u$ .

II.  $Sim_{ij}$ : قيمة التشابه بين العنصرين  $i$  و  $j$ .

III.  $r_{ui}$ : تقييم المستخدم  $u$  للعنصر  $i$ .

من الجدير بالذكر أنه في مواقع التجارة الالكترونية الكبيرة، تمثل عملية إنشاء الجوار في حالة الترشيح التعاوني المعتمد على المستخدم، لاسيّما عند حساب التشابه بين المستخدمين عنق الزجاجة في الأداء، لذلك تبدو تقنيات الترشيح التعاوني المعتمدة على العنصر أكثر قابلية للتوسع.

على الرغم من نجاح تقنية الترشيح التعاوني المعتمد على العنصر الكبير في حساب التوصية، إضافة إلى عدم حاجتها لمعلومات كبيرة عن المجال Minimal Domain Knowledge، إلا أنها تعاني من عدة تحديات نذكر منها:

### 1. مشكلة الإقلاع البارد لمستخدم وعنصر جديدين.


2. مشكلة الافتقار للمصادفة "Lack of Serendipity" في حالة الترشيح المعتمد على العنصر نظرًا لأن هذه التقنية تعتمد على حساب التشابه بين العناصر التي قام المستخدم بتقييمها سابقًا؛ لذلك تعاني من عدم القدرة على إيجاد عناصر جديدة غير مشابهة للعناصر السابقة، والتي قد تكون مفيدة للمستخدم.

### 3. عدم تضمين مميزات العناصر الجانبية Side Features

نظم الترشيح التعاوني التقليدية لا تتضمن مميزات جانبية للعناصر (في حالة الأفلام قد تتضمن المميزات الجانبية بلد وعمر الفيلم أو وقت المشاهدة صباحًا أم مساءً). حيث أنه يمكن لتضمين المميزات الجانبية تحسين دقة النموذج.

### 4. مشكلة نقص التنوع والذيل الطويل Lack of Diversity and Long Tail

ترتبط هذه المشكلة بمشكلة الإقلاع البارد ارتباطًا قويًا. من حيث المبدأ، من المتوقع أن يعزز الترشيح التعاوني التنوع Diversity؛ لأنه يساعد المستهلكين على اكتشاف المزيد من العناصر، لكن في بعض الأنظمة قد يفعل المستخدمون العكس تمامًا من غير قصد؛ كون هذا النهج يوصي بمنتجات بناءً على التقييمات أو المبيعات السابقة، فلن يوصي بمنتجات ذات بيانات تاريخية قليلة أو محدودة. وبالتالي المزيد من المستخدمين سيشاهدون ويشتررون منتجًا شائعًا، مما سيجعله أكثر شعبية، ويجعل العناصر الجديدة تجلس في الظل خلف العناصر الأكثر مبيعًا. تعرف هذه المشكلة بالذيل الطويل الشكل (5).



الشكل (5): الذيل الطويل لشعبية العناصر

تسمى المنتجات الموجودة على الجانب الأيسر (أو في المنطقة الزرقاء) بالمنتجات الشائعة، لأن شعبيتها أعلى من تلك الموجودة في المنطقة الخضراء أو منطقة الذيل الطويل. علاوة على ذلك، فإن المنتجات الشعبية هي منتجات تنافسية بشكل عام، فيما لا تحظى المنتجات في منطقة الذيل الطويل الخضراء بشعبية أو أنها منتجات جديدة في السوق، ناتجة عن مشكلة الإقلاع البارد لعناصر جديدة وتكون ذات تقييمات قليلة.

من الناحية العملية، في الجانب الأيمن من الرسم البياني تكون العناصر أقل تصنيفًا من تلك الموجودة في الجانب الأيسر. هذا يعني أن هناك الكثير من التقييمات المجهولة في مصفوفة التقييمات User-Item Matrix (مشكلة تباين البيانات Sparsity)، مما يؤدي ذلك في نظام التوصية المعتمد على خوارزميات الترشيح التعاوني، إلى نتائج غير دقيقة لذا تعتبر نقطة البداية للذيل الطويل (العتبة بين العناصر الشائعة وغير الشائعة) ذات أهمية كبيرة إذ يمكن أن يؤدي تحريكها بشكل صحيح في الرسم البياني، إلى زيادة التنوع في التوصيات المقدمة وتقديم عناصر أقل شعبية لكنها قد تكون مفيدة للمستخدم.

### 2.3.3.2 الترشح التعاوني المعتمد على النموذج Model-Based CF-RS

يتمثل العيب الرئيسي في التقنية القائمة على الذاكرة في الحاجة إلى تحميل قدر كبير من الذاكرة. وتصبح المشكلة خطيرة عندما تكون مصفوفة تقييمات العناصر ضخمة للغاية، في حالة وجود عدد كبير جدًا من الأشخاص الذين يستخدمون النظام. حيث يتم استهلاك الموارد الحاسوبية كثيرًا وينخفض أداء النظام؛ مما يؤدي لعدم قدرة النظام على الاستجابة لطلب المستخدم على الفور. يعمل النهج القائم على النموذج على حل مثل هذه المشاكل. هناك عدة نظم توصية تعاونية معتمدة على النموذج: نماذج بايز Bayesian Models [30,31]، ونموذج عامل المصفوفة MF، ونموذج تحليل المصفوفة إلى عوامل ونشير لها اختصارًا بنموذج تحليل القيمة المفردة (SVD) Singular Value Decomposition، ونموذج تحليل المكون الأساسي Principle Component Analysis (PCA) [32,33,34,35]، ونموذج تحليل المصفوفات الاحتمالي Probabilistic Matrix Factorization (PMF)، ونموذج العنقدة (التجميع) Clustering [36]، ونماذج التصنيف Classification، والنموذج الكامن Latent Model. سنذكر بالتفصيل نموذج العنقدة ونموذج عامل المصفوفة.

#### 1. العنقدة Clustering

يعتمد نموذج CF القائم على التجميع [37]، على افتراض أن المستخدمين في نفس المجموعة لديهم نفس الاهتمام؛ لذلك قاموا بتقييم العناصر بالمثل. يتم تقسيم المستخدمين إلى مجموعات تسمى عناقيد، ويتم تعريفها على أنها مجموعة من المستخدمين المتشابهين. يتم تمثيل المستخدم كمتجه يمثل تقييمه للعناصر  $u_i = (r_{i1}, \dots, r_{im})$ ، مقياس الاختلاف بين مستخدمين هو المسافة بين المتجهات. يمكننا استخدام مسافة مينكوفسكي (العلاقة 11) أو المسافة الإقليدية أو مانهاتن المذكورتين سابقًا.

$$d_{Minkowski}(u, v) = \sqrt[p]{\sum_{i \in I_u \cap I_v} (r_{ui} - r_{vi})^p} \quad (11)$$

كلما قلت المسافة بين  $u_1$  و  $u_2$ ، كلما كان  $u_1$  و  $u_2$  أكثر تشابهًا. يتضمن Clustering CF خطوتين:

I. تقسيم المستخدمين إلى عناقيد باستخدام الخوارزمية الشهيرة K-Means [38] كما يلي:

- a. نقوم باختيار K مستخدم بشكل عشوائي، كل منهم يمثل في البداية مركز من مراكز العناقيد K.
- b. من أجل كل مستخدم نقوم بحساب المسافة بينه وبين العناقيد، ينتمي هذا المستخدم للعنقود الأقرب إليه بمعنى آخر إذا كان المستخدم ينتمي إلى العنقود  $c_v$ ، فإن المسافة بين المستخدم  $u$  والمتوسط  $m_v$  للعنقود  $c_v$  المشار إليها  $d(u, m_v)$ ، تكون الأصغر بين كافة العناقيد.
- c. بعد ذلك، يتم إعادة حساب متوسط جميع العناقيد. إذا تم استيفاء شرط التوقف، فسيتم إنهاء الخوارزمية، وإلا يتم العودة للخطوة b.

هناك نوعان من شروط الإنهاء النموذجية (شروط التوقف) لخوارزمية K-Means:

- لا يتغير متوسط العناقيد بمعنى آخر، لا يتم تغيير العناقيد K. يشير هذا الشرط إلى مهمة تجميع مثالية للمستخدمين ضمن العناقيد.
- إذا كان معيار الخطأ (العلاقة 12) أقل من عتبة محددة مسبقاً.

$$error = \sum_{v=1}^k \sum_{u \in c_v} distance(u, m_v) \quad (12)$$

▪  $c_v$  تشير إلى العنقود v.

▪  $m_v$  تشير إلى متوسط العنقود v.

II. من أجل مستخدم جديد a يتم حساب التشابه بينه وبين كل العناقيد للعثور على أقرب مجموعة ل a، ثم نختار من هذه المجموعة أعلى m جار ندعوهم M. نقوم بحساب تقييم a للعناصر التي لم يقيّمها مسبقاً، عن طريق تجميع المتوسط المرجح للانحرافات عن المستخدمين M، ثم بعد ذلك نقوم باختيار العناصر ذات قيم التقييم العالية ونقدّمها كتوصية ل a كما في العلاقة 13:

$$Pred(a, i) = \bar{r}_a + \frac{\sum_{u \in M} Sim(a, u) \cdot (r_{ui} - \bar{r}_u)}{\sum_{u \in M} |Sim(a, u)|} \quad (13)$$

تعاني هذه الخوارزمية من مشكلة بعثرة البيانات ضمن مصفوفة التقييم (الكثير من القيم المفقودة) مما يؤدي إلى إعطاء قيم غير دقيقة.

## 2. نموذج عامل المصفوفة MF

تم اكتشاف عامل المصفوفة لزيادة أداء الترشيح التعاوني [39]، والهدف منه إيجاد مصفوفتين بأبعاد أصغر لتمثيل مصفوفة تقييم المستخدمين Rating Matrix. في نموذج عامل المصفوفة، نقوم بتحليل مصفوفة تقييم المستخدمين إلى جداء مصفوفتين، تمثّلان مصفوفتي السمات الكامنة؛ بفرض لدينا مجموعة المستخدمين U ومجموعة العناصر D، يتم تمثيل كل مستخدم وفق متجه  $p_u \in R^f$  وكل عنصر وفق متجه  $q_i \in R^f$  يمثل المتجه  $p_u$  درجة اهتمام المستخدم u بالعناصر ضمن النظام، ويمثل  $q_i$  ميّزات العنصر i. يتم التمثيل السابق ضمن فضاء العامل الكامن Latent Factor Space له البعد f، والهدف إيجاد K ميّزة كامنة، حيث K أصغر من عدد العناصر وعدد المستخدمين على حد سواء، تمثّل هذه الميزات خصائص العنصر، في

حالة الأفلام يمكن أن تكون الميزات هي النوع، والممثلين .. إلخ الشكل (6). يعبر عن تفاعل المستخدم مع العنصر كجاء داخلي في ذلك الفضاء، حيث يُحسب تقييم المستخدم  $u$  للعنصر  $i$ ، والمشار إليه بـ  $r_{ui}$  وفق العلاقة (14):

$$Pred(u, i) = f(u, i | p_u, q_i) = p_u^T \cdot q_i = \sum_{k=1}^K p_{uk} q_{ik} \quad (14)$$



الشكل (6): تمثيل مصفوفة تقييم العناصر Rating Matrix كمصفوفتي ميزات العناصر والمستخدمين.

أثناء تعلم النظام للمتجهين  $p_u$  .  $q_i$  يقلل من الخطأ التربيعي المنتظم Regularized Squared Error على النحو التالي (العلاقة 15):

$$L = \min_{q^*, p^*} \sum_{u, i \in Q} (r_{ui} - p_u^T \cdot q_i)^2 + \lambda (\|q_i\|^2 + \|p_u\|^2) \quad (15)$$

- $Q$ : تمثل مجموعة الثنائيات  $(u, i)$  حيث يكون  $r_{ui}$  معرفاً ضمن مجموعة التدريب.
- لتجنب الملائمة المفرطة Overfitting للنموذج تتم إضافة معامل تسوية  $\lambda$

تحدث الملائمة المفرطة للنموذج عندما يتعلم النموذج الضجيج في البيانات ونقص بالضجيج البيانات التالفة أو المشوهة.

### 3. نموذج عامل المصفوفة باستخدام تحليل القيمة المفردة SVD


تحليل القيمة المفردة SVD [40]، هي تقنية سائدة لتقليل أبعاد مصفوفة التقييم باستخدام العوامل الكامنة للبيانات. المفتاح الرئيسي في عمل SVD يكمن في العثور على فضاء ميّزات له بعد منخفض. يعرّف SVD للمصفوفة  $R$  التي تمثّل مصفوفة التقييم  $m \times n$  بالعلاقة 16:

$$SVD(R) = P \Sigma Q^T \quad (16)$$

حيث  $P$  و  $Q$  هما  $m \times m$  و  $n \times n$  مصفوفتين متعامدتين على التوالي، وتمثّل  $\Sigma$  مصفوفة متعامدة مفردة  $m \times n$ ، تكون عناصرها خارج القطر الرئيسي كلها أصفار وعناصرها القطرية مرتبة تنازليًا من الشكل:

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0 \quad (17)$$

وتمثّل العناصر في العلاقة 17 القيم المفردة للمصفوفة  $R$ ، بينما  $P$  و  $Q$  هما متجهات العمود التي يشار إليها باسم متجهات المفرد الأيسر ومتجهات المفرد الأيمن على الترتيب.



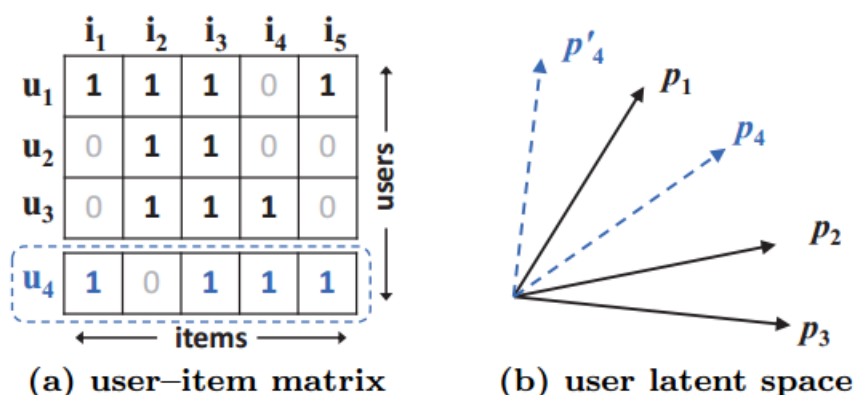
الشكل (7): عامل المصفوفة باستخدام تحليل القيمة المفردة.

#### 4. نموذج التعلّم العميق Deep Learning

على المستوى النظري، يمكن استخدام الشبكات العصبونية من تحسين دقة النموذج، والسبب هو أن لنهج عامل المصفوفة المنتظم شكل خطّي، مما يحدّ من قدرة النموذج على التعبير عن تعقيد العلاقة بشكل جيّد بين المستخدمين والعناصر. لتوضيح المشكلة بشكل أكبر، يتم نمذجة المستخدمين والعناصر في نفس فضاء العامل الكامن، ويتم حساب التقييم وفق عملية خطيّة (dot-product)، مما يعني أنه قد يتعرّض النموذج لمواقف لا يمكنه تمثيل العلاقة بين المستخدم  $u$  والمستخدم  $v$ ، بدون انتهاك العلاقة المعرّفة مسبقاً بين المستخدم  $v$  والمستخدم  $z$ . كما أنه من غير الممكن تمثيل مستخدم جديد بدقة في فضاء العامل الكامن، مع الأخذ بالاعتبار جميع تمثيلات المستخدمين الآخرين والعلاقات السابقة فيما بينهم [47]؛ وتصبح هذه المشكلة واضحة عند استخدام نموذج تقليل عدد الأبعاد الكامنة الشكل (8).

تتمثل إحدى طرق حل هذه المشكلة في زيادة أبعاد الفضاء الكامن، للسماح بمزيد من التعبير، ومنه تمثيل العلاقات الأكثر تعقيداً، لكن قد يؤثر ذلك سلبيّاً على النموذج، نتيجة الملائمة المفرطة Overfitting، خاصّة في المصفوفة شديدة التناثر Sparse Matrix [41].

لذا نلجأ لاستخدام شبكة عصبونية عميقة، والهدف تعلّم اللاخطية (من خلال استخدام توابع التنشيط غير الخطية مثل Relu) في العلاقات بين المستخدمين، وبذلك تزيد من قدرة النموذج النهائي على التعبير على العلاقات بين المستخدمين والعناصر.



الشكل (8): محدودية MF في تمثيل العلاقات

من الشكل السابق: من مصفوفة التقييم (a) نلاحظ، تشابه  $u_4$  إلى حد كبير مع  $u_1$  ومن ثم  $u_3$  وأخيراً  $u_2$ . لكن في تمثيل المستخدمين ضمن فضاء العامل الكامن (b) (بفرض  $p$  يعبر عن تمثيل المستخدم  $u$ ) وضع  $p_4$  أقرب إلى  $p_1$  يجعل  $p_4$  أقرب إلى  $p_2$  من  $p_3$ ، مما يؤدي إلى خسارة كبيرة في الترتيب.

يستند نموذج التعلم التعاوني العصبوني NCF [47] إلى تمثيل متعدد الطبقات Multi-Layer، لتفاعل المستخدم مع العنصر  $y_{ui}$ ، ويكون خرج كل طبقة في النموذج هو دخل للطبقة التي تليها. الشكل (9).

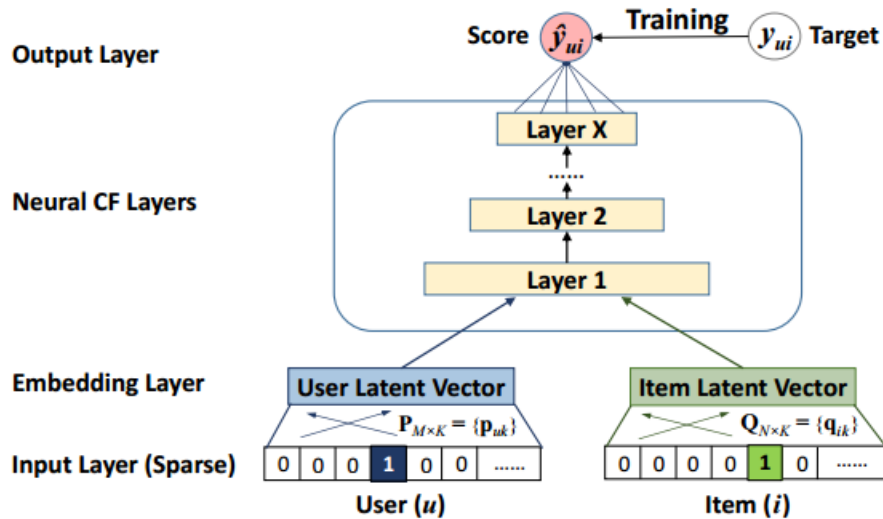
الطبقة الأولى تسمى طبقة الدخل Input Layer: وتتكون من متجهي السمات  $v_i^U$  و  $v_i^I$  اللذين يمثلان المستخدم  $u$  والعنصر  $i$ .

طبقة التضمين Embedding Layer: تلي طبقة الإدخال، وهي طبقة متصلة بالكامل، تحوّل التمثيل المتناثر لمتجهات المستخدمين والعناصر في طبقة الإدخال إلى متجهات كثيفة Dense Vector. يحدث التناثر في طبقة الإدخال بسبب تناثر البيانات في مصفوفة تقييم المستخدمين للعناصر. يمكن اعتبار تضمين المستخدم (العنصر) الذي تم الحصول عليه على أنه المتجه الكامن للمستخدم (العنصر).

يتم بعد ذلك إدخال تضمين المستخدم وتضمين العنصر في بنية عصبونية متعددة الطبقات، نطلق عليها اسم طبقات التصفية التعاونية العصبونية NCF-Layers، لتعيين المتجهات الكامنة إلى درجات التنبؤ. يمكن تخصيص كل طبقة من طبقات CF العصبونية، لاكتشاف بعض الهياكل الكامنة لتفاعلات المستخدم والعنصر. يُحدّد بعد آخر طبقة مخفية  $X$  قدرة النموذج.

طبقة المخرجات النهائية Output Layer هي الدرجة المتوقعة  $\hat{y}_{ui}$ ، ويتم التدريب عن طريق تقليل الخسارة النقطية Pointwise Loss بين  $y_{ui}$  و  $\hat{y}_{ui}$  (تقليل الخطأ التربيعي بين القيمة المتوقعة والقيمة المستهدفة). في تدريب تقليل الخسارة النقطية يتم التعامل مع كل مُدخَل بشكل منفرد.

هناك طريقة أخرى لتدريب النموذج تتمثل في إجراء التعلم الثنائي Pairwise، التي تنظر إلى زوج من المدخلات في وقت واحد ضمن تابع الخسارة مثلاً بالنسبة لمُدخلين  $\{(v_{u1}^U, v_{i1}^I), (v_{u2}^U, v_{i2}^I)\}$  هل  $\hat{y}_{u1i1}$  أكبر من  $\hat{y}_{u2i2}$  أم أصغر، ويتم مقارنته بالترتيب الحقيقي لـ  $y_{u1i1}$  و  $y_{u2i2}$  [42,43].



الشكل (9): بنية نموذج الترشيح التعاوني العصبوني NCF

يُصاغ النموذج التنبئي ل NCF بالعلاقة (18):

$$\widehat{y}_{ui} = f(P^T v_u^U, Q^T v_i^I | P, Q, \Theta_f) \quad (18)$$

حيث:

- $P \in \mathbb{R}^{M \times K}, Q \in \mathbb{R}^{N \times K}$  تدل على مصفوفة العامل الكامن للعناصر والمستخدمين.
- $\Theta_f$  يشير إلى معلمات النموذج لوظيفة التفاعل  $f$ .

يمكن تعريف الوظيفة  $f$  (كونها شبكة عصبونية متعددة الطبقات) على النحو التالي العلاقة (19):

$$f(P^T v_u^U, Q^T v_i^I) = \phi_{out} \left( \phi_{\chi} \left( \dots \phi_2 \left( \phi_1 (P^T v_u^U, Q^T v_i^I) \right) \right) \right) \quad (19)$$

حيث تشير  $\phi_{out}$  و  $\chi$  على التوالي إلى وظيفة التعيين لطبقة الإخراج، وطبقة الترشيح التعاوني العصبوني ذات الترتيب  $X$ ، فيكون بالمجموع هناك  $X$  طبقة CF عصبونية [47].

لتعلم معلمات النموذج يتم اتباع نموذج الانحدار لتقليل الخسارة المربعة [48,49]:

$$L_{sqr} = \sum_{(u,i) \in \mathcal{Y}^+ \cup \mathcal{Y}^-} w_{ui} (\widehat{y}_{ui} - y_{ui})^2 \quad (20)$$

حيث تشير  $\mathcal{Y}$  إلى مجموعة التفاعلات الملحوظة في  $\mathcal{Y}$ ، وتشير  $\mathcal{Y}^-$  إلى مجموعة الحالات السلبية، والتي يمكن أن تكون كلها (أو مأخوذة من) تفاعلات غير ملحوظة؛ و  $w_{ui}$  عبارة عن hyperparameter يدل على وزن التدريب ل  $(u,i)$ .

### 4.3.2 النموذج الهجين Hybrid Model

نظام التوصية الهجين هو نوع خاص من نظم التوصية، يمكن اعتباره مزيجًا من الترشيح المعتمد على المحتوى والترشيح التعاوني [44]. قد يساعد الجمع بين كلا النوعين في التغلب على القصور الذي نواجهه عند استخدامهما بشكل منفصل، مثل مشكلة الإقلاع البارد ومشكلة التخصيص الزائد إضافة إلى تناثر (بعثرة) البيانات. في كثير من الحالات يكون النظام الهجين أكثر فاعلية ويقدم توصية أكثر دقة.


يعد Netflix مثالاً جيداً على أنظمة التوصية الهجينة. يقدم توصيات من خلال مقارنة البحث الذي يجريه المستخدم مع مستخدمين مماثلين (ترشيح تعاوني)، إضافة إلى توفير الأفلام التي تشترك في الميزات مع الأفلام التي صنّفها هؤلاء المستخدمون المماثلون بدرجة عالية (الترشيح القائم على المحتوى) سابقاً.

يمكن تنفيذ الأساليب الهجينة بعدة طرق:

تنفيذ كل من الترشيح التعاوني والترشيح المعتمد على المحتوى بشكل فردي وتجميع تنبؤاتهم. قدم Burke [45] عدة طرق رئيسية في بناء نظام توصية هجين:

### 1. الجمع الموزون Weighted

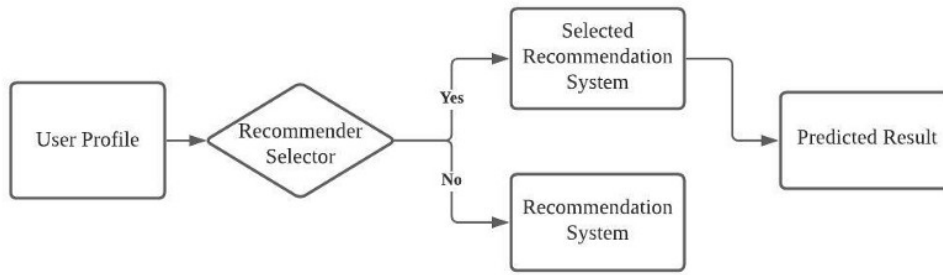
في نظم التوصية الموزونة، يمكننا بناء بعض النماذج القادرة على دراسة مجموعة البيانات، وتقديم التوصية (ترشيح تعاوني - ترشيح قائم على المحتوى). سيأخذ نظام التوصية الهجين الموزون المخرجات من كل نموذج، ويجمع النتيجة بشكل موزن، من الجدير بالذكر أن الوزن لا يتغير عبر مجموعتي التدريب والاختبار. على سبيل المثال، يمكننا الجمع بين نموذج قائم على المحتوى، ونموذج تصفية تعاوني معتمد على العنصر، ويأخذ كل منهما وزناً بنسبة 50% للتنبؤ النهائي، أو في البداية يُعطى الترشيح التعاوني والقائم على المحتوى وزنين متساويين، لكن يتم تعديل الأوزان (ترجيح النموذج)، تدريجيًا عندما يتم تأكيد أو عدم تأكيد التنبؤات حول تصنيفات المستخدم (الشكل (10)).



الشكل (10): نظام توصية هجين موزون

### 2. التبديل أو الانتخاب Switching

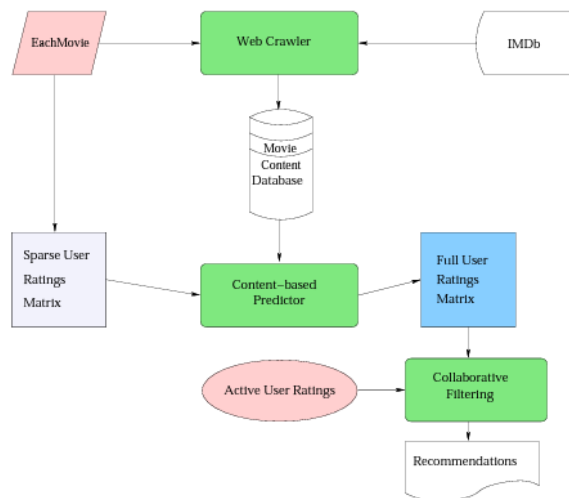
يختار هذا النوع من النظم الهجينة نظام توصية واحد من بين النظم المستخدمة (ترشيح تعاوني - قائم على المحتوى) بناءً على الموقف (الشكل (11)). يقدم هذا النهج طبقة إضافية، والتي تحدّد النموذج المناسب لاستخدامه. تستخدم تقنية DailyLearner الترشيح القائم على المحتوى الذي يعتمد على بيانات العناصر، وعلى أقرب جيران KNN، التي لا تتطلب عدد كبير من الأمثلة للتوصية الدقيقة، بالمقابل يوفّر الترشيح التعاوني في نموذج التبديل الهجين القدرة على التوصية بغض النظر عن نوع البيانات أي Cross-Genre، أي تقديم توصيات ليست قريبة دلاليًا من العناصر المقيّمة سابقاً بشكل جيّد، لكنها قد تكون ذات صلة باهتمامات المستخدم.



الشكل (11): نظام توصية هجين يعتمد التبديل

### دمج بعض الخصائص القائمة على المحتوى في ملف النموذج التعاوني.

قدّم [46] نهجًا متنبئًا قائمًا على المحتوى، لتحسين بيانات المستخدم الحالية، بعد ذلك يقوم بتقديم توصيات من خلال التصفية التعاونية، بالاعتماد على مجموعة بيانات EveryMovie. في البداية، يستخدم زاحف الويب عناوين URL المتوفرة في مجموعة بيانات EveryMovie، للحصول على محتوى الفيلم من موقع IMDb. وبعد المعالجة المسبقة المناسبة، يتم تخزين المحتوى الذي تم تحميله في قاعدة بيانات محتوى الفيلم. توفر مجموعة بيانات EveryMovie أيضاً مصفوفة تقييمات المستخدمين. نظرًا لتناثر البيانات في المصفوفة، لأن معظم العناصر لم يتم تصنيفها من قبل معظم المستخدمين؛ يتم تدريب المتنبئ المستند إلى المحتوى على كل متجه لتصنيفات المستخدم، وبعد ذلك يتم إنشاء متجه زائف لتصنيفات المستخدم. يحتوي متجه تصنيفات المستخدم الزائف على التقييمات الفعلية للمستخدم والتنبؤات المستندة إلى المحتوى للعناصر غير المصنفة. تشكل جميع متجهات تصنيفات المستخدمين الزائفة معًا مصفوفة التصنيفات الزائفة، وهي عبارة عن مصفوفة كاملة. بأخذ مستخدم معين  $u$  يتم إجراء تنبؤات لعنصر جديد باستخدام CF في مصفوفة التقييمات الزائفة الكاملة. الشكل (12).



الشكل (12): دمج بعض الخصائص القائمة على المحتوى في النموذج التعاوني

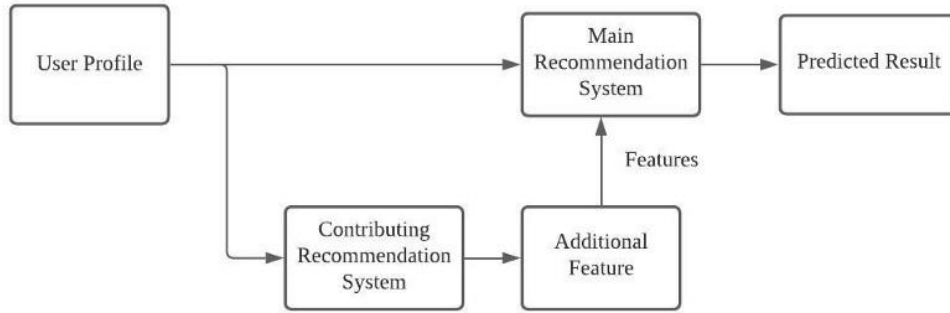
## دمج بعض الخصائص التعاونية في ملف النموذج القائم على المحتوى.

في هذا النوع يعمل النموذج الهجين في البداية على معالجة المعلومات التعاونية على أنها ميزات إضافية مرتبطة بكل عنصر ومن ثم يستخدم التقنيات القائمة على المحتوى عبر مجموعة البيانات المعززة هذه، الشكل (13).

النموذج الهجين في الشكل أدناه، قادر على النظر في البيانات التعاونية من النظام الفرعي Contributing RS دون الاعتماد عليه كلياً، وبالتالي يقلل من حساسية النظام لعدد المستخدمين الذين صنفوا عنصراً محدداً، كما أن النظام يحصل من خلال النموذج القائم على المحتوى على التشابه بين العناصر بالاعتماد على ميزات العنصر نفسها. فيكون لدينا في النهاية نموذج واحد يستخدم بيانات معززة Enhanced Data.

نشر Hirsh and Cohen (1998) تقرير عن التجارب التي تم فيها تطبيق متعلم القاعدة الاستقرائي على مهمة التوصية بالأفلام، باستخدام تقييمات المستخدم السابقة CF، إضافة إلى ميزات الأفلام نفسها CB، وحقق النموذج الهجين دقة أفضل من النموذج التعاوني البحت.

هناك طريقة أخرى تستخدم تقنية التحليل الدلالي الكامن Latent Semantic Analysis (LSA) ضمن نموذج قائم على المحتوى. صمم هذه التقنية Scott Deerwester [47]، وهي عبارة عن تقنية رياضية إحصائية، لاستخراج واستنتاج العلاقات بين الوثائق والمصطلحات. تطبق هذه التقنية تحليل القيمة المفردة (SVD)، وهي قادرة ربط المصطلحات ذات الصلة لغويًا ببعضها لإنشاء ميزات تعاونية.



الشكل (13): دمج الخصائص التعاونية في النموذج القائم على المحتوى Features Combination

## 2.4 تقييم نظم التوصية

يُعتبر تقييم أنظمة التوصية RS Evaluation موضوع بحث يجذب اهتمامًا كبيرًا ومتزايدًا مع الوقت [48,49]. بشكل عام يعتمد المقياس الذي سيتم استخدامه على مشكلة العمل التي يتم حلها. إذا اعتقدنا أننا قدمنا أفضل مقترح ممكن للمستخدم، وأعطى مقياس الدقة نتيجة رائعة، لكن عملية تقديم التوصية كانت مكلفة؛ فإن نظام التوصية لن يكون جيدًا في هذه الحالة، من وجهة نظر ثانية، يجب أن يكتسب نظام التوصية ثقة المستخدم User-Trust على سبيل المثال، إذا أوصينا بأفضل 10 منتجات، وكان 2 أو 3 فقط مناسبين له، فسيُعتبر أن نظام التوصية سيئ. لهذا السبب، لا تتمثل الفكرة في التوصية دائمًا بأهم K عنصر، ولكن يجب التوصية بالعناصر المناسبة (عبر عن ذلك المستخدم) والتي يتجاوز عددها حدًا معينًا (نسبة من أهم K عنصر). هناك نوعان من التجارب الرئيسية لاختبار نظم التوصية (تجارب عدم الاتصال بالإنترنت – تجارب الاتصال بالإنترنت).

الأنظمة التي يتم تقييمها باستخدام مجموعات البيانات تسمى بالأنظمة غير المتصلة بالإنترنت **Offline RS**. تسمح مجموعات البيانات للباحثين بتقدير أداء الخوارزمية كما لو تم استخدامها في بيئة عملية. على العكس من ذلك تسمح تجارب التقييم عبر الإنترنت **Online RS** للباحثين باختبار أنظمتهم في سيناريوهات حية، وفي الوقت الحقيقي مع مستخدمين فعليين؛ قدّم NewsReel (Hopfgartner et al., 2016) خوارزمية توصية لمقالات إخبارية جرى اختبارها بشكل فعلي، وبالوقت الحقيقي على مقالات إخبارية منتشرة عبر منافذ موجودة على الإنترنت بشكل مباشر، وعلى مستخدمين فعليين على الإنترنت.

تتمثل ميزة التقييم في وضع عدم الاتصال بالإنترنت في سرعة وسهولة اختبار الخوارزميات باستخدام مجموعات بيانات محددة مسبقًا، لكن نظرًا لأن هذه النتائج لا ترتبط بالمستخدمين الفعليين، توجد قيود على التقييم في وضع عدم الاتصال، أهمها أن مجموعات البيانات المستخدمة تتضمن صورة جزئية للمستخدم فقط، وبالتالي جزء من اهتماماته الفعلية والمحتملة وليس كلها. بينما تتمثل ميزة التقييم في وضع الاتصال بالإنترنت في أنها تقيس رضا المستخدم الملحوظ في الوقت الحقيقي Real-Time، بدلاً من التفاعل المفترض مع قائمة موصى بها سابقًا. وبالتالي، قد تكون هناك اختلافات كبيرة بين ما يُفترض أن يتفاعل معه المستخدم، والتفاعلات الفعلية التي تحدث في سياق مختلف (مع عدد محدود من العناصر أو عند تجربة اكتشاف اهتمامات جديدة). وتعاني تجارب الاتصال من صعوبات جمّة، تتمثل إحداها في تحديد الرضا الحقيقي للمستخدم، وليس الرضا المستنتج (على سبيل المثال في نظام توصية يستنتج مدى اهتمام المستخدم بالمقالة، إن قصر النتائج على مجرد النقر فوق مقالة ما (نسبة النقر إلى الظهور أو CTR\*)، لا تأخذ بالاعتبار ما إذا كانت المقالة قد تمت قراءتها بالفعل، أو أن المستخدم وجد المقالة مفيدة فعليًا له. إذ يجب أن تعتمد التقييمات عبر الإنترنت على مؤشرات أكثر صعوبة، مثل الوقت المستغرق (الوقت الذي يقضيه المستخدم في مقالة ما بعد النقر عليها في البداية).

\* في التسويق عبر الإنترنت، تشير نسبة النقر إلى الظهور Click-Through Rate إلى نسبة النقر إلى الظهور: مقياس يقيس عدد النقرات التي يتلقاها المعلنون على إعلاناتهم لكل عدد من مرات الظهور.

عملياً توجد أربعة أنواع رئيسية لمقاييس التقييم لأنظمة التوصية:

### 1. مقاييس الدقة التنبؤية

الدقة التنبؤية، أو مقاييس التنبؤ بالتقييم تبين مدى قرب التقييمات التي قدّرها نظام التوصية بالنسبة إلى تقييمات المستخدم الحقيقية، وهي الأكثر شيوعاً من بين مقاييس الدقة، وتعدّ الأنسب لسيناريوهات الاستخدام التي يكون فيها التنبؤ الدقيق بتصنيفات جميع المنتجات أمراً بالغ الأهمية. من أهم مقاييس الدقة التنبؤية: متوسط الخطأ المطلق (MAE)، ومتوسط الخطأ التربيعي (MSE)، جذر متوسط الخطأ التربيعي (RMSE)، متوسط الخطأ المطلق المسوّى (NMAE).

$$MAE(y, \hat{y}) = \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{n} = mean(|e|) \quad (21)$$

$$RMSE(y, \hat{y}) = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} = \sqrt{mean(e^2)} \quad (22)$$

$$NMAE(y, \hat{y}) = \frac{MAE(y, \hat{y})}{\frac{1}{n} \sum_{i=1}^n |y_i|} = \frac{MAE(y, \hat{y})}{mean(|y|)} \quad (23)$$

بالمقارنة مع مقياس MAE، يستخدم MSE و RMSE انحرافات مربعة، وبالتالي يعطيان أهمية للأخطاء الكبيرة. للمقارنة بين مجموعة خوارزميات توصية بمجالات تقييم مختلفة، يقوم NMAE بتسوية مقياس MAE على مجال التقييم المستخدم في كل خوارزمية.

### 2. مقاييس دقة التصنيف

تقيم مقاييس دقة التصنيف قدرة اتخاذ القرار لنظم التوصية. وتعد اختيار جيد لمهام تحديد المنتجات ذات الصلة، أو غير ذات الصلة للمستخدم. بالنسبة لمقاييس دعم القرار، يتم تجاهل قيمة التقييم لكل عنصر [50].

#### I. مصفوفة الارتباك Confusion Matrix (جدول 1)

	Recommended (T)	Not-Recommended (F)
<b>Relevant (P)</b>	<b>True-Positive (TP)</b>	<b>False-Negative (FN)</b>
<b>Non-Relevant (N)</b>	<b>False-Positive (FP)</b>	<b>True-Negative (TN)</b>

الجدول (1): مصفوفة الارتباك Confusion Matrix لنظام توصية

من خلال المصفوفة السابقة يمكن حساب Precision بالعلاقة 24:

$$Precision = \frac{TP}{TP + FP} \quad (24)$$

تُظهر الدقة Precision قدرة نظام التوصية على إظهار نسبة العناصر المفيدة (الموصى بها بشكل صحيح) للمستخدم فقط من بين كل العناصر الموصى بها.

ويمكن حساب Recall بالعلاقة 25:

$$Recall = \frac{TP}{TP + FN} \quad (25)$$

بينما يظهر Recall قدرة نظام التوصية على إظهار نسبة العناصر المفيدة (الموصى بها بشكل صحيح) للمستخدم فقط من بين كل العناصر ذات الصلة بالمستخدم. ومن المقاييس الأخرى المشتقة من Precision و Recall مقياس F-Measure [50] الذي يدرس سلوك كل من Precision و Recall في قيمة واحدة؛ العلاقة 26:

$$F_{\beta} = \frac{Precision * Recall}{(1 - \beta)Precision + \beta Recall} \quad (26)$$

ومن أجل  $\beta = \frac{1}{2}$  (F1-Measure) العلاقة 27.

$$F_1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (27)$$

عند تعريف عدد العناصر التي يجب على النظام أن يوصي بها للمستخدم وليكن K، عندئذٍ يتم حساب Precision و Recall على أساس عدد العناصر K، واللذان يُعرَّفان بالشكل Precision@K و Recall@K، العلاقتين 28 و 29.

$$Precision@k = \frac{TP@k}{TP@k + FP@k} \quad (28)$$

$$Recall@k = \frac{TP@k}{TP@k + FN@k} \quad (29)$$

### 3. مقاييس دقة الترتيب

على الرغم من أهمية مقاييس دقة التنبؤ ودقة التصنيف، إلا أن خوارزميات التوصية في العديد من المجالات، غالبًا ما توصي للمستخدم بمجموعة من العناصر المرتبة ضمن قائمة معينة، وتكون رؤية العناصر في أسفل القائمة أقل احتمالاً من العناصر في أعلى القائمة وهذه المقاييس هي:

#### I. متوسط مقلوب الترتيب Mean Reciprocal Rank

مقلوب الترتيب RR هو مقياس استرجاع معلومات [51]، يُستخدم لتقييم أي خوارزمية تنتج قائمة بالعناصر مرتبة حسب احتمالية ملائمتها. يقيس RR مقلوب الترتيب لأول عنصر ذات صلة بالمستخدم بالنسبة لاستعلام معين Query. ويتم حساب متوسط مقلوب الترتيب MRR بالنسبة لمجموعة استعلامات كما في العلاقة 30. يتعلّق MRR بأول عنصر ذات صلة بالمستخدم، وله أعلى ترتيب فقط ضمن مجموعة الاستعلامات من القائمة المنتجة؛ وهذا يعني أن MRR لا ينظر إذا كانت هناك عدة عناصر صحيحة (على فرض أن الخوارزمية قامت بإرجاع 10 عناصر واتضح أن أول عنصر ذا صلة له الترتيب 3، فهذا ما يهتم به MRR. لن يتحقق MRR مما إذا كانت العناصر الأخرى ذات صلة بين العناصر ذات الترتيب 4 إلى 10).

$$MRR = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \frac{1}{rank_i} \quad (30)$$

تكون قيمة RR تساوي 1 إذا تم استرداد عنصر ذات صلة في المرتبة 1 من بين مجموعة العناصر، ويكون 0.5 إذا تم استرداد عنصر ذات صلة في المرتبة 2. نلاحظ عند الانتقال من الترتيب 1 للترتيب 2 يكون التغير كبير (0.5) مقارنة بالانتقال من الترتيب 100 للترتيب 1000 (التغير 0.009).

## II. الربح التراكمي المخصوص (DCG)

DCG هو مقياس لجودة الترتيب [52]، ولوصف المقياس بشكل واضح، علينا أن نبدأ بتعريف مصطلح المنفعة (الربح):

### • المنفعة أو الربح Gain.

الربح لعنصر ما هو في الأساس نفس درجة ملاءمة هذا العنصر للمستخدم، والتي يمكن أن تكون تقييمات رقمية مثل نتائج البحث في Google، ويمكن تصنيفها ضمن مقياس من 1 إلى 5، أو ثنائي في حالة البيانات الضمنية، حيث نعرف فقط ما إذا كان المستخدم قد استهلك عنصر معين أم لا. ومن أجل قائمة توصية مؤلفة من K عنصر، يتم تعريف الربح التراكمي الطبيعي على أنه مجموع المكاسب حتى المركز k في قائمة التوصيات. العلاقة 31.

$$CG(k) = \sum_{i=1}^k G_i \quad (31)$$

أحد المشاكل الواضحة لـ CG هو أنها لا تأخذ في الاعتبار الترتيب. من خلال تبديل الترتيب النسبي لأي عنصرين، لن تتأثر CG. هذه مشكلة عندما يكون الترتيب مهمًا. على سبيل المثال، في نتائج بحث Google، من الواضح أننا لا نرغب برؤية العنصر الأكثر ملاءمة في الجزء السفلي من القائمة. لذلك نعدّل علاقة CG السابقة لتصبح بالعلاقة 32:

$$DCG(k) = \sum_{i=1}^k \frac{G_i}{\log_2(i+1)} \quad (32)$$

وفي نظام توصية من أجل مجموعة مستخدمين U ومن أجل قائمة من العناصر موصاة للمستخدمين مؤلفة من k عنصر نعرّف DCG بالعلاقة 33:

$$DCG = \frac{1}{|U|} \sum_{u_i \in U} \sum_{n=1}^k \frac{g_{u,i_n}}{\log_2(n+1)} \quad (33)$$

حيث  $g_{u,i_n}$  هو الربح لمستخدم  $u_i \in U$  من أجل عنصر n.

تكمّن المشكلة في DCG في أن قيمه متزايدة مع طول قائمة التوصيات. لذلك، لا يمكننا مقارنة DCG للنظام الذي يوصي بأعلى 5 عناصر مع DCG لنظام آخر يعطي أعلى 10 عناصر، لأن الأخير سيكون له درجة أعلى ليس بسبب جودة توصياته، ولكن بسبب طول قائمة التوصيات التي يقدمها. لهذا السبب يتم استخدام nDCG وهو الربح التراكمي المخصوص المعدّل Normalized DCG.

يمكن الحصول على nDCG عن طريق حساب Ideal DCG (IDCG)، حيث يجب تسوية الربح التراكمي لقيمة مختارة K. ويتم ذلك بترتيب العناصر ذات الصلة في مجموعة مرتبة تنازلياً حسب درجة صلة العنصر بالمستخدم وينتج عن ذلك أكبر قيمة ممكنة ل DCG من أجل K. ويعمل IDCG كعامل تسوية Normalization Factor (العلاقة 34).

$$nDCG_k = \frac{DCG_k}{IDCG_k} \quad (34)$$

### III. مقياس الدقة المتوسطة AP@K

رأينا سابقاً أن مقياس دعم القرار Precision@K يحسب جزء K من التوصيات المفيدة، لكن عيب هذا المقياس في أنه لا يعتبر القائمة الموصى بها مرتبة، ويعامل جميع الأخطاء في القائمة الموصى بها على قدم المساواة، لكن في الواقع يجب إعطاء أهمية أكبر للأخطاء في أعلى القائمة، ثم تقليل أهمية الأخطاء مع النزول للعناصر السفلية في القائمة، وهو مايقوم به هذا المقياس العلاقة (35).

$$AP@K = \frac{1}{r_K} \sum_{k=1..K} \frac{\#relevant\ items\ in\ top\ k\ results * rel(k)}{k} \quad (35)$$

$$rel(k) = \begin{cases} 1: & \text{if } k\text{th item is relevant} \\ 0: & \text{otherwise} \end{cases} \quad (36)$$

حيث  $r_K$  هو عدد العناصر الكلي ذات الصلة بالمستخدم ضمن قائمة من K عنصر.

### IV. متوسط مقياس الدقة المتوسطة MAP:

في الواقع إن مقياس الدقة المتوسطة AP@K السابق هو لمستخدم واحد فقط، ويُحسب المقياس السابق لعدة مستخدمين بأخذ متوسط AP@K بالنسبة لعدد المستخدمين.

$$MAP@K = \frac{1}{N} \sum_{i=1}^N (AP@K)_i \quad (37)$$

هناك مجموعة أخرى من مقاييس أداء نظم التوصية وهي التنوع Diversity والتغطية Coverage والابتكار Novelty، لكن سنركز في أطروحتنا هذه على مقاييس الدقة التنبؤية ومقاييس دقة الترتيب.

## الفصل الثالث

نستعرض في هذا الفصل دراسة مرجعية  
لنظم التوصية السياقية Context-Aware RS، وينصب تركيزنا  
على نظم التوصية التي تعتمد السياق الزمني Time-Aware RS.

### 1.3 مقدمة

تركز غالبية الأساليب الحالية لنظم التوصية على التوصية بالعناصر الأكثر صلة للمستخدمين، ولا تأخذ بالاعتبار أي معلومات سياقية، مثل الوقت والمكان ووجود أشخاص آخرين بصحبة المستخدم، على سبيل المثال، مشاهدة الأفلام أو تناول الطعام بالخارج برفقة العائلة أو برفقة الأصدقاء، بمعنى آخر، تتعامل أنظمة التوصية التقليدية مع المستخدمين والعناصر فقط.

$$R: User \times Item \rightarrow Rating$$

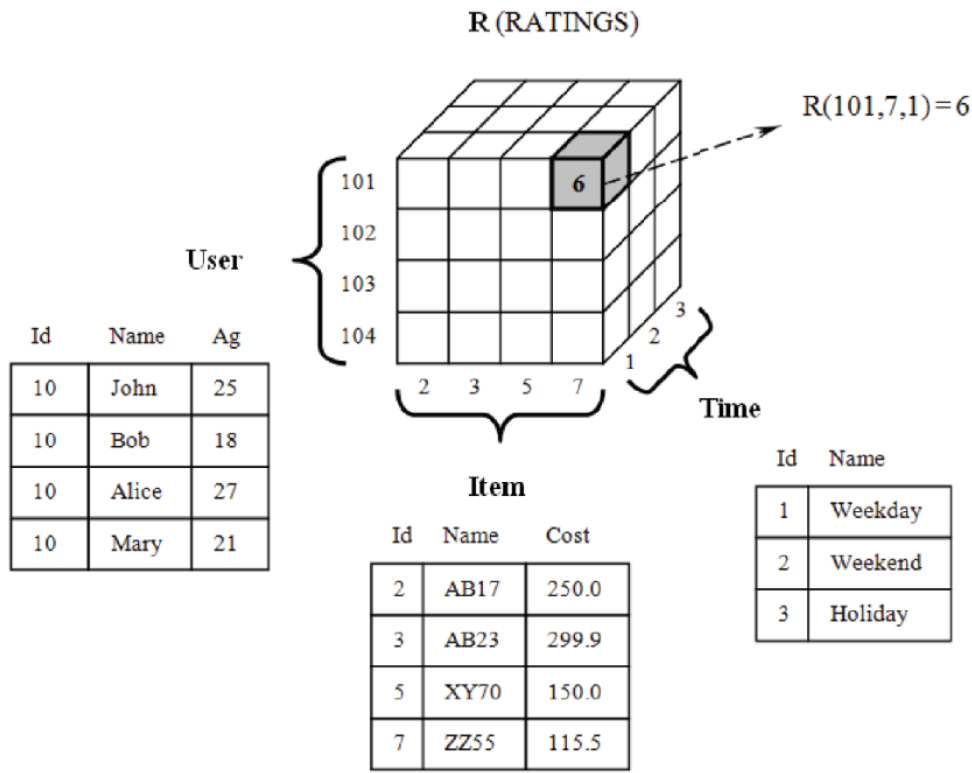
لبيان أهمية المعلومات السياقية في نظم التوصية، نأخذ على سبيل المثال لا الحصر السياق الزمني، عند الاعتماد على معلومات السياق الزمني Temporal-Context سيوفر نظام التوصية بالسفر توصية بأيام العطل في الشتاء يمكن أن تكون مختلفة تماماً عن تلك الموجودة في الصيف. من وجهة نظر أخرى، قد يفضل المستخدم في أيام الأسبوع قراءة أخبار العالم عندما يقوم بتسجيل الدخول في الصباح، ومعلومات عن سوق الأسهم في المساء، بينما في عطلات نهاية الأسبوع، قد يفضل قراءة مجلات أو حضور الأفلام والقيام بالتسوق.

$$R: User \times Item \times Context \rightarrow Rating$$

قبل مناقشة دور وفرص المعلومات السياقية في أنظمة التوصية يجب أن نعرّف السياق.

### 2.3 السياق

السياق هو مفهوم متعدد الأوجه تمت دراسته عبر تخصصات بحثية مختلفة، بما في ذلك علوم الكمبيوتر (بشكل أساسي في الذكاء الاصطناعي)، والعلوم المعرفية واللغويات والفلسفة وعلم النفس والعلوم التنظيمية. يعرّف السياق على أنه "الشروط أو الظروف التي تؤثر على شيء ما" [53]. تم تعريف السياق في أنظمة التوصية المدركة للسياق TARS، على أنه مجموعة المعلومات التي تخص موقع المستخدم، Location، وهوية الأشخاص Nearby People بالقرب من المستخدم، ومزاج المستخدم User Mood، إضافة للتغيرات في شعبية العناصر زمنياً Popularity with time، ووقت تقييم العناصر Rating Time. سنركز في هذه الأطروحة على السياق الزمني المتعلق بالمستخدم Temporal Context (TC). وبذلك يتم توسعة مصفوفة تقييم العناصر، لتصبح بالشكل (14).



الشكل (14): نموذج متعدد الأبعاد لتوصية المستخدم × العنصر × الوقت

### 3.3 الدّراسة المرجعية

#### 1.3.3 نموذج الترشيح التعاوني CF:

قدّم [54] نظام توصية مدرك للوقت TARS يعتمد على الذاكرة، ويستند إلى الترشيح التعاوني، وهو الأساس الذي اعتمدنا عليه في هذه الأطروحة. استند هذا النظام إلى مقاربتين رئيسيتين:

- مقارنة حداثة التوصيات Fresh-Based.
- مقارنة السياق Context-Based.

استُخدم في هذا النظام معيار التشابه (المسافة الإقليدية Euclidean Distance). وقدّم في بنية حداثة التوصيات المقاربتان التاليتان:

1. مقارنة النافذة الزمنية المتخامدة Damped Window التي تأخذ كل التقييمات بالاعتبار ويعطى كل تقييم وزن بناء على تابع انحلال زمني من الشكل:

$$f(t) = 2^{-\lambda(t-t_{u,i})} \quad (38)$$

- معامل حساسية تعبّر عن درجة التخامد.
- الوقت الحالي  $t$ .
- وقت تقييم المستخدم  $u$  للعنصر  $i$ .

2. مقارنة النافذة الزمنية المنزلقة Sliding Window.

أما مقارنة السياق فيأخذ فيها السياق الزمني على عدّة مستويات:

- الوقت ضمن اليوم الواحد (الصباح – الظهر – العصر - المساء).
- اليوم من الإِسبوع (السبت ... الجمعة).
- الوقت ضمن الإِسبوع (يوم عمل – يوم عطلة).

استُخدمت مجموعة البيانات ml-100k وجمعت من خلال موقع MovieLens على الوب [movielens.umn.edu](http://movielens.umn.edu)، خلال فترة سبعة أشهر من 19 سبتمبر 1997 حتى 22 أبريل 1998. وتتألف من 100,000 تقييم من قبل 1000 مستخدم على مجموعة مؤلفة من 1700 فيلم.

حقق النموذج المقترح النتائج التالية، بالمقارنة مع نظام توصية لا يأخذ الزمن بالاعتبار TF-RS:

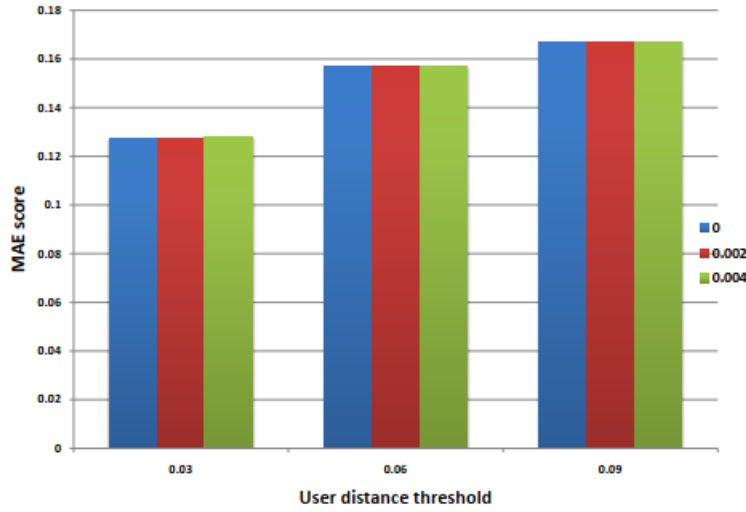
#### ❖ مقارنة النافذة الزمنية المتخامدة

من أجل قيم مختلفة لعتبة التشابه:

1. عند أخذ  $\lambda = 0$  عندئذ تكون قيم تابع الانحلال الزمني لكل التقييمات مساوية لـ 1، وبالتالي يكون نظام التوصية غير متعلّق بالزمن TF-RS، ويأخذ كامل التوصيات بالاعتبار دون أن يقوم بوزنها تاريخياً (اللون الأزرق).

2. نلاحظ من أجل  $\lambda = 0.002$  و  $\lambda = 0.004$  لم يقدّم النظام المقترح أي تحسينات تذكر (أو

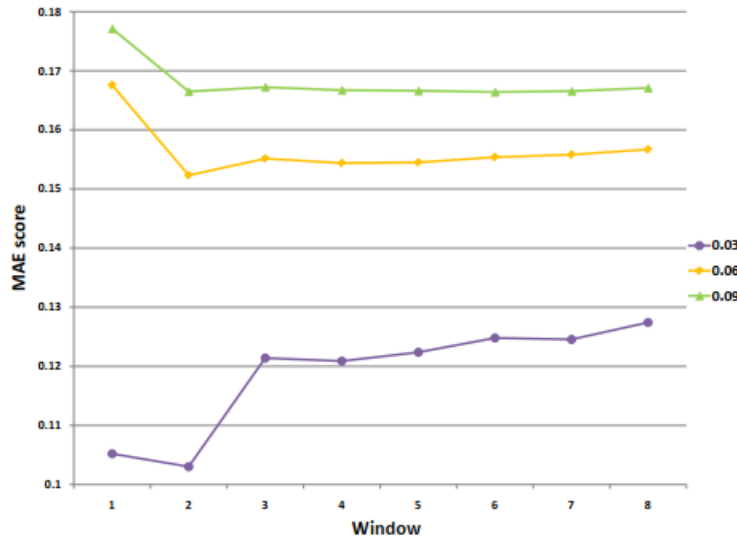
كان التحسّن طفيف جداً) بحسب [54]. الشكل (15)



الشكل (15): قيم متوسط الخطأ المطلق MAE من أجل قيم مختلفة لمعامل الحساسية  $\lambda$  والتشابه Similarity

❖ مقارنة النافذة الزمنية المنزقة التي تأخذ فقط مجموعة صغيرة المعطيات ضمن نافذة معينة: (بسبب طبيعة مجموعة المعطيات اعتمد [54] على نوافذ زمنية شهرية فقط).

من أجل قيم مختلفة لعتبة التشابه المستخدمة (0.003 و 0.06 و 0.09) ومن أجل عدّة نوافذ بدءاً من  $W = 1$  التي تأخذ بالاعتبار التقييمات ضمن شهر واحد سابق فقط وصولاً لـ  $W = 8$ ، أي نظام توصية غير متعلق بالزمن، ويأخذ كامل التقييمات على كامل المجال الزمني لمجموعة المعطيات، حقق النظام المقترح النتائج التالية (الشكل 16):



الشكل (16): قيم متوسط الخطأ المطلق MAE من أجل عدّة نوافذ وعدّة عتبات لمعيار التشابه

1. بالنسبة لعتبة مسافة المستخدم التي تساوي 0.03 و  $W = 2$  تم تحسين التنبؤات بحوالي 2.5% مقارنة بـ  $W = 8$  (أي مقارنة بنموذج التوصيات غير المتعلقة بالوقت).


2. بالنسبة لعتبة تساوي 0.06 و  $W = 3$ ، تحسّنت التوقعات بمعدل 0.5% مقارنة بـ  $W = 8$ ، إضافة إلى ذلك، كلما كانت النافذة أكبر، كلما كان التحسّن أصغر.

3. فيما يتعلق بتأثير عتبات تشابه المستخدم، بالنسبة لعتبات مسافة المستخدم الأكبر، تزداد قيم MAE لجميع أحجام النوافذ، حيث يتم أخذ المزيد من المستخدمين المختلفين في الاعتبار لحساب الاقتراحات.

بشكل عام، قدّمت التوصيات جودة أفضل للنوافذ الصغيرة (ماعد النافذة  $W = 1$  بسبب قلة التصنيفات المستخدمة للتنبؤات).

### ❖ المقاربة المعتمدة على السياق Context-Based.

حقق النظام المقترح النتائج التالية عند أخذ سياق المستخدم المتعلّق بالوقت من السبوع (يوم عمل - يوم عطلة)، الذي قام فيه المستخدم بتقييم العناصر. وبأخذ نفس عتبات التشابه السابقة.



الشكل (17): قيم متوسط الخطأ المطلق MAE من أجل السياق الزمني (الوقت من الإِسبوع)

تم تحسين جودة التوصيات مقارنة بنهج يتجاهل تماماً المعلومات الزمنية السياقية للتصنيفات:

1. بالنسبة لعتبة المسافة الإقليدية التي تساوي 0.03، تحسّن التنبؤ في حالة استخدام السياق (Weekdays, Weekends) بمعدّل 0.95% مقارنة بالنهج الخالي من السياق الزمني.
2. بالنسبة لعتبة المسافة التي تساوي 0.06، تحسّن التنبؤ بحالة يوم عمل Weekdays بحوالي 0.5%.

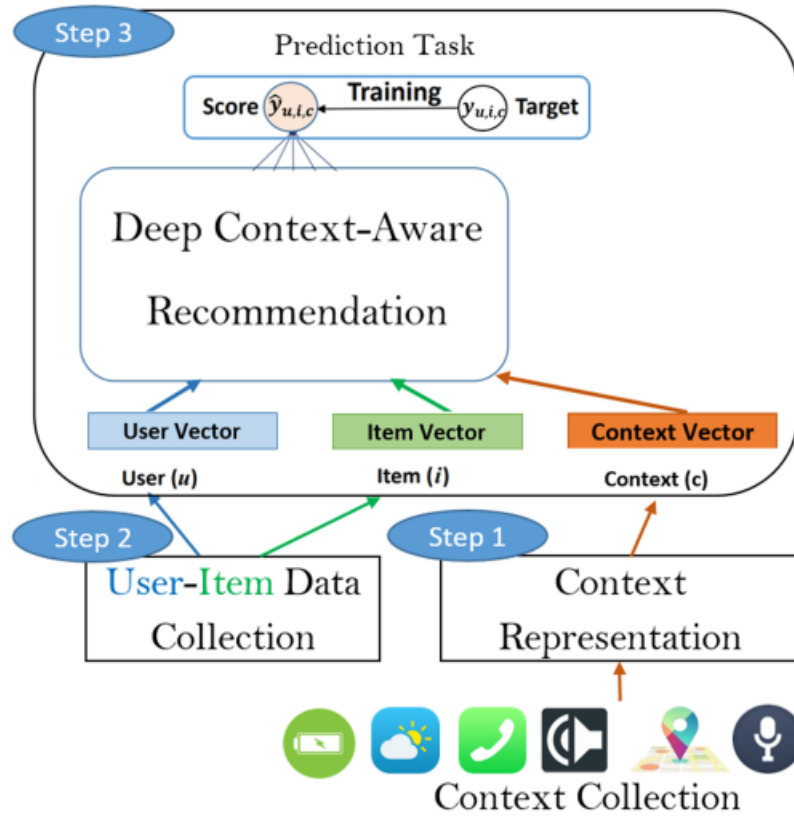
نلاحظ أنّ زيادة قيم عتبات التشابه الأكبر إلى قيم MAE أكبر، أي أن جودة التوصيات تتناقص مع ازدياد عتبة مسافة المستخدم. بالنسبة لبقية المعلومات السياقية (الوقت ضمن اليوم الواحد - اليوم من الإِسبوع) لم يحقق النموذج نتائج مرضية مقارنة مع نموذج لايتعلّق بالزمن.

### 2.3.3 نموذج التعلّم العميق

قدّم [55] بشهر أيار من عام 2020 نموذج توصية يعتمد على التعلّم العميق، ويأخذ المعلومات السياقية (نشاط المستخدم – الموقع – الوقت – الطقس) بالاعتبار ضمن عدّة أشكال، واقترح تعزيز نموذجي الترشيح التعاوني التقليدي NCF، وعامل المصفوفي NeuMF، المعتمدين على الشبكات العصبونية بالعديد من تمثيلات السياق.

يستخدم النموذج المقترح (الشكل 18) الشبكات العصبونية العميقة DNNs لتعلم الوظيفة غير الخطية للتفاعل بين (عنصر - مستخدم)، بدلاً من الجداء الخطي الثابت المستخدم في MF. ويتم توسعة نموذج التوصية العصبية مع ثلاثة أنواع من تمثيلات السياق: 1- صريحة، 2- مهيكلة كامنة 3- غير مهيكلة كامنة. واستناداً إلى النموذج المقترح تم تقديم ثلاث مهام توصية متنوعة:

1. توقع التصنيف.
2. توصية أعلى N عنصر.
3. تصنيف تعليقات المستخدمين (أعجبني Like، لم يعجبني Dislike، وصلت إلى المكان Check-In)



الشكل (18): نموذج التوصية المدرك للسياق CARS

اقترح [55] ثلاث نماذج:

1. نموذج مدرك للسياق الصريح (Explicit Context-Aware Model (ECAM)، الذي يدمج سياقات المستخدمين الصريحة غير الهرمية.
2. نموذج مدرك للسياق غير المهيكل (Unstructured Context-Aware Model (UCAM)، الذي يدمج تضمينات سياقية كامنة غير هرمية مشتقة من شبكة ترميز تلقائي (Auto-Encoder (AE).
3. نموذج هرمي مهيكل (Hierarchical Context-Aware Model (HCAM) يستخدم التمثيل الهرمي للتضمينات السياقية الكامنة.

في البداية من أجل كل من التمثيلات السياقية، تمت تسوية قيم السمات السياقية إلى مقياس ضمن المجال  $[0,1]$ ، ومن ثم تحويل السمات الإسمية إلى ميزات ثنائية. ونتج عن ذلك متجه سياقي:

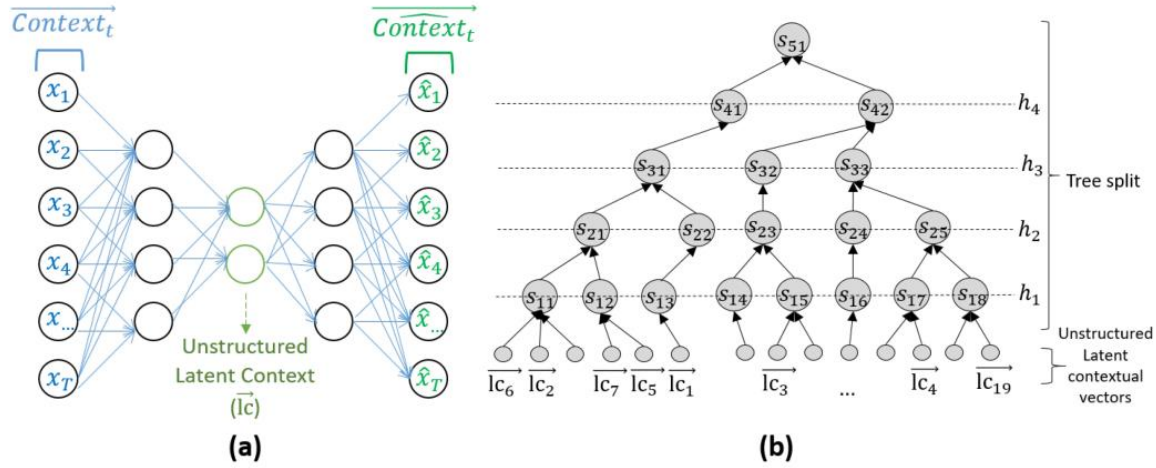
$$\overrightarrow{Context} = [x_1, x_2, x_3, \dots, x_T]$$

يتضمن استخراج التمثيل السياقي الصريح استخدام كل من الميزات السياقية المتاحة (الخام)، والتي تمثل  $T$  ميزة سياقية، في حين أن المعلومات السياقية الكامنة غير الهرمية هي تمثيل مضغوط يحتوي على  $L$  قيمة كامنة ( $L < T$ ) مستخرجة من AE. بالنسبة لعملية بناء السياقات الهرمية الكامنة، تم بناء تمثيل هرمي عن طريق تجميع مجموعة المتجهات السياقية الكامنة غير المهيكلة في مجموعة محدودة من العناقيد Clusters، حيث يمثل كل عنقود Latent Cluster (LC) حالة سياقية ضمنية يمكن توضيحها بالخطوات التالية:

1. استخراج متجهات السياق الكامنة المضغوطة من AE.
2. بناء شجرة هرمية من المتجهات السياقية الكامنة غير المنظمة.
3. في نهج تصاعدي Bottom-Up، لتمثيل المواقف السياقية الهرمية على مستويات مختلفة، طُبِّق نهج العنقدة الهرمية التجميعية (Agglomerative Hierarchical Clustering (AHC)، لتقدير عدد المواقف السياقية المحتملة (المجموعات) تلقائياً. ويتم تطبيق خوارزمية K-Means لتجميع متجهات سياقية كامنة تمثل حالة سياقية معينة.

يتم تعريف المتجه السياقي الكامن الهرمي على أنه مسار (أي مجموعة من المواقف السياقية) لمتجه سياقي كامن غير هرمي من الورقة إلى أعلى شجرة التمثيل.

$$\overrightarrow{l_{c19}} = [s_{18}, s_{25}, s_{33}, s_{42}, s_{51}]$$



الشكل (19): تمثيلات السياق الكامنة. (a) سياق كامن غير مهيكل (b) سياق الكامن الهرمي

يمكن تفسير التمثيلات السياقية على النحو التالي:

### 1. السياق الصريح EC

يحتوي التمثيل السياقي الصريح على جميع الميزات السياقية المتاحة التي تصف (الوقت ضمن اليوم، واليوم من الأسبوع، إضافة إلى الموقع والطقس).

### 2. السياق الكامن غير الهرمي UC

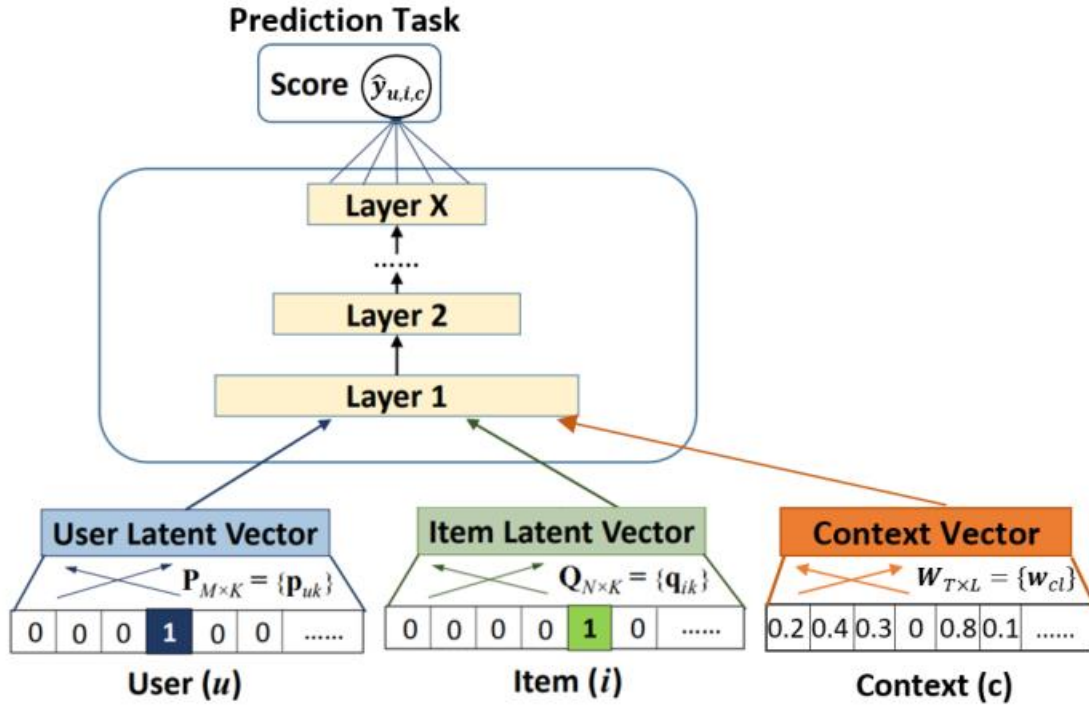
سيحتوي متجه السياق الكامن غير الهرمي على  $L$  قيمة رقمية، تمثل الارتباطات غير الخطية بين السمات السياقية الأصلية، بتمثيل مضغوط ومنخفض الأبعاد على سبيل المثال بعد ظهر يوم الأحد في الموقع  $X$ ، وصباح الجمعة في الموقع  $Y$ .

### 3. السياق الكامن الهرمي HC

سيحتوي التمثيل الهرمي للسياقات الكامنة على عدة مواقف سياقية مشتقة من شجرة، والتي تمثل عدة أنماط من الخصائص الكامنة غير الهرمية.

- ✓ تمثل بعض المواقف السياقية في المستوى المنخفض من الشجرة "موقع المستخدم"، مثل "في المنزل" أو "في العمل"، لأن هذه المواقف عبارة عن أنماط، وارتباطات، للسمات السياقية الزمنية الأصلية (الوقت من اليوم، واليوم من الأسبوع).
- ✓ يمكن أن تمثل بعض المواقف السياقية، في المستوى الأوسط من الشجرة، مواقف ذات درجة أعلى، مثل الوقت الذي يقضيه في العمل.
- ✓ وقد يمثل أعلى مستوى من الشجرة، المستخدمين في مدينتهم الأصلية، في أيام الأسبوع والمستخدمين خارج مدينتهم الأصلية في عطلات نهاية الأسبوع.

في نموذج NCF الموسّع تم إضافة مكوّن جديد للمعلومات السياقية: متجه سياقي (Context) في الشكلين 19 و 20) واقترح ثلاث نماذج كما ذكر سابقاً، بحسب طريقة تمثيل المعلومات السياقية ضمن NCF.



الشكل (20): تعزيز نموذج الترشيح التعاوني العصبوني NCF بإضافة المعلومات السياقية المضمّنة

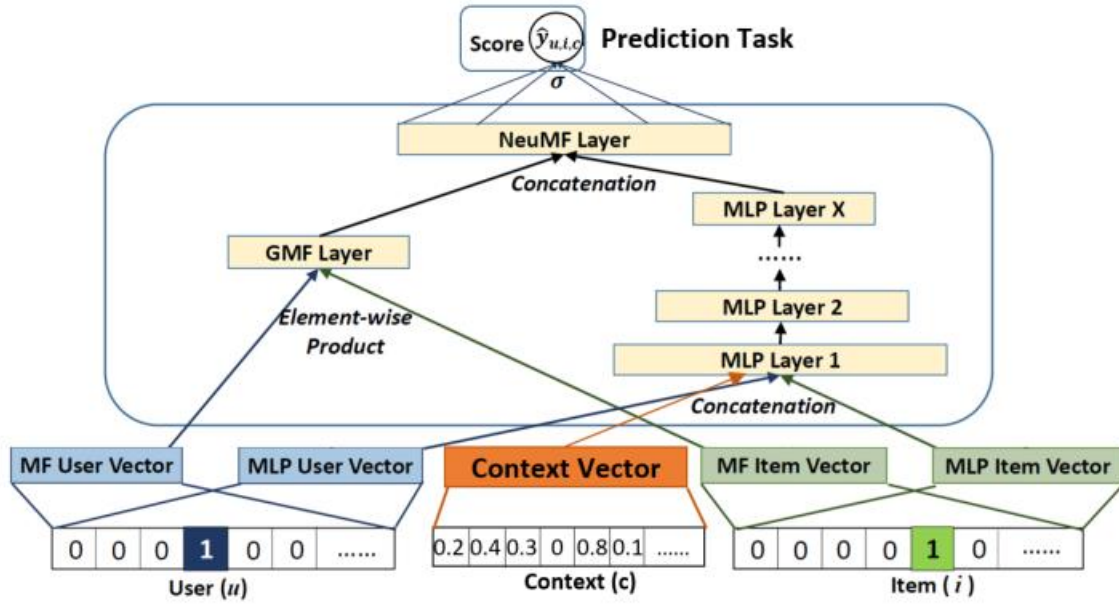
نموذج NeuMF الموسّع الموضح في الشكل 20، هو تعميم لنموذج NCF مع تفاعلات جديدة تم تعلّمها بين المستخدم، والعنصر، والميّزات السياقية. يتكون من مكونين رئيسيين:

### 1. عامل المصفوفة المعمم (GMF)

يستخدم عامل المصفوفة المعمّم، المشار إليه بطبقة GMF في الشكل 20، وظيفة خطيّة يتم تعلّمها من خلال دمج تضمينات المستخدم والعنصر بطريقة One-Hot Encoding.

### 2. الشبكة العصبونية متعددة الطبقات MLP.

تمنح هذه الشبكة النموذج قدرًا كبيرًا من المرونة واللاخطية، في تعلّم التفاعلات بين المستخدم، والعنصر، وتمثيلات المتجه السياقي (السياقات الكامنة الصريحة وغير الهرمية والهرمية).



الشكل (21): تعزيز نموذج عامل المصفوفة العصبوني Neu-MF بإضافة المعلومات السياقية المضمّنة

يتضمن الجدول التالي توصيف لمجموعات البيانات التي استخدمها [55] في بناء النموذج.

المجال المستخدم	التفاعلات (عنصر - مستخدم)	الميزات السياقية	عدد العناصر	عدد المستخدمين	مجموعة البيانات
(1 dislike) (3 like) (5 check-in)	38,900	247	1918	98	CARS
0-4.46	96,203	22	4082	957	Frappe
1-5	3,383,536	9	80796	451,341	Yelp

الجدول (2): توصيف مجموعات البيانات المستخدمة

في النماذج المقترحة تم تقسيم البيانات إلى 10 مجموعات فرعية، ومن ثم تقسيم كل مجموعة فرعية، بشكل عشوائي إلى ثلاثة أجزاء: 80% للتدريب، و 10% للتحقق، و 10% للاختبار. استُخدمت مجموعة التحقق، لضبط المعلمّات الفائقة لتدريب نموذج التوصية Tuning Hyperparameters، وتم إجراء مقارنة الأداء النهائية على مجموعة الاختبار وأخذ متوسط التجارب العشر كنتيجة نهائية.

كما طُبّق تقسيم زمني على مجموعتي البيانات CARS و Yelp التي تتضمن ميزة الطابع الزمني Timestamp، حيث قُسمت البيانات تاريخياً إلى جزأين زمنيين؛ وتم تدريب نموذج التنبؤ على الجزء الأول من البيانات، وقياس أداء النموذج على الجزء الثاني من البيانات، والتقسيم كان 80:20. استُخدم لتقييم دقة نماذج التوصية مقياسي RMSE و MAE، وأظهر [55] أن نموذج التعلّم العميق DL-MF عند إضافة السياق أفضل من نموذج MF التقليدي (الجدول 3).

		CARS Rating Prediction				Yelp Dataset Rating Prediction				Frappe Dataset 10-CV Fold App Usage Prediction	
		10-Fold CV		Time-Based		10-Fold CV		Time-Based		RMSE	MAE
Model Type	Model	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
Non-neural baselines	MF	0.614	0.5	0.487	0.396	1.16	0.89	2.19	1.698	0.786	0.624
	FM*	0.59	0.48	0.468	0.356	1.141	0.881	1.9	1.446	0.71	0.55
	ECM	0.602	0.488	0.481	0.319	1.146	0.883	1.81	1.332	0.69	0.523
	LCM	0.51	0.426	0.395	0.301	1.132	0.871	1.71	1.286	0.689	0.522
Neural- CF baselines	NCF	0.431	0.362	0.372	0.315	1.078	0.8	1.54	1.25	0.692	0.528
	NeuMF	0.416	0.338	0.356	0.28	1.026	0.762	1.471	1.19	0.685	0.52
Deep Context- Aware Models	$ECAM_{NCF}$	0.419	0.357	0.361	0.306	0.971	0.73	1.43	1.16	0.679	0.5
	$UCAM_{NCF}$	0.407	0.346	0.353	0.292	0.959	0.69	1.42	1.13	0.668	0.43
	$HCAM_{NCF}$	0.396	0.335	0.341	0.284	0.881	0.6	1.35	1.09	0.591	0.355
	$ECAM_{NeuMF}$	0.41	0.332	0.354	0.29	0.95	0.713	1.394	1.12	0.654	0.42
	$UCAM_{NeuMF}$	0.392	0.319	0.343	0.278	0.931	0.679	1.379	1.1	0.633	0.396
	$HCAM_{NeuMF}$	0.381	0.308	0.33	0.243	0.862	0.587	1.311	1.077	0.578	0.349

الجدول (3): مقارنة نتائج النماذج المطبقة مع النماذج التقليدية بدون إضافة السياق Context

\* FM: آلات التحليل إلى عوامل، هي نهج عام وشامل، تجمع بين عمومية هندسة الميزات، ونماذج تحليل عامل المصفوفة، في تقدير التفاعلات بين المتغيرات الفئوية Categorical.

استخدم [55] برمجية LibFM، وهي برمجية لآلات التحليل إلى عوامل، التي تتميز بعدة تقنيات منها الانحدار التدريجي العشوائي Stochastic Gradient Descent (SGD) وتحسين المربعات الصغرى البديلة (ALS) Alternating Least Squares إضافة إلى استدلال بايز باستخدام سلسلة ماركوف مونت كارلو Bayesian inference Markov Chain Monte Carlo (MCMC).

## الفصل الرابع

نستعرض في هذا الفصل النماذج المقترحة،  
والنتائج الخاصة بكل نموذج ونختم هذا الفصل بتحليل النتائج.

## 1.4 مقدمة

كما ذكرنا سابقاً، تعتمد معظم نظم التوصية في تقديم الترشيحات للعناصر التي قد تهتم المستخدم، على المستخدمين والعناصر فقط، دون الأخذ بالاعتبار السياق الزمني للمستخدم بعملية التوصية، وتكمن مشكلة البحث في غياب السياق الزمني في حساب التوصيات، لذلك تم اقتراح عدّة نماذج تدمج هذا السياق في عملية التوصية، ونقصد بالسياق الزمني في بحثنا، هو وقت تقييم المستخدم للعناصر. ومن أجل تقييم أداء النماذج المقترحة استخدمنا مقياس الدقة التنبؤية MAE، ومقاييس دقة الترتيب MRR و NDCG.

## 2.4 مجموعة المعطيات Dataset

اعتمدنا في هذا البحث على مجموعة المعطيات ML-Small-Latest، وهي مجموعة توصية للأفلام، تمثّل تصنيف من 5 نجوم، إضافة إلى تعليقات نصيّة من قبل المستخدم للأفلام، وتحتوي على 100836 تصنيف لمجموعة مؤلفة من 9742 فيلم، و 3683 تعليق، تم إنشاؤهم من قبل مجموعة مؤلفة من 610 مستخدم ضمن المجال الزمني بين 29 آذار 1996 و 24 أيلول 2018، وأنشئت بتاريخ 26 أيلول 2018. تم اختيار المستخدمين عشوائياً، ولم يتم تضمين المعلومات الديموغرافية للمستخدمين. يتم تمثيل كل مستخدم بمعرف خاص Id، ولاتتوفر أي معلومات أخرى عن المستخدمين. تحتوي مجموعة المعطيات على الطابع الزمني Timestamp، الذي يشير إلى وقت تقييم المستخدم لهذه العناصر، وهو الأساس الذي اعتمدنا عليه في البحث الجدول (4). كما تحتوي هذه المجموعة على ملفات تتضمن روابط الأفلام Links وكذلك توصيف الأفلام وأنواعها Movies، وملف تقييمات المستخدمين Ratings، وملف التعليقات Tags، يتضمن تعليقات المستخدمين على الأفلام التي شاهدوها.

نوع البيانات	عدد التقييمات	عدد المستخدمين	عدد العناصر	نوع التقييم	المجال الزمني لمجموعة المعطيات	تناثر المعطيات
أفلام	100836	610	9742	Star Rating (1-5)	من 29 آذار 1996 لغاية 24 أيلول 2018	98.3%

الجدول (4): توصيف مجموعة البيانات المستخدمة

#### 4.3 المعالجة المسبقة لمجموعة المعطيات Preprocessing

في البداية، وقبل إدخال البيانات ضمن النموذج المعتمد على الذاكرة، من الضروري تصفية الأفلام والمستخدمين ذوي عدد التقييمات المنخفضة؛ لإزالة الضجيج الناتج من القيم المتطرفة، حيث وضعنا عتبة لأقل عدد من التقييمات التي يجب أن يحصل عليها الفيلم وهي 2، كذلك يجب أن يكون المستخدم قد قِيم على الأقل 25 فيلم، إضافة إلى أنه يوجد ضمن الأفلام 18 فيلمًا لم يحصلوا على أي تقييم. الجدول (5) و (6).

عدد الأفلام قبل المعالجة	عدد الأفلام المحذوفة	النسبة
9724	3446	35.44%

الجدول (5): معالجة الأفلام ذات عدد التقييمات المنخفضة

عدد المستخدمين قبل المعالجة	عدد المستخدمين المحذوفين	النسبة
610	67	10.98%

الجدول (6): معالجة المستخدمين ذوي عدد التقييمات المنخفضة

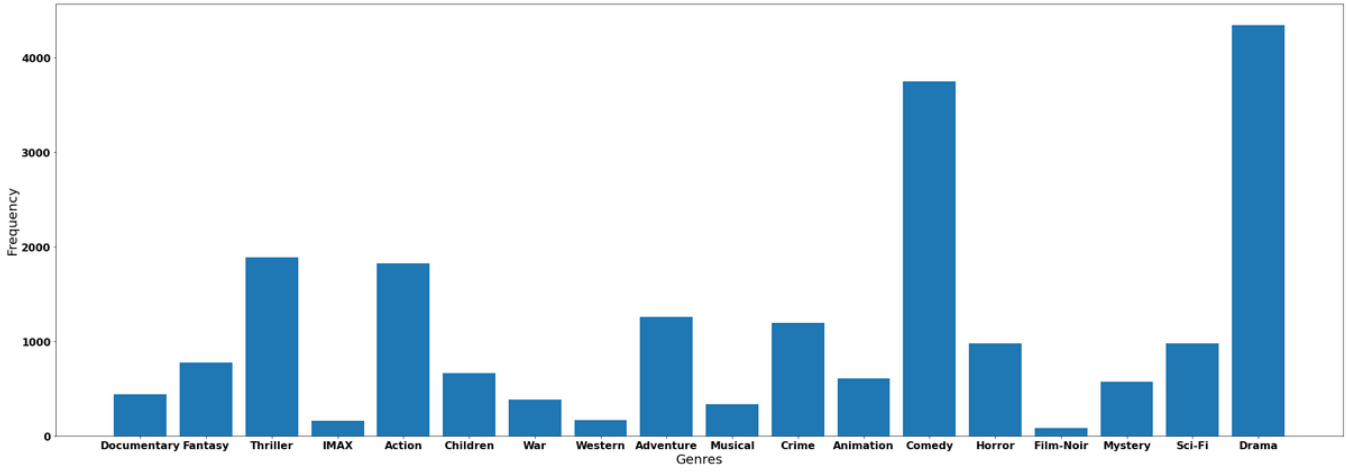
#### • تجنب الانحياز

في الواقع نظراً لاختلاف أذواق الأشخاص، وبالتالي قد يكون لديهم أساس مختلف عند إعطاء التقييمات، حيث يميل بعضهم إلى إعطاء درجات عالية بشكل عام، بينما يكون البعض الآخر صارماً جداً، وقد لا يعطي درجات تقييم عالية، على الرغم من رضاهم عن العناصر. لتجنب هذا التحيز، يمكننا طرح متوسط تقييم كل مستخدم لجميع العناصر عند حساب المتوسط المرجح.

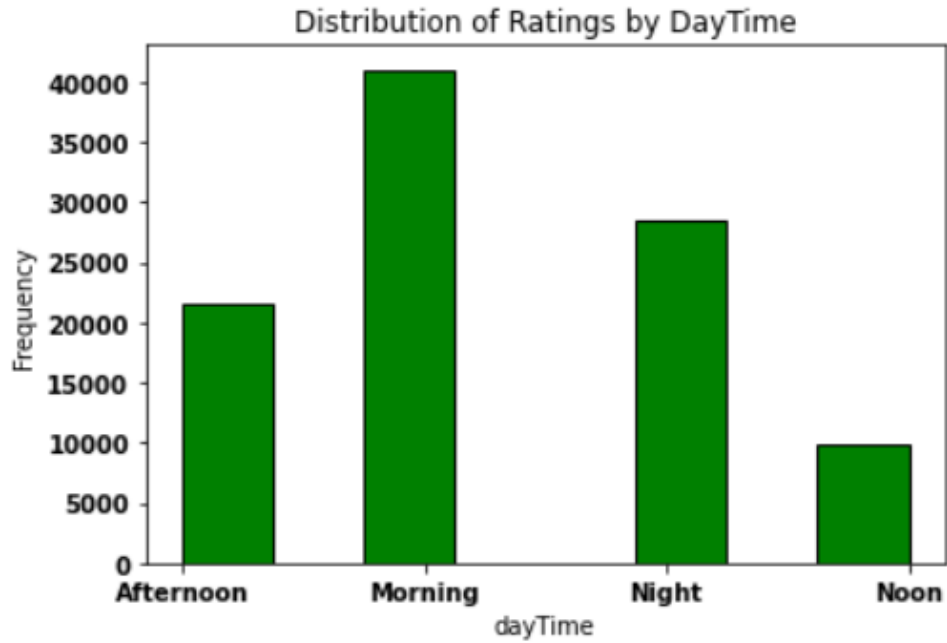
$$r_{new(u,i)} = r_{(u,i)} - \bar{r}_u \quad (39)$$

قمنا بتجنب الانحياز في النموذج المعتمد على الذاكرة فقط، بينما في نموذج التعلم العميق، قمنا بعملية تسوية Normalization للتقييمات باستخدام MinMax Scaler التي سنأتي على ذكرها لاحقاً.


#### 4.4 توزع مجموعة المعطيات




الشكل (22): توزع أنواع الأفلام ضمن مجموعة البيانات




الشكل (23): توزع التقييمات بالنسبة للوقت من اليوم



الشكل (24): توزيع التقييمات بالنسبة لفصول السنة



الشكل (25): توزيع التقييمات بالنسبة لوقت الإِسبوع (يوم عمل - يوم عطلة)



الشكل (26): توزيع التقييمات بالنسبة لسنوات التقييم

#### 5.4 حساب التقييم بحالة نموذج غير مدرك للوقت Time Free

في حالة النموذج غير المدرك للزمن نرمز له بـ  $f$  تقدر درجة ملائمة العنصر  $i$  للمستخدم  $u$  وفق العلاقة 40:

$$relevance^f(u, i) = \frac{\sum_{u' \in P(u, Q) \cap Z_i} Sim(u, u') \times preference(u', i)}{\sum_{u' \in P(u, Q) \cap Z_i} Sim(u, u')} \quad (40)$$

1. تمثل  $Z_i$  مجموعة المستخدمين الذين قيّموا العنصر  $i$ .
2. تمثل  $preference(u', i)$  تقييم المستخدم  $u'$  للعنصر  $i$ .
3.  $Sim(u, u')$  تشابه المستخدم  $u$  مع  $u'$  وفق معيار تشابه معين.
4.  $P(u, Q)$  تمثل مجموعة المستخدمين المشابهين لـ  $u$  من أجل استعمال معين  $Q$ . لكن في هذه الأطروحة، لن نعتمد مفهوم الاستعلام من قبل المستخدم، أي لن نقدم التوصيات بالأفلام بناء على استعمال يكتبه المستخدم، وإنما سنوصي بالعناصر الأكثر ملائمة للمستخدم بشكل عام. لذلك يمكن اعتبار  $P(u, Q)$  هي المستخدمين المشابهين للمستخدم الهدف ضمن كامل مجموعة المعطيات، وليس بالنسبة لاستعلام ما. أي  $P(u, Q) = S_u$  حيث  $S_u$  مجموعة المستخدمين المشابهين للمستخدم  $u$ . ويتم أخذ المستخدمين المشابهين الذين حققوا تشابه أعلى من عتبة ما Threshold بحسب معيار تشابه معين.

أجرى [62] دراسة لتأثير معايير التشابه على نماذج الترشيح التعاوني، ووصل إلى نتيجة أن معامل PCC أعطى أفضل نتيجة في حالة الترشيح التعاوني المعتمد على المستخدم، لذلك اعتمدنا في هذه الأطروحة على معيار التشابه PCC وأخذنا عدة عتبات للتشابه، كلما زادت قيمة العتبة قلت مجموعة المستخدمين المشابهين. نظراً لوفرة العناصر في تطبيق التوصية، لا يقوم المستخدمون، حتى الخبراء منهم، بتقييم سوى جزء صغير منها. لذلك، عادة ما يُطرح السؤال التالي: ما مدى ثقة درجات الملاءمة المرتبطة بالعناصر الموصى بها؟ للتعامل مع هذه المشكلة، نقدم مفهوم الدعم Support لكل عنصر مرشح  $i$  لأن يبدي المستخدم  $u$  تفضيلاً

له والذي يحدد كم النسبة من المستخدمين المشابهين للمستخدم  $u$  الذين أبدوا تفضيلاً للعنصر  $i$ . العلاقة (41).

$$Support^f(u, i) = \frac{|S_u \cap Z_i|}{|S_u|} \quad (41)$$

تعبّر فكرة الدعم عن مدى موثوقية تقديرنا لدرجة ملائمة العنصر  $i$ . ولتقدير أهمية توصية عنصر ما لمستخدم، نفتح الجمع بين درجة الملائمة المحسوبة بالعلاقة 40 والدعم في العلاقة 41 ضمن تابع تجميعي (تابع القيمة Value-Function)

$$value^f(u, i) = \sigma \times relevance^f(u, i) + (1 - \sigma) \times Support^f(u, i) \quad (42)$$

#### 4.6 النماذج المدركة للوقت والمعتمدة على الذاكرة Memory-Based

##### 1.6.4 نموذج النافذة المتخامدة Damped Window

يستند هذا النموذج على فكرة إدراج كل تقييمات المستخدمين المشابهين للمستخدم الهدف، وتثقيل كل تقييم حسب أهميته زمنياً، أي اعتبار التقييمات الأكثر حداثة (آخر فترة زمنية قريبة من المستخدم) أكثر أهمية مقارنة بالتقييمات القديمة، بالاعتماد على تابع انحلال زمني Time Decay Function، وبالتالي تتعامل مع مشكلة التحوّل في تفضيلات المستخدم بسلاسة أو بشكل جذري. تستخدم التطبيقات الزمنية التخامد الأسي، وبالتالي فإن وزن التفضيل  $Preference(u, i)$  يتناقص بشكل كبير مع الوقت عبر تابع الانحلال الزمني.

$$f(t) = 2^{-\lambda(t-t_{u',i})} \quad (43)$$

تعبّر  $t_{u',i}$  عن وقت تقييم المستخدم  $u'$  للعنصر  $i$ ، بينما تعبّر  $t$  عن الوقت الحالي، وتعبّر  $\lambda$  عن درجة حساسية التابع بالنسبة للزمن، وهي قيمة موجبة دوماً  $\lambda > 0$ ، كلما زادت قيمتها كلما قلت أهمية التقييمات التاريخية مقارنة بالتقييمات الأكثر حداثة. وباختيار قيمتها مساوية للصفر نحصل على نموذج غير مدرك للوقت أي تصبح قيمة التابع مساوية لـ 1 ويكون لكل التقييمات الوزن نفسه.

$$relevance^d(u, i) = \frac{\sum_{u' \in S_u \cap Z_i} 2^{-\lambda(t-t_{u',i})} \times Sim(u, u') \times preference(u', i)}{\sum_{u' \in S_u \cap Z_i} Sim(u, u')} \quad (44)$$

يتم تثقيل كل تقييم بتابع الحدثة (الانحلال الزمني) المعرف بالعلاقة 44.

بالنسبة للدعم المدرك للزمن، والمتعلق بكل عنصر، كوننا أخذنا جميع التقييمات بالاعتبار لذلك يكون الدعم مساوٍ لحالة النموذج غير المدرك للوقت بالعلاقة (45).

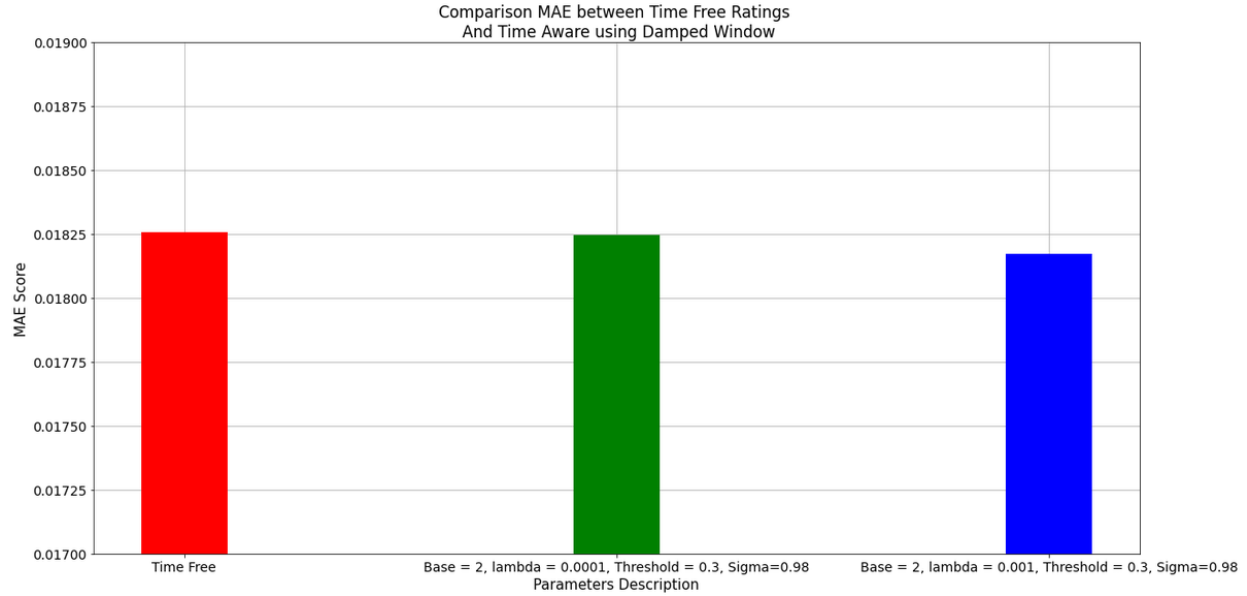
$$Support^f(u, i) = Support^d(u, i) \quad (45)$$

وبالنسبة لتابع القيمة الكلي لكل عنصر نعرّفه بالعلاقة 46:

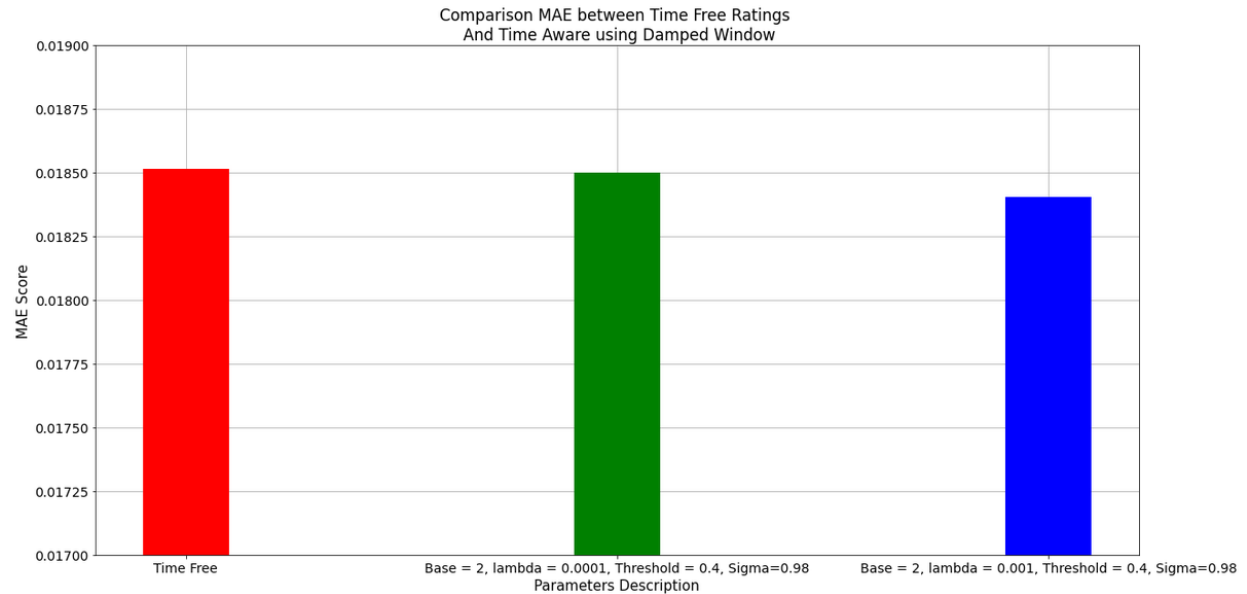
$$value^d(u, i) = \sigma \times relevance^d(u, i) + (1 - \sigma) \times Support^d(u, i) \quad (46)$$

تشير  $d$  إلى مصطلح النافذة المتخامدة Damped Window.

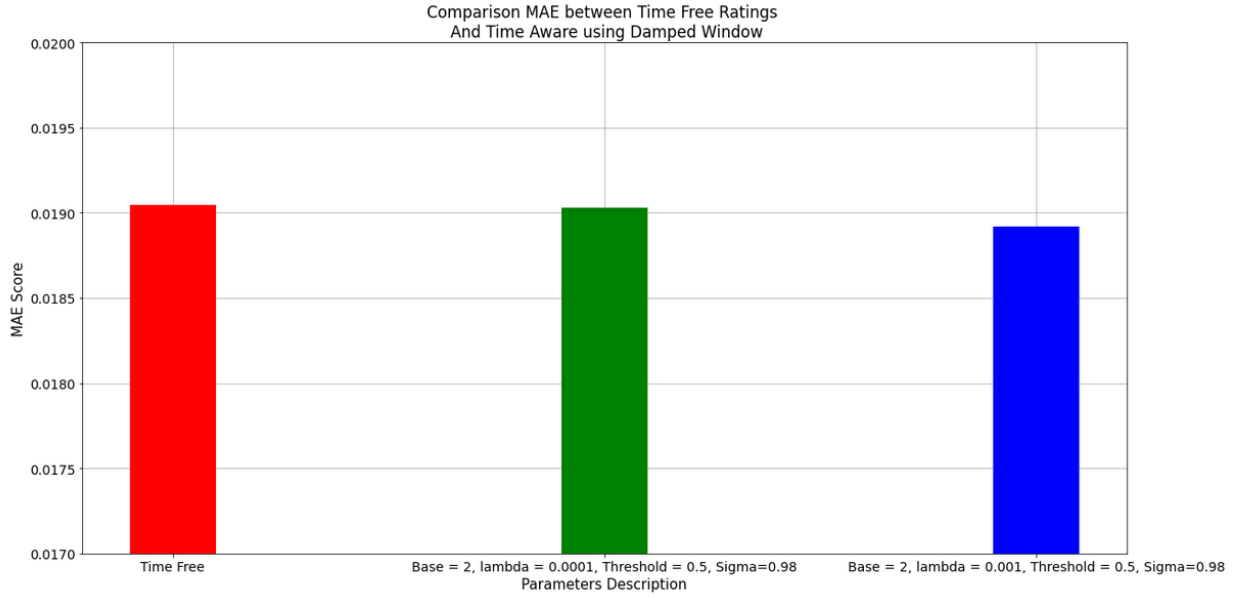
للمقارنة بين هذا النموذج والنموذج غير المدرك للوقت، اعتمدنا على مقياس الدقة التنبؤية MAE، بعد أخذ عدّة عتبات تشابه، واختبار هذا النموذج نقوم باختيار عدّة قيم لمقدار الحساسية  $\lambda$ ، ومن أجل معامل تابع القيمة  $\sigma$  اخترنا القيمة  $\sigma = 0.98$ .



الشكل (27): مقارنة بين نموذج النافذة المتخادمة والنموذج غير المدرك للوقت باختيار عتبة التشابه  $\text{Threshold} = 0.3$  واختيار  $\text{Sigma} = 0.98$  من أجل عدّة قيم للحساسية.



الشكل (28): مقارنة بين نموذج النافذة المتخادمة والنموذج غير المدرك للوقت باختيار عتبة التشابه  $\text{Threshold} = 0.4$  واختيار  $\text{Sigma} = 0.98$  من أجل عدّة قيم للحساسية.



الشكل (29): مقارنة بين نموذج النافذة المتخادمة والنموذج غير المدرك للوقت باختيار عتبة التشابه  $\text{Threshold} = 0.5$  واختيار  $\text{Sigma} = 0.98$  من أجل عدة قيم للحساسية.

النموذج	عتبة التشابه	مقدار الحساسية	معامل تابع القيمة $\sigma$	قيمة MAE	نسبة تحسين الخطأ
غير المدرك للوقت Time-Free	0.3	0	0.98	0.01826	-
مدرك للوقت Time-Aware	0.3	0.0001	0.98	0.01825	0.05%
	0.3	0.001	0.98	0.01817	0.49%

الجدول (7): مقارنة نموذج النافذة المتخادمة المدرك للوقت مع نموذج غير مدرك للوقت بأخذ عتبة تشابه 0.3

النموذج	عتبة التشابه	مقدار الحساسية	معامل تابع القيمة $\sigma$	قيمة MAE	نسبة تحسين الخطأ
غير المدرك للوقت Time-Free	0.4	0	0.98	0.01851	-
مدرك للوقت Time-Aware	0.4	0.0001	0.98	0.01850	0.05%
	0.4	0.001	0.98	0.01840	0.59%

الجدول (8): مقارنة نموذج النافذة المتخادمة المدرك للوقت مع نموذج غير مدرك للوقت بأخذ عتبة تشابه 0.4

النموذج	عتبة التشابه	مقدار الحساسية	معامل تابع القيمة $\sigma$	قيمة MAE	نسبة تحسن الخطأ
غير المدرك للوقت Time-Free	0.5	0	0.98	0.01905	-
مدرك للوقت Time-Aware	0.5	0.0001	0.98	0.01903	0.1%
	0.5	0.001	0.98	0.01892	0.68%

الجدول (9): مقارنة نموذج النافذة المتخادمة المدرك للوقت مع نموذج غير مدرك للوقت بأخذ عتبة تشابه 0.5

## 2.6.4 نموذج النافذة الزمنية المنزلقة Sliding Window

### 1. نموذج النافذة الزمنية المنزلقة مع تشابه ثابت SSSW (Static Similarity SW)

الطريقة الثانية التي تعتمد على الأخذ بالاعتبار حداثة التقييمات زمنياً هي النافذة المنزلقة، وعلى العكس من نموذج النافذة المتخادمة، تأخذ النافذة الزمنية المنزلقة جزءاً من التقييمات المتاحة، وبخاصة الأحداث منها فقط، حسب حجم النافذة الزمنية  $W$ ، دون أن تعطي التقييمات ضمن النافذة أي وزن، يمكن أن نتخيل النافذة الزمنية بأننا نأخذ التقييمات من المستخدمين المشابهين آخر سنة أو آخر 5 سنين أو آخر 10 سنين أو من وجهة نظر أخرى أخذ أحدث 1000 تقييم. بفرض أن حجم النافذة هو  $W$  سنة، نعتبر تقييم المستخدم المشابه نشطاً، ويؤخذ بالاعتبار إذا تحققت العلاقة (47).

$$t_{u,i} \text{ is active if } t_{u,i} > t - W \quad (47)$$

ونحسب درجة ملائمة العنصر، وكذلك الدعم، وتابع القيمة الكلي للتقييم المقدّر، بالعلاقات 48 و 49 و 50 على الترتيب.

$$relevance^s(u, i) = \frac{\sum_{u' \in (S_u \cap \chi_i)} \times Sim(u, u') \times preference(u', i)}{\sum_{u' \in u' \in (S_u \cap \chi_i)} Sim(u, u')} \quad (48)$$

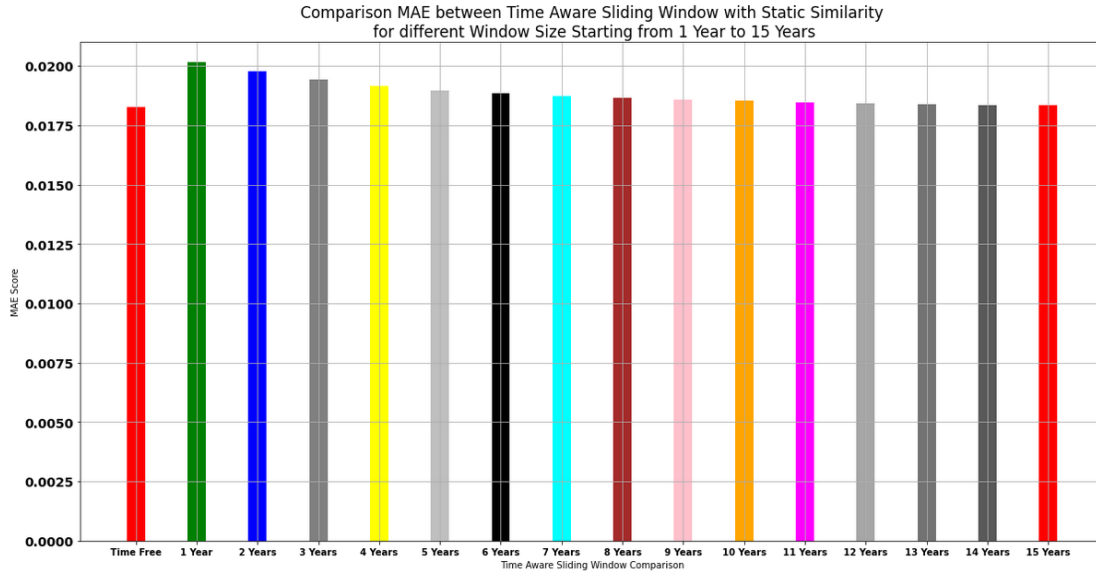
تمثل  $\chi_i$  مجموعة جزئية من  $Z_i$  بحيث تحقق أن  $\forall u' \in \chi_i, t_{u',i} > t - W$

$$Support^s(u, i) = \frac{|S_u \cap \chi_i|}{|S_u|} \quad (49)$$

$$value^s(u, i) = \sigma \times relevance^s(u, i) + (1 - \sigma) \times Support^s(u, i) \quad (50)$$

نلاحظ وضوحاً أن  $Support^s(u, i) \leq Support^d(u, i)$  ذلك أن  $|\chi_i| \leq |Z_i|$  حسب طول النافذة المأخوذة.

من أجل اختبار النموذج، اعتمدنا على نافذة لها طول زمني سنة، وعدّلنا طولها بدءاً من سنة ولغاية 15 سنة، ثم قارنا مع نموذج غير مدرك للوقت بأخذ نافذة زمنية على كامل مجموعة المعطيات ونحسب التشابه على أساس كامل التقييمات ضمنها، ثم اعتمدنا على مقياس الدقة التنبؤية MAE، بعد أخذ عدّة أطوال للنافذة الشكل (29). من الجدير بالذكر أننا أخذنا عتبة التشابه 0.3 أثناء المقارنة في كلا النموذجين.



الشكل (30): مقارنة النافذة الزمنية المنزقة مع نموذج غير مدرك للوقت باستخدام نافذة ذات أطوال متغيرة بدءاً من سنة ولغاية 15 سنة

MAE Score	طول النافذة مقدرة بالسنوات (Years)
0.02015	1
0.01978	2
0.01942	3
0.01915	4
0.01896	5
0.01886	6
0.01875	7
0.01867	8
0.01858	9
0.01852	10
0.01847	11
0.01843	12
0.01839	13
0.01835	14
0.01834	15
0.01826	22 (Time-Free)

الجدول (10): مقارنة قيم MAE بين نموذج النافذة المنزقة والنموذج غير المدرك للوقت بأخذ عدة أطوال للنافذة

أوقفنا الاختبار عند طول 15 سنة، لأنه لاحظنا على الرغم أن الخطأ يتناقص بزيادة طول النافذة، لكن التناقص بطيء، ونتوقع أنه سيصل في النهاية ليساوي الخطأ المحسوب عند طول نافذة 22 سنة، وهو النموذج غير المدرك للوقت، دون أن يكون هناك تحسن ملحوظ؛ لأن عدد العناصر (الأفلام) وعدد المستخدمين المشابهين، يقل كلما قل طول النافذة المأخوذة مقارنة بكامل مجموعة المعطيات، وبالتالي يزداد الخطأ كلما قل طول النافذة.

نلاحظ بعد الاختبار، أن النموذج لم يعط النتيجة المرجوة، وبقي النموذج غير المدرك للوقت أفضل من نموذج النافذة المنزلقة من ناحية الخطأ التنبؤي MAE.

إن  $Sim(u, u')$  في نموذج النافذة الزمنية المنزلقة السابق، محسوب على كامل مجموعة المعطيات، وليس على أساس النافذة المأخوذة، لذا يمكن اعتباره تشابه ثابت Static Similarity، ندرس في هذه الأطروحة أيضاً حالة أن يكون  $Sim(u, u')$  محسوب على أساس نافذة زمنية أي Dynamic Similarity، ذلك أنه أقرب للواقع، حيث أن المستخدمين  $u, u'$  لن يحافظا على نفس نسبة التشابه لمدة زمنية طويلة، إذ يمكن أن تزيد، أو تنقص حسب عدة عوامل مؤثرة، مثل ابتعاد أو تقرب المستخدمين من بعضهما بفترة زمنية معينة. إضافة إلى تغير تفضيلات هذين المستخدمين عبر الزمن نظراً لظروف حياتية ما (عمل - زواج - سفر ... إلخ).

## 2. نموذج النافذة الزمنية المنزلقة مع تشابه متغير DSSW (Dynamic Similarity SW)

في هذا النموذج، قمنا بإعادة نموذج النافذة الزمنية المنزلقة السابق، لكن بدلاً من أخذ تشابه بين المستخدمين محسوب على كامل مجموعة المعطيات، أخذنا تشابه جزئي محسوب على أساس نافذة زمنية معينة، تختلف عن النافذة الزمنية التي نحسب على أساسها درجة ملائمة العناصر العلاقة (51)، لتوضيح ذلك، قمنا في النموذج السابق بحساب درجة ملائمة العناصر للمستخدم بأخذ تقييمات المستخدمين للعناصر ضمن 5 سنوات فقط، لكن تم أخذ التشابه بين المستخدمين في علاقة حساب درجة الملائمة (46) على كامل مجموعة المعطيات، أي على نافذة طولها 22 سنة، بينما في هذا النموذج سنغير قيم التشابه بين المستخدمين، بدءاً من النافذة التي يتم حساب التقييمات على أساسها. (مثلاً في حالة حساب درجة الملائمة ضمن 5 سنوات، قمنا بأخذ عدة قيم للتشابه، بدءاً من التشابه ضمن 5 سنوات، ومن ثم ضمن 6 سنوات، وهكذا بشكل تصاعدي، ثم درسنا تأثير ذلك على النتائج المحسوبة. أما في حالة حساب درجة الملائمة ضمن 3 سنوات، بدأنا بقيم تشابه ضمن 3 سنوات، ثم 4 وهكذا بشكل تصاعدي). في حالة التشابه المتغير يكون لدينا مجموعة من مصفوفات التشابه، وليس مصفوفة واحدة كما في حالة التشابه الثابت؛ وبما أن النوافذ المحسوب ضمنها التشابه ذات طول من سنة لغاية 22 سنة، لذلك سيكون لدينا 22 مصفوفة تشابه حسب النافذة.

$$PCC_w(u, v) = \frac{\sum_{i \in I_{wu} \cap I_{wv}} (r_{ui} - \bar{r}_u) \cdot (r_{vi} - \bar{r}_v)}{\sqrt{\sum_{i \in I_{wu}} (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_{i \in I_{wv}} (r_{vi} - \bar{r}_v)^2}} \quad (51)$$

حيث:

- $I_{wu} \cap I_{wv}$ : مجموعة العناصر التي قيمتها المستخدمين  $u$  و  $v$  معاً ضمن النافذة الزمنية ذات الطول  $w$  وفيها يكون:  $\forall i \in I_{wu} \cap I_{wv} \Rightarrow t_{u,i} > t - w \wedge t_{v,i} > t - w$
- $I_{wu}, I_{wv}$ : مجموعة العناصر التي قيمتها كل من المستخدمين  $u$  و  $v$  على الترتيب ضمن النافذة الزمنية ذات الطول  $w$ .

اكتفينا في هذه الأطروحة، بدراسة مصفوفات التشابه على نوافذ ذات أطوال من 1 لغاية 20 سنة فقط، لأن معظم المستخدمين في مجموعة المعطيات، قدّموا تقييماتهم للأفلام بشكل مجمع خلال فترة زمنية قصيرة نسبياً، وليس بشكل مستمر على فترة زمنية طويلة.

يمثل الشكلين 30 و 31 مصفوفتي التشابه لنافذتين، الأولى لها طول سنة واحدة، والثانية ذات طول 20 سنة.

	1	2	3	4	5	6	7	8	9	10	...	601	602	603	604	605	606	607	608	609	610
1	1.0	0.0	0.0	0.09954	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	-0.05509	0.00000	0.0	0.00000	0.17456	0.0	0.00000	0.0
2	0.0	1.0	0.0	0.00000	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	0.00000	0.00000	0.0	0.00000	0.00000	0.0	0.00000	0.0
3	0.0	0.0	1.0	0.00000	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	0.00000	0.00000	0.0	0.00000	0.00000	0.0	0.00000	0.0
4	0.0	0.0	0.0	1.00000	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	0.11913	0.00000	0.0	0.00000	0.00000	0.0	0.00000	0.0
5	0.0	0.0	0.0	0.00000	1.0	0.04317	0.0	0.02835	0.0	0.0	...	0.0	0.15330	0.00000	0.06779	0.0	0.00000	0.00000	0.0	0.38411	0.0
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
606	0.0	0.0	0.0	0.00000	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	0.00000	0.00000	0.0	1.00000	0.00000	0.0	0.00000	0.0
607	0.0	0.0	0.0	0.00000	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	-1.00000	0.00000	0.0	0.00000	1.00000	0.0	0.00000	0.0
608	0.0	0.0	0.0	0.00000	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	0.00000	0.00000	0.0	0.08575	0.00000	1.0	0.00000	0.0
609	0.0	0.0	0.0	0.00000	0.0	0.19365	0.0	0.14186	0.0	0.0	...	0.0	0.18851	0.00000	0.64162	0.0	0.00000	0.00000	0.0	1.00000	0.0
610	0.0	0.0	0.0	0.00000	0.0	0.00000	0.0	0.00000	0.0	0.0	...	0.0	0.00000	0.00000	0.00000	0.0	0.00000	0.00000	0.0	0.00000	1.0

543 rows × 543 columns

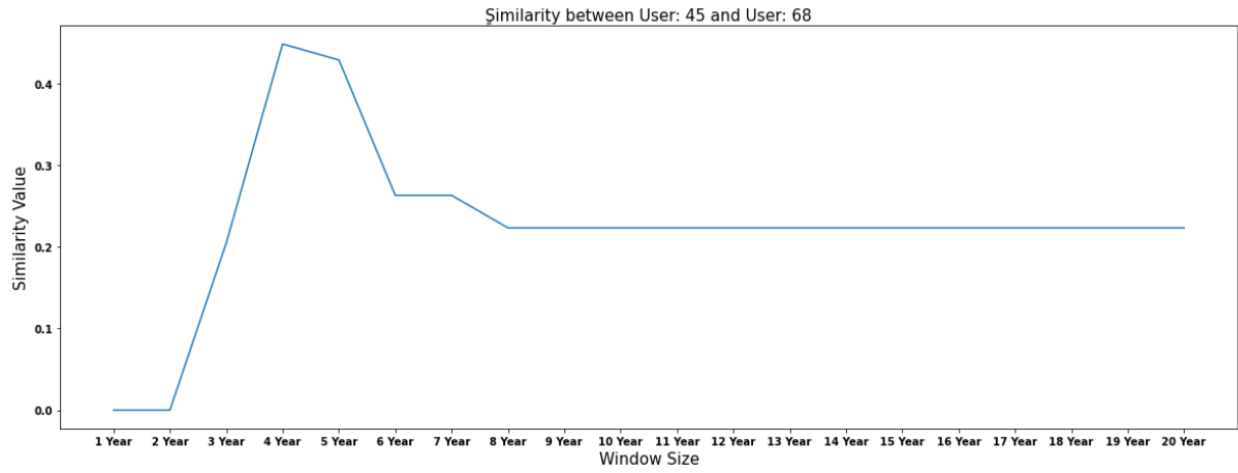
الشكل (31): مصفوفة التشابه بين المستخدمين ضمن نافذة طولها سنة واحدة

	1	2	3	4	5	6	7	8	9	10	...	601	602	603	604	605	606
1	1.00000	0.00000	0.00000	0.09954	0.26875	-0.29164	0.00000	0.46967	0.00000	0.00000	...	0.00000	0.00000	-0.05509	-0.40756	0.00000	0.00000
2	0.00000	1.00000	0.00000	0.00000	0.00000	0.00000	-0.99124	0.00000	0.00000	0.00000	...	0.00000	0.00000	-1.00000	0.00000	0.00000	0.58333
3	0.07982	0.00000	1.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	...	0.00000	0.00000	0.43320	0.00000	0.00000	-0.79133
4	0.20798	0.00000	0.00000	1.00000	-0.33652	0.14850	0.00000	0.11785	0.00000	0.00000	...	0.00000	0.39664	0.09009	-0.08030	0.00000	0.00000
5	0.00000	0.00000	0.00000	0.00000	1.00000	0.04317	0.00000	0.02835	0.00000	0.00000	...	0.00000	0.15330	0.00000	0.06779	0.00000	0.00000
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
606	0.06638	0.00000	-0.79133	0.14460	0.24432	-0.04919	0.13777	0.25358	0.57270	0.00000	...	0.00000	0.14061	0.31847	0.68295	0.16706	1.00000
607	0.17456	0.00000	0.00000	0.11652	0.23108	0.25564	0.00000	0.25128	0.00000	0.00000	...	0.00000	0.21721	0.16252	0.03581	0.00000	0.00000
608	0.26807	0.00000	0.00000	-0.17050	-0.02055	0.12543	0.00808	0.43442	0.33662	0.00000	...	0.00000	0.29765	0.08642	0.05399	0.00000	0.24081
609	0.00000	0.00000	0.00000	0.00000	0.00000	0.19365	0.00000	0.14186	0.00000	0.00000	...	0.00000	0.18851	0.00000	0.64162	0.00000	0.00000
610	-0.03209	0.62329	0.56956	-0.04379	0.00000	0.00000	0.34123	0.00000	0.61564	-0.20508	...	0.1715	0.00000	0.27091	0.00000	0.46227	0.38919

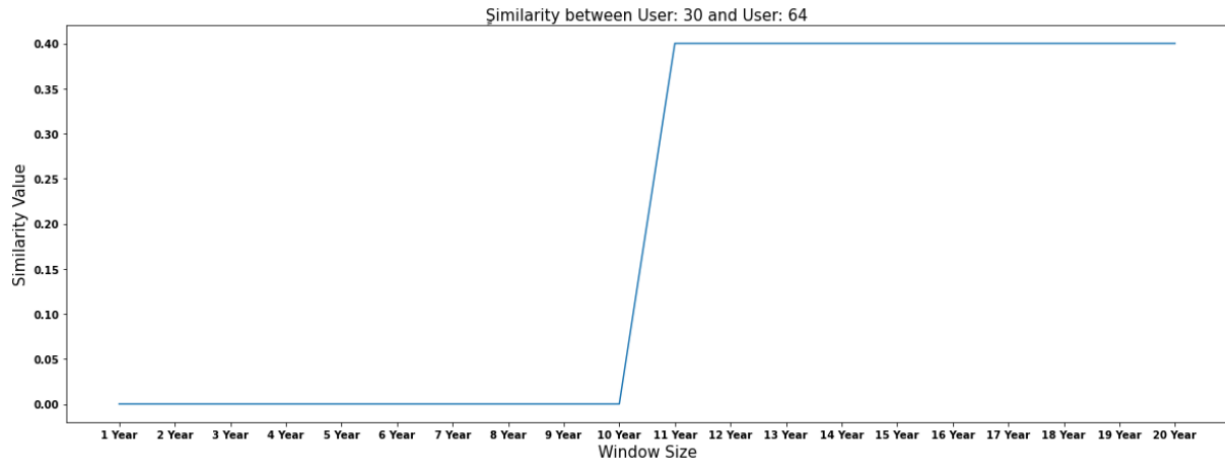
543 rows × 543 columns

الشكل (32): مصفوفة التشابه بين المستخدمين ضمن نافذة طولها 20 سنة

بناء على ما سبق، سيتغير التشابه بين المستخدمين بحسب النافذة المأخوذة؛ يبين الشكل (33) تغير التشابه بين المستخدمين ذوي المعرفين 45 و 68 ضمن 20 سنة.



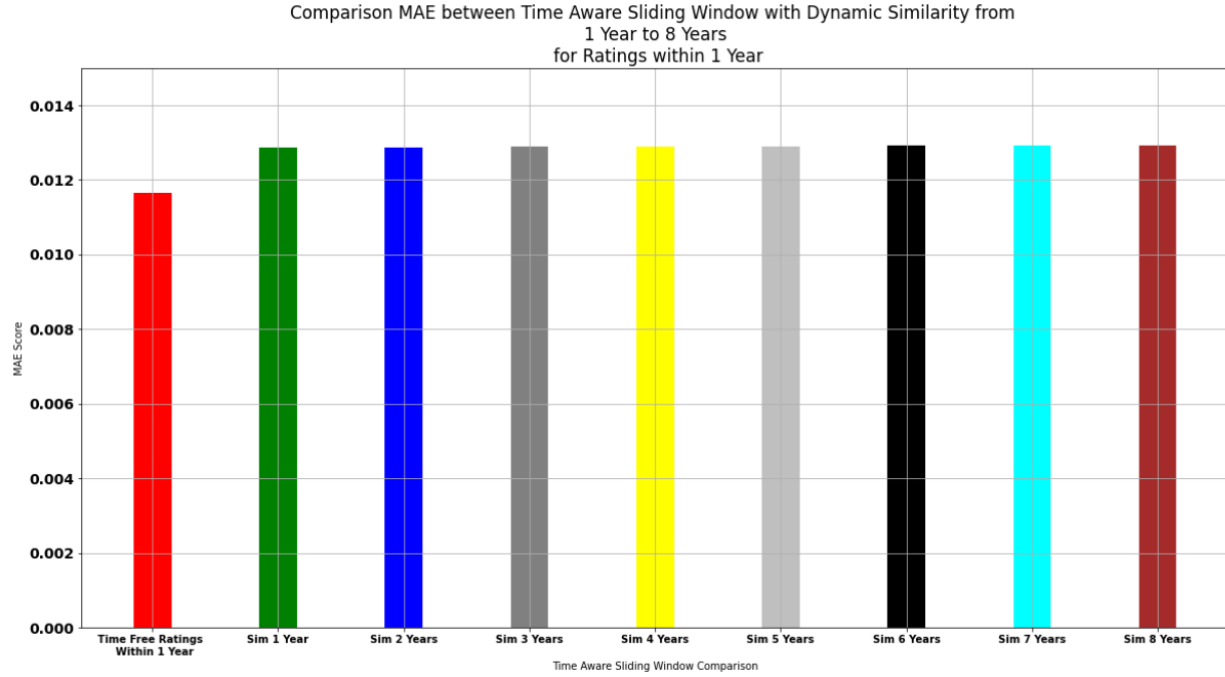
الشكل (33): تغير التشابه بين المستخدمين ذوي المعرفين 45 و 68.



الشكل (34): تغير التشابه بين المستخدمين ذوي المعرفين 30 و 64.

بعد حساب التشابه على النوافذ السنوية السابقة، نبدأ بحساب درجات ملائمة العناصر، ومقارنتها مع نتائج النموذج غير المدرك للوقت، على نفس مجموعة العناصر ضمن النافذة المأخوذة، تم أخذ عتبة التشابه 0.3 أثناء المقارنة في كلا النموذجين.

## 1- MAE في حالة نافذة ذات طول سنة واحدة



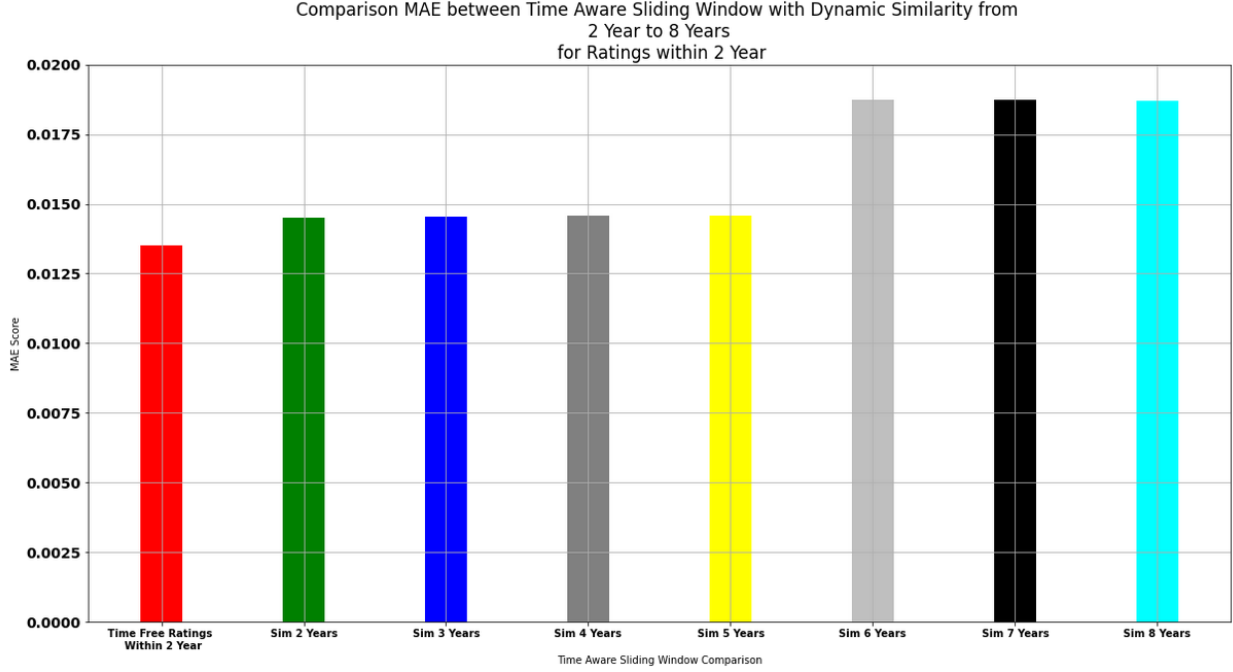
الشكل (35): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (1-8) والنموذج غير المدرك للوقت ضمن نافذة طولها سنة واحدة

MAE Score	طول نافذة التشابه مقدرة بالسنوات (Years)
0.01285	1
0.01287	2
0.01289	3
0.01290	4
0.01290	5
0.01291	6
0.01291	7
0.01291	8
0.01165	Time-Free

الجدول (11): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (1-8) والنموذج غير المدرك للوقت ضمن نافذة طولها سنة واحدة

أوقفنا عملية الحساب، لأنه لاحظنا أن الخطأ يزداد بزيادة طول نافذة التشابه، ومنه نستنتج أن نموذج النافذة المنزلقة ضمن سنة واحدة بتشابه متغير، لم يعطِ النتيجة المرجوة مقارنة بالنموذج غير المدرك للوقت.

## 2- MAE في حالة نافذة ذات طول سنتان



الشكل (36): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (2-8) والنموذج غير المدرك للوقت ضمن نافذة طولها سنتين.


MAE Score	طول نافذة التشابه مقدرة بالسنوات (Years)
0.01452	2
0.01456	3
0.01458	4
0.01457	5
0.01873	6
0.01872	7
0.01873	8
0.01349	Time-Free

الجدول (12): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (2-8) والنموذج غير المدرك للوقت ضمن نافذة طولها سنتين

أيضاً في هذا النموذج أوقفنا عملية الحساب، لأنه لاحظنا أن الخطأ يزداد بزيادة طول نافذة التشابه كما لاحظنا قفزة في الخطأ عند نافذة تشابه 6 سنوات، قد يكون نتيجة انخفاض عدد المستخدمين المشابهين عند نافذة أكبر من 5 سنوات نتيجة انخفاض قيم التشابه (حالة قيم منخفضة في تابع التشابه عند 6 إلى 8

سنوات)، بالإضافة إلى أن عدد المستخدمين المشابهين ضمن نافذة سنتين قليل نسبياً. لاحظنا أن النموذج لم يعطِ النتيجة المرجوة مقارنة بالنموذج غير المدرك للوقت.

### 3- MAE في حالة نافذة ذات طول ثلاث سنوات




الشكل (37): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (3-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 3 سنوات

MAE Score	طول نافذة التشابه مقدرة بالسنوات (Years)
0.01530	3
0.01533	4
0.01534	5
0.01536	6
0.01536	7
0.01537	8
0.01450	Time-Free

الجدول 13: مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (3-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 3 سنوات

أوقفنا عملية الحساب، كما في حالة النوافذ السابقة عند نافذة تشابه 8 سنوات؛ لأن الخطأ يزداد بزيادة طول نافذة التشابه لكن في هذا النموذج، لم تظهر أي قفزة في الخطأ عند نافذة تشابه 6 سنوات، مقارنة بالنموذج السابق لأن التقييمات مأخوذة ضمن 3 سنوات، وبالتالي ازداد عدد المستخدمين المشابهين، مما ساهم بتخفيض الخطأ لكن مازال النموذج غير المدرك للوقت يعطي نتيجة أفضل من حيث دقة التنبؤ.

#### 4- MAE في حالة نافذة ذات طول 4 سنوات



الشكل (38): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (4-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 4 سنوات

MAE Score	طول نافذة التشابه مقدرة بالسنوات (Years)
0.01588	4
0.01589	5
0.01591	6
0.01592	7
0.01593	8
0.01529	Time-Free

الجدول (14): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (4-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 4 سنوات

#### 5- MAE في حالة نافذة ذات طول 5 سنوات

MAE Score	طول نافذة التشابه مقدرة بالسنوات (Years)
0.01615	5
0.01619	6
0.01620	7
0.01621	8
0.01574	Time-Free

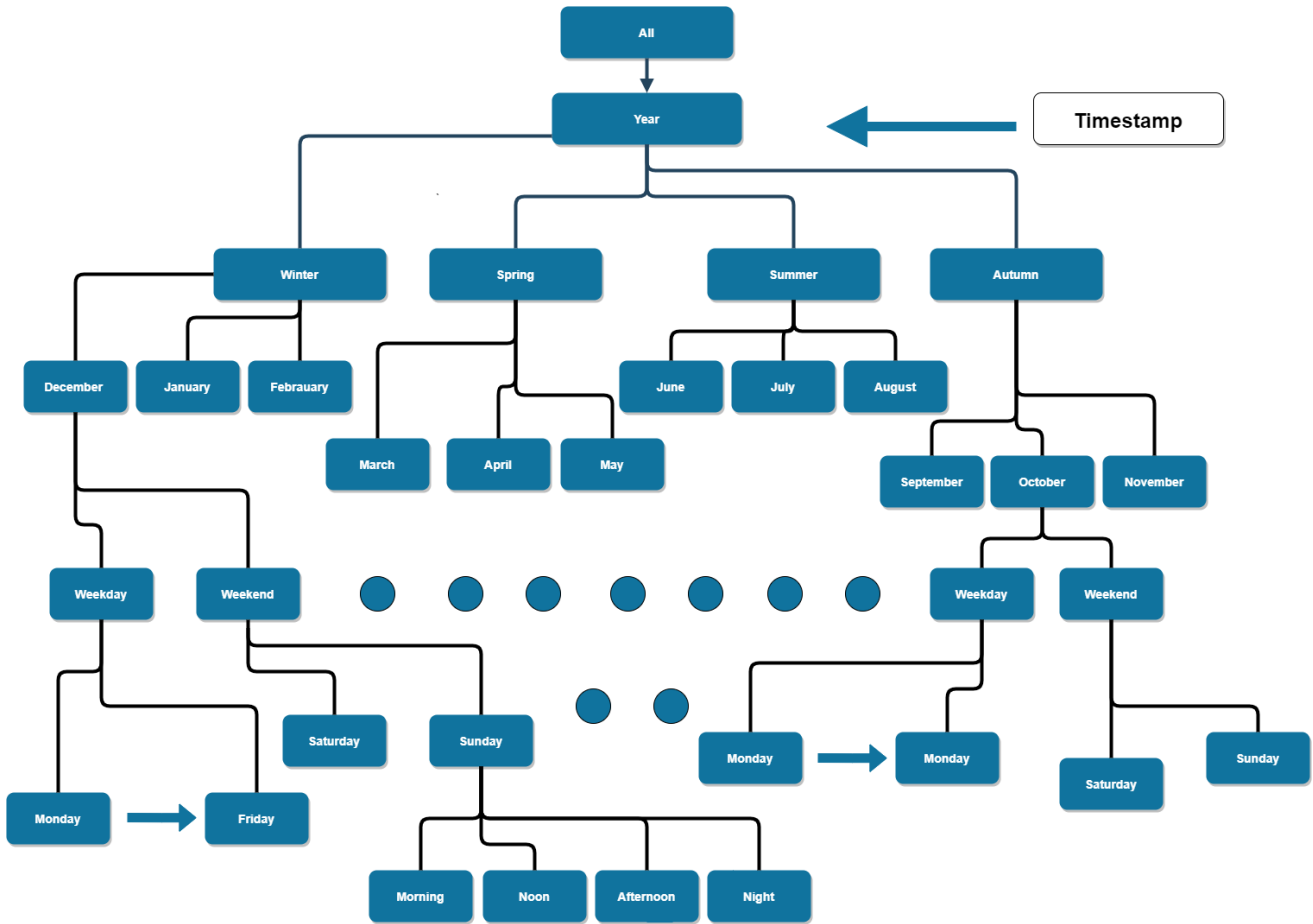
الجدول (15): مقارنة قيم MAE بين نموذج النافذة المنزلقة بتشابه متغير على عدة سنوات (5-8) والنموذج غير المدرك للوقت ضمن نافذة طولها 5 سنوات

نلاحظ من الجدولين السابقين أن الخطأ يزداد بزيادة طول نافذة التشابه، وما زال النموذج غير المدرك للوقت يعطي نتيجة أفضل من حيث دقة التنبؤ.

من النماذج الخمسة السابقة إن MAE لنموذج DSSW أعلى من النموذج غير المدرك للوقت، لكن لاحظنا أن خطأ النموذج يقترب من خطأ TF عند نقطة بداية حساب التشابه (نافذة التشابه مساوية لنافذة التقييمات) بزيادة طول نافذة التقييمات نتيجة زيادة عدد المستخدمين المشابهين.

### 3.6.4 نموذج السياق الزمني Context-Aware RS

قبل البدء بهذا النموذج، قمنا بنمذجة الوقت كميزة متعددة الأبعاد Multidimensional Feature، بالاستفادة من الطابع الزمني Timestamp، التي تمثل الوقت الذي قيّم فيه المستخدم العنصر، أي  $t(u, i)$  تأخذ هذه الأبعاد شكل هرمي Hierarchical كما في الشكل (38).



الشكل (39): تمثيل الوقت بشكل هرمي كميزة متعددة الأبعاد

○ حساب درجة ملائمة العنصر وتابع القيمة في نموذج السياق الزمني CA:

نحسب درجة ملائمة العنصر، وكذلك الدعم وتابع القيمة الكلي للتقييم المقدّر، بالعلاقات 52 و 53 و 54 على الترتيب.

$$relevance^c(u, i) = \frac{\sum_{u' \in (S_u \cap \mathcal{Y}_i)} \times Sim(u, u') \times preference(u', i)}{\sum_{u' \in u' \in (S_u \cap \mathcal{Y}_i)} Sim(u, u')} \quad (52)$$


تمثّل  $\mathcal{Y}_i$  مجموعة جزئية من  $Z_i$  بحيث تحقق أن  $\Theta$

وتمثّل  $\Theta$  السياق الزمني الحالي للمستخدم كمثل: الوقت من الإِسبوع (يوم عطلة - يوم عمل)، أو يوم من الإِسبوع (السبت ... الجمعة)، أو الوقت من اليوم (صباح - ظهر - عصر - مساء).

$$Support^c(u, i) = \frac{|S_u \cap \mathcal{Y}_i|}{|S_u|} \quad (53)$$

$$value^c(u, i) = \sigma \times relevance^c(u, i) + (1 - \sigma) \times Support^c(u, i) \quad (54)$$


قمنا بحساب درجات الملائمة، وتابع القيمة، ضمن عدّة سياقات زمنية، ومن ثمّ مقارنتها مع نموذج غير مدرك للوقت باستعمال معيار الدقّة التنبؤية MAE.



الشكل (40): مقارنة قيم MAE بين نموذج السياق الزمني ونموذج غير مدرك للوقت من أجل عتبة تشابه 0.3

MAE Score	نوع النموذج
0.01770	الوقت من الإِسبوع (يوم عمل – يوم عطلة)
0.01952	نموذج اليوم فقط (سبت، أحد، ..)
0.01861	نموذج الوقت من اليوم (صباح، ظهر، ...)
0.01878	نموذج الفصل (شتاء، ربيع، ..)
0.02048	نموذج الشهر (كانون الثاني، شباط، ....)
0.01825	Time-Free


الجدول (16): مقارنة قيم MAE لنموذج السياق الزمني من أجل عدّة سياقات زمنية باستخدام عتبة تشابه 0.3



الشكل (41): مقارنة قيم MAE بين نموذج السياق الزمني ونموذج غير مدرك للوقت من أجل عتبة تشابه 0.4

MAE Score	نوع النموذج
0.01801	الوقت من الإِسبوع (يوم عمل – يوم عطلة)
0.01969	نموذج اليوم فقط (سبت، أحد، ..)
0.01893	نموذج الوقت من اليوم (صباح، ظهر، ...)
0.01908	نموذج الفصل (شتاء، ربيع، ..)
0.02048	نموذج الشهر (كانون الثاني، شباط، ....)
0.01851	Time-Free

الجدول (17): مقارنة قيم MAE لنموذج السياق الزمني من أجل عدّة سياقات زمنية باستخدام عتبة تشابه 0.4



الشكل (42): مقارنة قيم MAE بين نموذج السياق الزمني ونموذج غير مدرك للوقت من أجل عتبة تشابه 0.5

MAE Score	نوع النموذج
0.01868	الوقت من الإِسبوع (يوم عمل – يوم عطلة)
0.01985	نموذج اليوم فقط (سبت، أحد، ..)
0.01932	نموذج الوقت من اليوم (صباح، ظهر، ...)
0.01940	نموذج الفصل (شتاء، ربيع، ..)
0.02038	نموذج الشهر (كانون الثاني، شباط، ...)
0.01905	Time-Free

الجدول (18): مقارنة قيم MAE لنموذج السياق الزمني من أجل عدّة سياقات زمنية باستخدام عتبة تشابه 0.5

نلاحظ أن نموذج السياق الزمني في حالة الوقت من الإِسبوع، أعطى نتيجة أفضل من النموذج غير المدرك للوقت من أجل عتبات التشابه (0.3، 0.4، 0.5)، نعزو ذلك لأن عدد المستخدمين الأكثر تشابهًا للمستخدم الهدف، يقع في نفس سياق الوقت من الإِسبوع الذي قيّم فيه المستخدم العناصر، كما نلاحظ أن الخطأ يبتعد عن خطأ النموذج غير المدرك للوقت في حالة نموذج الشهر؛ لأن عدد المستخدمين المشابهين يقل كثيرًا بأخذ نفس الشهر الذي قيّم فيه المستخدم العنصر بغض النظر عن عتبة التشابه.

#### 4.7 النموذج المدرك للوقت والمعتمد على التعلّم العميق Neural-TARS

كما ذكرنا سابقاً على المستوى النظري، إن طبيعة نموذج عامل المصفوفة الخطية تصعب عملية كشف العلاقات غير الخطية بين المستخدمين أنفسهم أو بين المستخدمين والعناصر. لذا فإن الفكرة الرئيسية لاستخدام شبكة عصبية عميقة هي تعلم اللاخطية، ومنه زيادة قدرة النموذج على التعبير عن العلاقات. يعتمد النموذج المقترح في الواقع على شبكتين مختلفتين، يتم دمجهما بعد ذلك لحساب النتيجة النهائية. من ناحية، ويأخذ النموذج كمدخل إضافة إلى المستخدمين والعناصر السياق الزمني (الشكل 43) للمستخدم كما سنرى لاحقاً. من جهة لدينا شبكة عامل المصفوفة القياسي GMF، ومن ناحية أخرى لدينا شبكة متعددة الطبقات MLP. الهدف هو الاستفادة من كل من الخطية واللاخطية للشبكتين.

	user	movie	order	date	year	season	month	day	weekend	dayTime
	0	0	1	0	2000-07-30 18:45:03	2000	Summer	July	Sun	1 Afternoon
	1	0	3	2	2000-07-30 18:20:47	2000	Summer	July	Sun	1 Afternoon
	2	0	6	5	2000-07-30 18:37:04	2000	Summer	July	Sun	1 Afternoon
	3	0	47	43	2000-07-30 19:03:35	2000	Summer	July	Sun	1 Night
	4	0	50	46	2000-07-30 18:48:51	2000	Summer	July	Sun	1 Afternoon
	...	...	...	...	...	...	...	...	...	...
100831	609	166534	9416	2017-05-03 21:53:22	2017	Spring	May	Wed	0	Night
100832	609	168248	9443	2017-05-03 22:21:31	2017	Spring	May	Wed	0	Night
100833	609	168250	9444	2017-05-08 19:50:47	2017	Spring	May	Mon	0	Night
100834	609	168252	9445	2017-05-03 21:19:12	2017	Spring	May	Wed	0	Night
100835	609	170875	9485	2017-05-03 21:20:15	2017	Spring	May	Wed	0	Night

الشكل (43): السياق الزمني في مجموعة المعطيات المستخرج من الطابع الزمني Timestamp لكل تقييم

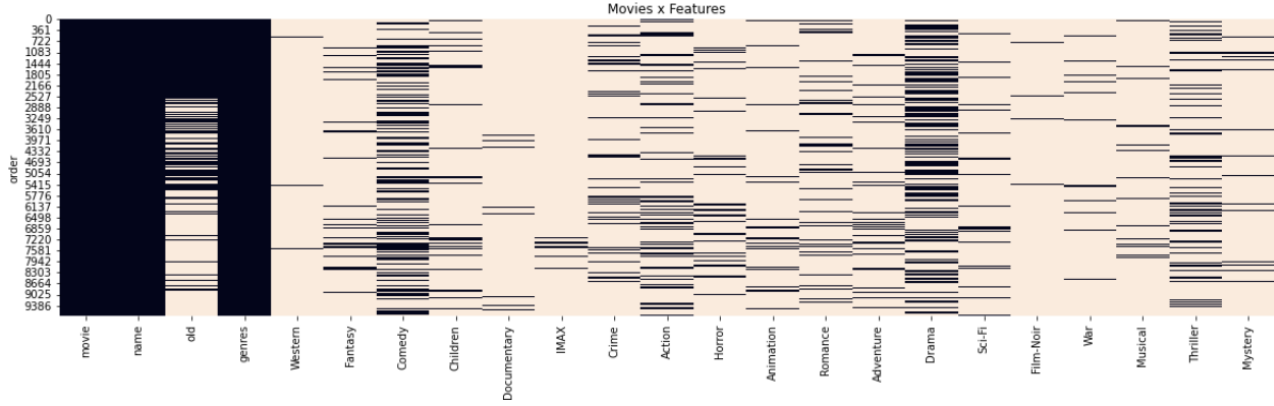
#### • توزع مميزات الأفلام Movies Features

يبين الشكل (45) مميزات الأفلام، وعددها 20 تمثل أنواع الأفلام إضافة إلى ميزة Old، التي تشير إلى قدم الفيلم (إنتاجه تم قبل عام 2000)، استخرجنا هذه المميزات باستخدام نهج Binary Relevance وذلك لتحويل المتغير Genres في مجموعة المعطيات إلى أنواع منفردة الشكل (43).

$$Unique\ Genres = [t_1, t_2, \dots, t_m]$$

X	y		X	t <sub>1</sub>	t <sub>2</sub>	t <sub>3</sub>	t <sub>4</sub>	t <sub>5</sub>
X <sub>1</sub>	[t <sub>2</sub> , t <sub>5</sub> ]	→	X <sub>1</sub>	0	1	0	0	1
X <sub>2</sub>	[t <sub>1</sub> , t <sub>3</sub> , t <sub>2</sub> ]		X <sub>2</sub>	1	1	1	0	0
X <sub>3</sub>	[t <sub>4</sub> ]		X <sub>3</sub>	0	0	0	1	0

الشكل (44): استخراج الأنواع بشكل منفرد



الشكل (45): توزع ميزات الأفلام ضمن مجموعة المعطيات

### • تسوية تقييمات المستخدمين Ratings Normalization

قمنا بتسوية التقييمات ضمن مصفوفة تقييم العناصر، لتصبح في المجال [0,1] باستخدام تقنية MinMax Scaler العلاقة (55).

$$r_{new} = \frac{r - \min}{\max - \min} \quad (55)$$

يتكون نموذج التعلّم العميق من أربعة مكونات رئيسية وهي: النموذج Model، وتابع الكلفة Cost Function، ومجموعة المعطيات (المستخدمين - العناصر - السياق الزمني) التي تمثل دخل Input للنموذج، إضافة إلى خوارزمية الأمثلة Optimization Algorithm.

قمنا بتقسيم عملية التعلّم إلى قسمين: قسم للتدريب Training، وقسم للاختبار Testing، من خلال التدريب يحاول النموذج إيجاد علاقة بين الدخل والخرج وتحسين معيار الأمثلة، وبالتالي تقليص خطأ التدريب. بينما يعبر الاختبار عن مدى جودة النموذج على المعطيات غير المرئية سابقاً.

من أجل عملية المقارنة قمنا ببناء 3 نماذج وهي:

- نموذج عامل المصفوفة القياسي GMF
- ونموذج يدمج خطية عامل المصفوفة مع شبكة متعددة الطبقات Neural-MF
- يهدف هذا النموذج إلى الاستفادة من اللاخطية في الشبكات العصبونية.
- نموذج السياق الزمني Neural-TARS

استخدمنا لتقييم أداء النماذج السابقة المعايير MRR و MAP و NDCG.

## 1. نموذج عامل المصفوفة القياسي GMF

يتألف هذا النموذج من ثلاث طبقات وهي:

- **طبقة الدخل Input Layer:** تأخذ هذه الطبقة مَتَجَّهات المستخدمين والعناصر كدخل للشبكة.
- **طبقة التضمين Embeddings:** تتألف هذه الطبقة من تضمين لكل من المستخدمين والعناصر (الأفلام)، وهي مَتَجَّه يعبر عن كيان معين. في البداية يحوي قيم مهياة بشكل عشوائي ومن ثم يتم تحديثها أثناء تدريب الشبكة العصبونية تمثل هذه القيم العوامل الكامنة Latent Factors، هدفنا هو إيجاد أفضل قيم للتضمين، من أجل التمثيل الصحيح لكل مستخدم وكل فيلم. يمكن تمثيل الكيانات في نظم التوصية كمَتَجَّهات عالية الأبعاد High Dimensional Vectors من التقاط العلاقات المعقدة بينها. في الواقع يمكن النظر لمَتَجَّه تضمين المستخدم على أنه يحمل مَيَّزات هذا المستخدم، على سبيل المثال في مَتَجَّه مكوّن من N بعد قد يمثل البعد الأول مدى إعجاب المستخدم بالخيال العلمي، والبعد الثاني عن مدى إعجابه بأفلام الحركة Action، وهكذا. بينما ينظر لمَتَجَّه تضمين العنصر على أنه يحمل مَيَّزات هذا العنصر مثلاً قد يمثل البعد الأول في مَتَجَّه تضمين فيلم ما مدى كون هذا الفيلم خيالاً علمياً.
- **التقارب في فضاء التضمين:** إذا كان فيلم ومستخدم قريبين في فضاء التضمين، فمن المرجح أن يقوم المستخدم بتصنيف هذا الفيلم بدرجة عالية، أشهر طريقة للتقاط التقارب هي من خلال حاصل الضرب النقطي Dot Product.

- **طبقة الخرج Output Layer:** تعطي هذه الطبقة قيم التقييم المتوقعة، يمكن أن تحوي خلية عصبونية وحيدة أو أكثر، في حالتنا، هناك خلية عصبونية واحدة، حيث سيتم توقع قيمة تقييم المستخدم للفيلم.

يمثل هذا النموذج شبكة عصبونية بسيطة. نقوم بعملية إعداد لمَتَجَّهات التضمينات الخاصة بالمستخدمين والعناصر، ثم نقوم بضربها معاً باستخدام الضرب النقطي Dot Product. يمثل الخرج النهائي لدينا طبقة كثيفة ذات خلية عصبونية واحدة.

يتميز كل اتصال بين عصبون وآخر بارتباطه بقيمة تمثل وزن معين، وتعبّر عن مدى الارتباط بين هذين العصبونين، يقوم العصبون بضرب كل قيمة دخل واردة إليه من عصبونات الطبقة السابقة له بأوزن الوصلات إليه، ومن ثم جمع كافة نواتج الضرب، بعد ذلك يخضع النتيجة النهائية لتابع تفعيل Activation Function والذي يرمز له بالرمز  $\sigma$ . العلاقات 56 و 57 و 58 على الترتيب.

$$\sum = x \times w = (x_1 \times w_1) + \dots + (x_n \times w_n) \quad (56)$$

$$Z = x \times w + b \quad (57)$$

$$\hat{y} = \sigma(Z) = \frac{1}{1 + e^{-z}} \quad (58)$$

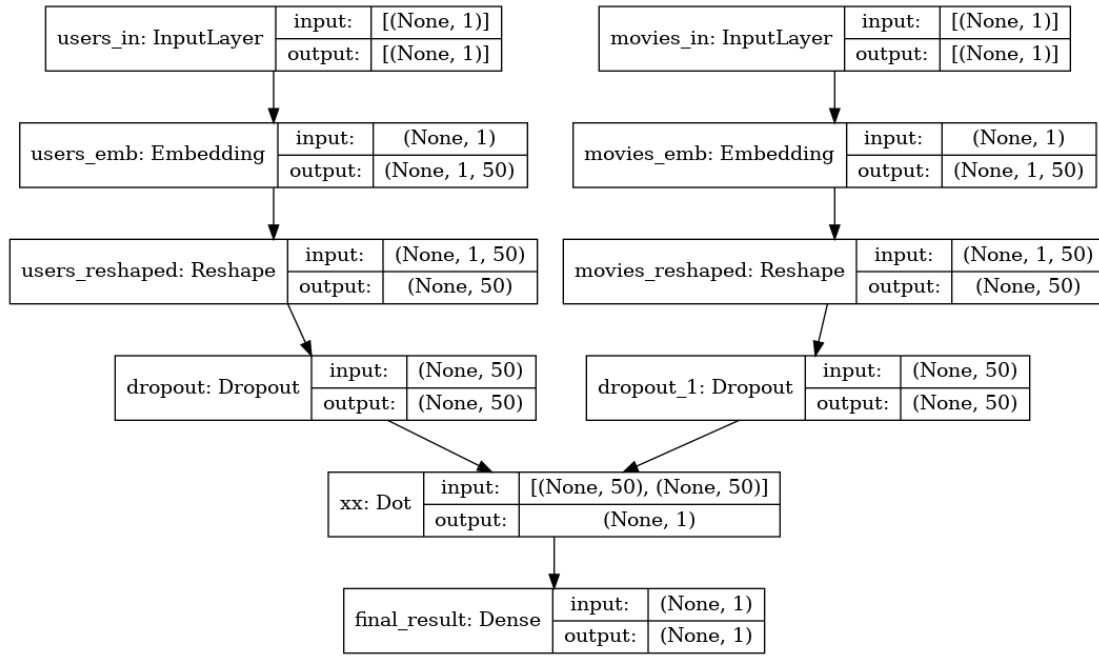
تابع التفعيل في العلاقة 58 هو Sigmoid، وهناك عدّة توابع أخرى مثل Relu و Linear و Tanh. يشير مصطلح الخسارة Loss إلى الخطأ في الشبكة العصبونية. يحسب تابع الخسارة الخطأ لتنبؤ معين، وتابع الخسارة مطلوب في خوارزمية التعلم (أو المحسّن Optimizer)، من أجل تحديد الخطوات التي يجب

اتخاذها لتقليل الخسارة. وعلى العكس من تابع الخسارة، يحسب تابع الكلفة Cost Function الخسارة لمجموعة البيانات كاملة.

قسمنا مجموعة البيانات إلى مجموعة للتدريب، ومجموعة للاختبار بنسبة 30:70 على الترتيب، واستخدمنا في هذا النموذج تابع الخسارة متوسط الخطأ المطلق MAE (العلاقة 59)، كما استخدمنا Relu كتابع تفعيل (العلاقة 60)، للتنبؤ بقيمة تقييم المستخدم لعنصر ما واعتمدنا طول شعاع التضمين 50.

$$MAE = \frac{1}{n} \sum_1^n |y - \hat{y}| \quad (59)$$

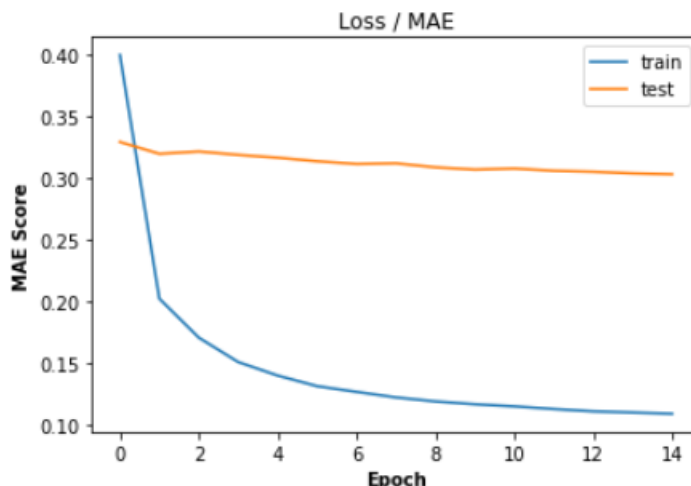
$$\Phi_L = Relu(w_X Z_X + b_X) \quad (60)$$



الشكل (46): بنية نموذج عامل المصفوفة القياسي

القيمة	الموسم
128	حجم دفعة التدريب
15	عدد تكرارات التدريب
50	طول شعاع التضمين
1	عصبونات طبقة الخرج
Adam	خوارزمية الأمثلة
0.001	Learning Rate

الجدول (19): معلمات نموذج GMF لتنبؤ تقييم المستخدم لعنصر ما



الشكل (47): تابع الخسارة في نموذج GMF بالنسبة لعدد تكرارات التدريب في كل من مجموعتي التدريب والاختبار

يوضح الجدول التالي قيم معايير تقييم النموذج السابق

المعيار	القيمة
MRR	0.264
MAP	0.512
NDCG	0.937

الجدول (20): قيم معايير تقييم النموذج السابق

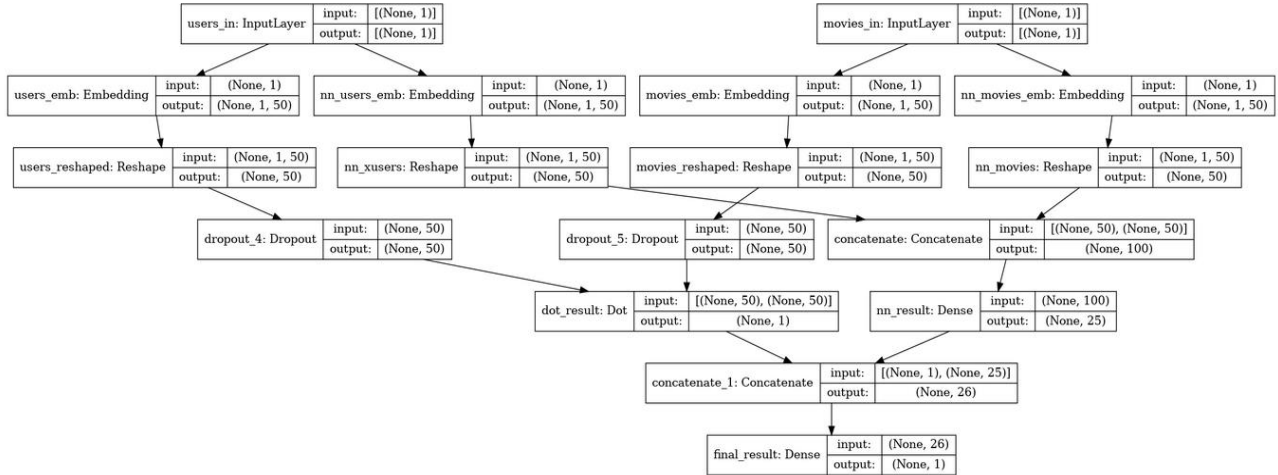
ثم قمنا بعملية تقييم للنموذج باستخدام MAE على كل من مجموعتي التدريب والاختبار، وأعطى النتائج التالية:

خطأ التدريب	0.143
خطأ الاختبار	0.347

الجدول (21): قيم تابع الكلفة في مجموعتي التدريب والاختبار

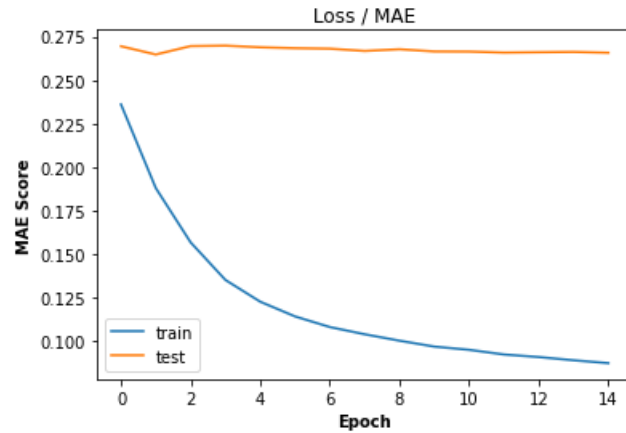
## 2. نموذج عامل المصفوفة القياسي GMF و الشبكة متعددة الطبقات Neural-MF

لزيادة جودة النموذج في التعبير عن العلاقات بين الكيانات، دمجت النموذج السابق مع شبكة عصبونية تأخذ كمدخل كل من أشعة التضمين للمستخدمين والعناصر معاً، بهدف إيجاد العلاقات غير الخطية فيما بينهم. نلاحظ من الشكل (47) لدينا شبكة عصبونية تمثل GMF وشبكة ثنائية NN تقوم بدمج أشعة التضمين في سلسلة واحدة، وبعد ذلك نقوم بإدخالها إلى طبقة كثيفة NN\_Result، يتألف خرج هذه الطبقة من 25 عصبون، بعد ذلك نقوم بدمج الخرج السابق مع خرج الجداء النقطي من نموذج GMF. ودخل الطبقة النهائية Final\_Result هو 26 عصبون، والخرج عصبون واحد يمثل قيمة التنبؤ بتقييم المستخدم لعنصر. واستخدمنا أيضاً تابع التفعيل Relu، وحافظنا على نفس معاملات التدريب في النموذج السابق.



الشكل (48): بنية نموذج Neural-MF

نلاحظ من الشكل (48) أن خطأي التدريب والاختبار قد انخفض عن النموذج السابق، نتيجة الاستفادة من اللاحظية للشبكات العصبونية.



الشكل (49): تابع الخسارة في نموذج Neural-MF بالنسبة لعدد تكرارات التدريب في كل من مجموعتي التدريب والاختبار

ثم قمنا بعملية تقييم للنموذج باستخدام MAE على كل من مجموعتي التدريب والاختبار، وأعطى النتائج التالية:

0.125	خطأ التدريب
0.311	خطأ الاختبار

الجدول (22): قيم تابع الكلفة في مجموعتي التدريب والاختبار في نموذج Neural-MF

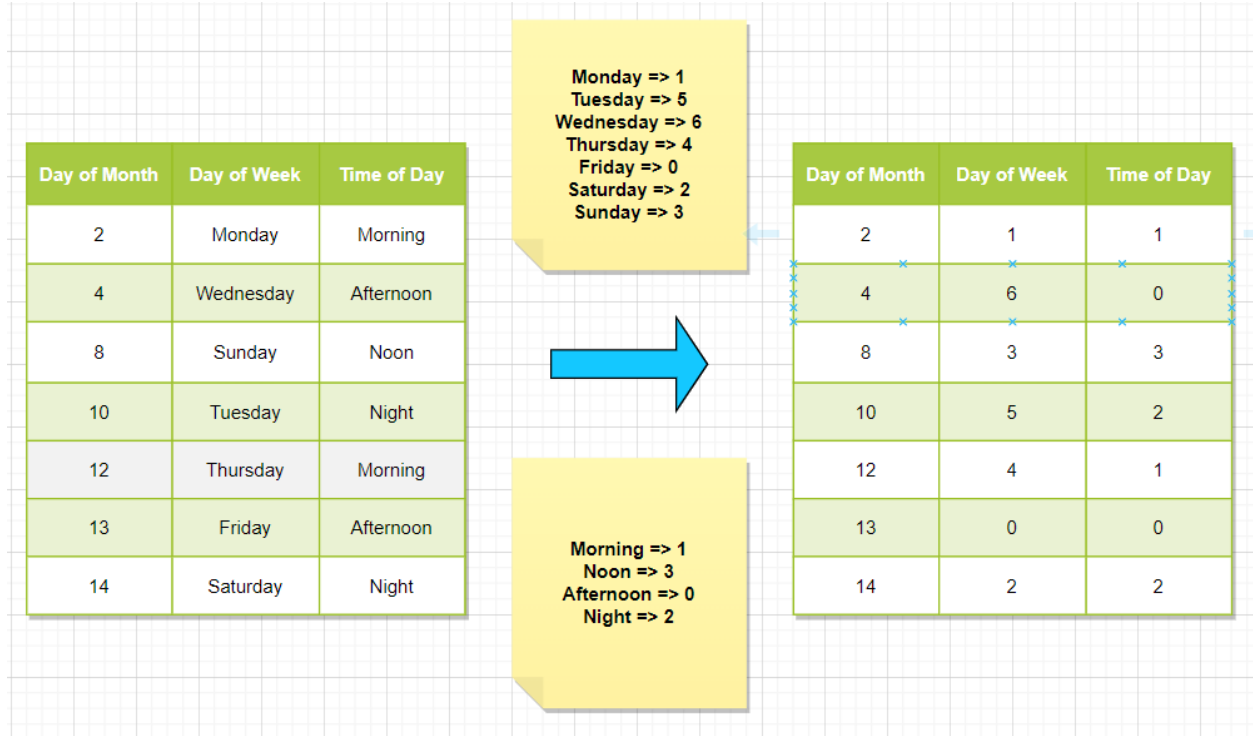
يوضح الجدول التالي، قيم معايير تقييم نموذج Neural-MF، حيث أدى إلى زيادة طفيفة في MAP بينما لم نلاحظ أي زيادة في المعيارين MRR و NDCG.

المعيار	القيمة
MRR	0.266
MAP	0.513
NDCG	0.937

الجدول (23): قيم معايير تقييم نموذج Neural-MF

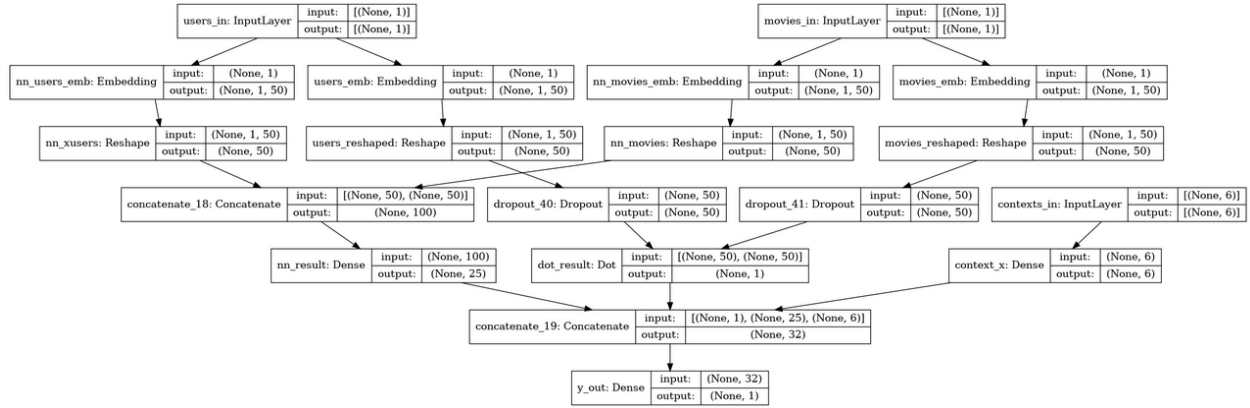
### 3. النموذج المدرك للسياق الزمني Neural-TARS

قبل البدء بهذا النموذج، يجب علينا تحويل السياق المستخرج سابقًا في Context-Aware RS (الشكل 38) إلى قيم عددية، بحيث يمكن الاستفادة منها في الشبكة العصبونية، لذا طبّقنا ترميز التسمية Label Encoding (الشكل 49) لكل من اليوم من الاسبوع، والوقت من السبوع، بحسب ترتيب ظهور كل "تسمية Categorical Name" أول مرة ضمن مجموعة المعطيات.




الشكل (50): ترميز التسمية للسياق الزمني في نموذج Neural-TARS

بعد القيام بعملية ترميز التسمية، عزلنا السياق من مجموعة المعطيات كي يكون دخل للشبكة العصبونية، واعتمدنا أيضاً على تابع التفعيل Relu، وحافظنا في هذا النموذج أيضاً على نفس معلمات التدريب المستخدمة في النموذجين السابقين. يظهر الشكل (51) بنية نموذج Neural-TARS.



الشكل (51): بنية نموذج التوصية المدرك للوقت العصبي Neural-TARS



الشكل (52): تابع الخسارة في نموذج Neural-MF بالنسبة لعدد تكرارات التدريب في كل من مجموعتي التدريب والاختبار

ثم قمنا بعملية تقييم للنموذج باستخدام MAE على كل من مجموعتي التدريب والاختبار، وأعطى النتائج التالية:

0.123	خطأ التدريب
0.309	خطأ الاختبار

الجدول (24): قيم تابع الكلفة في مجموعتي التدريب والاختبار في نموذج Neural-TARS

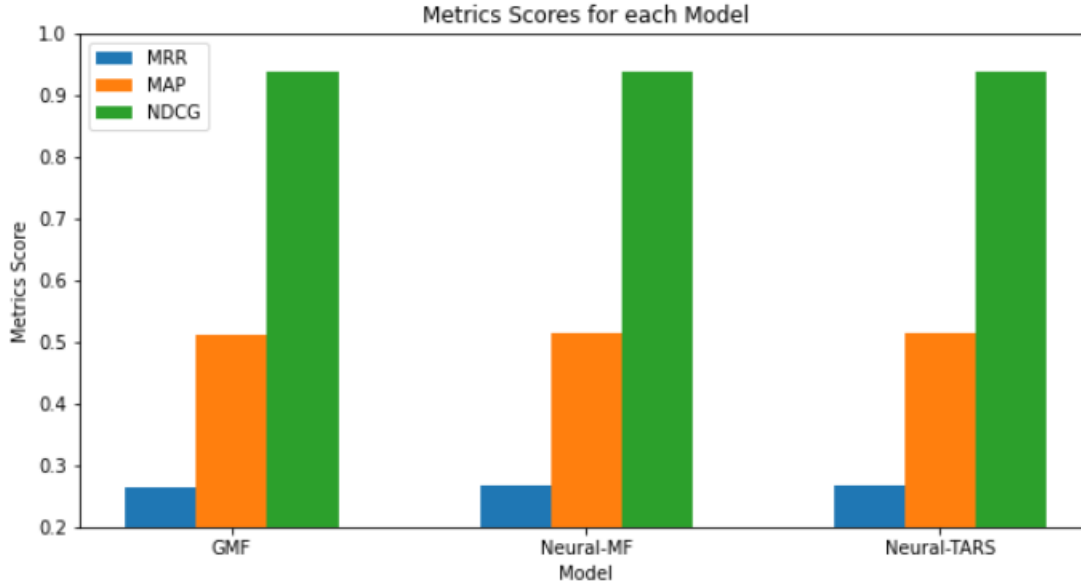
نلاحظ تحسّن طفيف عن نموذج Neural-MF التقليدي من ناحية خطأي التدريب والاختبار، كما نلاحظ تحسّن طفيف في مقاييس دقة الترتيب في نموذج السياق الزمني (الجدول 25).

القيمة	المعيار
0.267	MRR
0.515	MAP
0.938	NDCG


الجدول (25): قيم معايير التقييم في نموذج Neural-TARS

## 8.4 تحليل النتائج

قمنا بترتيب الخوارزميات المطبقة المعتمد على التعلّم العميق، قمنا بترتيبها وفق معيار تابع الخسارة Loss Function وكذلك وفق معايير التقييم MRR و MAP و NDCG، نلاحظ أن الفرق طفيف جداً في معايير الترتيب من أجل كل النماذج، أما بالنسبة لمعايير دقة التنبؤ نلاحظ الفرق أكبر بين الخوارزميات، ويتبين لنا أن نموذج التعلّم العميق المدرك للسياق الزمني لم تؤثر على دقة ترتيب العناصر الأكثر ملائمة، وإنما أثرت على درجة ملائمة العناصر للمستخدم، إذ حسّنت من درجة الملائمة مقارنة بالنماذج الأخرى.



الشكل (53): مقاييس التقييم (دقة الترتيب) لكل نموذج على مجموعة المعطيات المستخدمة



الشكل (54): مقاييس التقييم (دقة التنبؤ) لكل نموذج على مجموعتي التدريب والاختبار لكل نموذج

الفصل الخامس  
الخاتمة والآفاق المستقبلية

## 5.1 الخاتمة والآفاق المستقبلية

طبّقنا في هذه الأطروحة عدّة نماذج (نموذج الذاكرة – نموذج التعلّم العميق) لاستغلال المعلومات الزمنية، وتفضيلات المستخدم في عملية التوصية بهدف زيادة الدقّة، كما درسنا عدّة أنواع للتأثيرات الزمنية (النافذة المتخامدة – المنزلقة – السياق الزمني). تم تطبيق النماذج السابقة على مجموعة معطيات تخصّ الأفلام، ورأينا أن نموذجي النافذة المتخامدة، والسياق الزمني أعطوا نتيجة أفضل من نموذج التوصية غير المدرك للوقت من ناحية الدقّة التنبؤية، بالنسبة لنموذج التعلّم العميق طبّقنا نموذج عامل المصفوفة القياسي باستخدام الشبكة العصبونية GMF، بعد ذلك وسّعنا النموذج للاستفادة من اللاخطية التي تقدّمها الشبكة في نموذج Neural-MF، وفي النهاية دمجنا السياق الزمني في نموذج Neural-TARS، ورأينا أن نموذج السياق الزمني قلّل من خطأي التدريب والاختبار.

تطرّقنا بعد ذلك، إلى عدّة مقاييس لاختبار جودة نماذج التعلّم العميق المطبّقة، واخترنا المقاييس المدركة للترتيب Rank-Aware Evaluation Metrics وهي MRR و MAP و NDCG، بالإضافة إلى مقياس الدقّة التنبؤية MAE وقارنّا بين النماذج السابقة بالاعتماد على هذه المقاييس.

أثبتت النتائج المقدّمة في هذه الأطروحة أن خوارزميات التوصية المدركة للوقت قد تكتشف علاقات كامنة جديدة بين المستخدمين والعناصر مع وقت تقييم هذه العناصر، وبالتالي تتغلّب على قصور خوارزميات التوصية التقليدية المعتمدة على المستخدمين والعناصر فقط وتؤدي إلى زيادة الدقّة التنبؤية.

نهدف مستقبلاً إلى توسعة هذه النماذج بدمج سياقات أخرى للمستخدم غير السياق الزمني، مثل السياق المكاني Location، والاستفادة من نماذج التعلّم العميق، التي تُعنى بمعالجة البيانات ذات الطبيعة التسلسلية زمنياً، مثل الشبكة العصبونية التكرارية RNN، لاسيّما الشبكة العصبونية ذات الذاكرة الطويلة قصيرة المدى LSTM. كما نهدف إلى إعادة اختبار النماذج المطبّقة في هذه الأطروحة على بيانات دقيقة، باستخدام منهجيات الاتصال بالبوب وتحليل نتائج هذه النماذج واختيار الأفضل منها.

## المراجع

- [1] C. Garcia and L. Rona, *The Netflix Challenge.*, 2018.
- [2] M. J. Pazzani, "A Framework for Collaborative, Content-Based and Demographic Filtering," in *Artificial Intelligence Review*, 1999, p. 393–408.
- [3] M. J. Pazzani and D. Billsus, "Content-Based Recommendation Systems," in *The Adaptive Web*, Berlin Heidelberg, 2007, p. 325–341.
- [4] J. A. Konstan, B. N. Miller, D. Maltz, J. L. Herlocker and L. R. Gordon, "GroupLens: applying collaborative filtering to Usenet news," *ACM*, p. 77–87, 1997, <https://doi.org/10.1145/245108.245126>.
- [5] J. L. Herlocker, J. A. Konstan, A. Borchers and J. Riedl, "An algorithmic framework for performing collaborative filtering," *ACM*, pp. 230-237, August 1999, <https://doi.org/10.1145/312624.312682>.
- [6] R. Burke, "Knowledge-based recommender systems," Department of Information and Computer Science University of California, Irvine, 2000.
- [7] R. Burke, "Hybrid Web Recommender Systems," University of Colorado Boulder, 2007, [doi:10.1007/978-3-540-72079-9\\_12](https://doi.org/10.1007/978-3-540-72079-9_12).
- [8] N. J. Belkin and W. B. Croft, "Information filtering and information retrieval: two sides of the same coin?," *ACM*, p. 29–38, Dec. 1992, <https://doi.org/10.1145/138859.138861>.
- [9] D. Goldberg, D. Nichols, B. M. Oki and D. Terry, "Using collaborative filtering to weave an information tapestry," *ACM*, p. 61–70, Dec. 1992, <https://doi.org/10.1145/138859.138867>.
- [10] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom and J. Riedl, "GroupLens: an open architecture for collaborative filtering of netnews," *ACM*, p. 175–186, October 1994, <https://doi.org/10.1145/192844.192905>.
- [11] J. Riedl, "Fine Tuning the Social Web," 22 April 2013. [Online]. Available: <https://research.umn.edu/inquiry/post/fine-tuning-social-web-john-riedl>.
- [12] G. Salton and M. J. McGill, *Introduction to Modern Information Retrieval*, 11 West 19th Street New York, NY United States: McGraw-Hill, Inc. Professional Book Group, October 1986, p. 400.

- [13] B. Mobasher, "Data Mining for Web Personalization," in *The Adaptive Web*, Berlin, Heidelberg, Lecture Notes in Computer Science, vol 4321 Springer, 2007, [https://doi.org/10.1007/978-3-540-72079-9\\_3](https://doi.org/10.1007/978-3-540-72079-9_3), p. 90–135.
- [14] E. Bozdag, "Bias in algorithmic filtering and personalization. Ethics Inf Technol," *Springer*, p. 209–227, 23 June 2013, <https://doi.org/10.1007/s10676-013-9321-6>.
- [15] O. Stitini, S. Kaloun and O. Bencharef, "An Improved Recommender System Solution to Mitigate the Over-Specialization Problem Using Genetic Algorithms Electronics. 11(2):242.," *MDPI*, 2022, <https://doi.org/10.3390/electronics11020242>.
- [16] P. Lops, M. d. Gemmis and G. Semeraro, "Content-based Recommender Systems: State of the Art and Trends," in *Recommender Systems Handbook*, Springer, 01 January 2010, p. 73–105.
- [17] D. Das, L. Sahoo and S. Datta, "A Survey on Recommendation System," *ResearchGate*, February 2017, DOI:10.5120/ijca2017913081.
- [18] D. Maltz and K. Ehrlich, "Pointing the way: active collaborative filtering, CHI '95: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems," *ACM*, p. Pages 202–209, May 1995, <https://doi.org/10.1145/223904.223930>.
- [19] U. Shardanand and P. Maes, "Social information filtering: algorithms for automating “word of mouth” CHI '95: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems," *ACM*, p. Pages 210–217, May 1995, <https://doi.org/10.1145/223904.223931>.
- [20] W. Hill, L. Stead, M. Rosenstein and G. Furnas, "Recommending and evaluating choices in a virtual community of use, CHI '95: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems," *ACM*, p. Pages 194–201, May 1995, <https://doi.org/10.1145/223904.223929>.
- [21] F. Fkih, "Similarity measures for Collaborative Filtering-based Recommender Systems: Review and experimental comparison," *Journal of King Saud University - Computer and Information Sciences*, p. pp 7645–7669, Oct 2022, <https://doi.org/10.1016/j.jksuci.2021.09.014>.
- [22] J. S. Breese, D. Heckerman and C. Kadie, "Empirical analysis of predictive algorithms for collaborative filtering,," in *roceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence, UAI'98, Morgan Kaufmann Publishers Inc., , San Francisco, CA, USA, July 1998*.
- [23] C. E. Shannon, "A mathematical theory of communication," January 2001, <https://doi.org/10.1145/584091.584093>.
- [24] A. Brun, S. Castagnos and A. Boyer, "A positively directed mutual information measure for collaborative filtering," in *M. Ghenima, S. Sidhom, A. Ouksel (Eds.), 2nd International*

*Conference on Information Systems and Economic Intelligence - SIIE 2009, Malek Ghenima (ESCE Université la Manouba - Tunisie) and Sahbi Sidhom (Nancy Université - France), 2009.*

- [25] B. Sarwar, G. Karypis, J. Konstan and J. Riedl, "Item-based collaborative filtering recommendation algorithms," in *Proceedings of the 10th international conference on World Wide Web*, University of Minnesota, Minneapolis, May 2001, doi:10.1145/371920.372071..
- [26] C. C. Aggarwal, *Recommender Systems*, Springer, 2016, DOI: <https://doi.org/10.1007/978-3-319-29659-3>.
- [27] S. Biswas, L. V. Lakshmanan and S. B. Ray, Combating the Cold Start User Problem in Model Based Collaborative Filtering, arXiv, 18 Feb 2017, <https://doi.org/10.48550/arXiv.1703.00397>.
- [28] G. Karypis, "Evaluation of Item-Based Top-N Recommendation Algorithms," in *Proceedings of the tenth international conference on Information and knowledge management*, October 2001, <https://doi.org/10.1145/502585.502627>.
- [29] G. Linden, B. Smith and J. York, "Amazon.com recommendations: item-to-item collaborative filtering," *IEEE Internet Computing*, Vols. vol. 7, no. 1, pp. pp. 76-80., Jan.-Feb. 2003, doi: 10.1109/MIC.2003.1167344..
- [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*, October 2008, <https://doi.org/10.1145/1454008.1454031>.
- [31] K. Miyahara and i. J. Pazzani, "Collaborative Filtering with the Simple Bayesian Classifier. In: Mizoguchi, R., Slaney, J. (eds) PRICAI 2000 Topics in Artificial Intelligence. PRICAI 2000. Lecture Notes in Computer Science,," *Springer*, vol. 1886, Berlin, Heidelberg. [https://doi.org/10.1007/3-540-44533-1\\_68](https://doi.org/10.1007/3-540-44533-1_68).
- [32] 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)*, June 2016, DOI:10.1109/ICIS.2016.7550930.
- [33] X. Guan, C.-T. Li and Y. Guan, "Matrix Factorization With Rating Completion: An Enhanced SVD Model for Collaborative Filtering Recommender Systems," *IEEE*, vol. 5, pp. pp. 27668-27678, 2017, doi: 10.1109/ACCESS.2017.2772226..
- [34] X. Guan, C.-T. Li and Y. Guan, "Enhanced SVD for Collaborative Filtering. In: Bailey, J., Khan, L., Washio, T., Dobbie, G., Huang, J., Wang, R. (eds) *Advances in Knowledge Discovery and Data Mining*," *Springer, Cham*, vol. 9652, p. pp 503–514, 12 April 2016, [https://doi.org/10.1007/978-3-319-31750-2\\_40](https://doi.org/10.1007/978-3-319-31750-2_40).


- [35] M. G. Vozalis and K. G. Margaritis, "A Recommender System using Principal Component Analysis," in *Published in 11th Panhellenic Conference in Informatics*, 2007.
- [36] H. Zarzour, Z. A. Al-Sharif, M. Al-Ayyoub and Y. Jararweh, "A new collaborative filtering recommendation algorithm based on dimensionality reduction and clustering techniques," in *9th International Conference on Information and Communication Systems (ICICS)*, April 2018, DOI:10.1109/IACS.2018.8355449.
- [37] Ungar, L.H, Foster and D.P, "Clustering Methods for Collaborative Filtering.," in *Proceedings of the 1998 Workshop on Recommender Systems*, AAAI Press, Menlo Park, 1998.
- [38] R.D. and T. Júnior, "Combining Collaborative and Content-based Filtering to Recommend Research Paper," Universidade Federal do Rio Grande do Sul, Porto Alegre., 2004.
- [39] C. Li and C. Yang, "The research based on the Matrix Factorization recommendation algorithms," in *IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*, pp. 691-698, , 2016, doi: 10.1109/IMCEC.2016.7867298..
- [40] H. Li, B. He and M. Lublin, "Matrix factorization: objective and ALS algorithm on a single machine. CME 323," in *Stanford University*, Stanford, California, 2015.
- [41] X. He, L. Liao, H. Zhang, L. Nie, X. Hu and T.-S. Chua, "Neural Collaborative Filtering," in *WWW '17: Proceedings of the 26th International Conference on World Wide Web*, 26 Aug 2017, <https://doi.org/10.1145/3038912.3052569>.
- [42] X. He, H. Zhang, M.-Y. Kan and T.-S. Chua, "Fast Matrix Factorization for Online Recommendation with Implicit Feedback," in *SIGIR '16: Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval*, July 2016, <https://doi.org/10.1145/2911451.2911489>.
- [43] M. Wang, W. Fu, S. Hao, D. Tao and X. Wu, "Scalable Semi-Supervised Learning by Efficient Anchor Graph Regularization," *IEEE Transactions on Knowledge and Data Engineering*, vol. 28, no. 7, pp. pp. 1864-1877, July 2016, doi: 10.1109/TKDE.2016.2535367..
- [44] F. Ortega, J.-L. SáNchez, J. Bobadilla and A. Gutiérrez, "Improving collaborative filtering-based recommender systems results using Pareto dominance," *Information Sciences*, p. pp 50–61, August, 2013, <https://doi.org/10.1016/j.ins.2013.03.011>.
- [45] R. Burke, "Hybrid Web Recommender Systems. In: Brusilovsky, P., Kobsa, A., Nejdl, W. (eds) *The Adaptive Web. Lecture Notes in Computer Science*," *Springer*, vol. 4321, no. Berlin, Heidelberg., 2007, [https://doi.org/10.1007/978-3-540-72079-9\\_12](https://doi.org/10.1007/978-3-540-72079-9_12).

- [46] P. Melville, R. J. Mooney and R. Nagarajan, "Content-Boosted Collaborative Filtering for Improved Recommendations," in *Proceedings of the Eighteenth National Conference on Artificial Intelligence(AAAI-2002)*, pp. 187-192, , Edmonton, Canada, July 2002.
- [47] D. S. C, D. S. T, F. G. W, H. R. A, L. T. K, L. K. E and S. L. A, "Computer information retrieval using latent semantic structure, US Patent No. 4839853," Jun 13, 1989.
- [48] P. Castells, N. J. Hurley and S. Vargas, "Novelty and Diversity in Recommender Systems. In: Ricci, F., Rokach, L., Shapira, B. (eds) Recommender Systems Handbook.," *Springer, Boston, MA.*, 2015, [https://doi.org/10.1007/978-1-4899-7637-6\\_26](https://doi.org/10.1007/978-1-4899-7637-6_26).
- [49] N. Ferro, N. Fuhr, G. Grefenstette, J. A. Konstan, P. Castells, E. M. Daly, T. Declerck, M. D. Ekstrand, W. Geyer, J. Gonzalo, T. Kuflik, K. Lindn, B. Magnini, J.-Y. Nie and Raffaele, "The Dagstuhl Perspectives Workshop on Performance Modeling and Prediction," *ACM*, vol. 52, no. 1, p. pp 91–101, June 2018, <https://doi.org/10.1145/3274784.3274789>.
- [50] E. H. Martin and E. Gaudioso, "A Common Framework and Metric for Recommender Systems: A Proposal," 2007.
- [51] N. Craswell, "Mean Reciprocal Rank. In: LIU, L., ÖZSU, M.T. (eds) Encyclopedia of Database Systems.," *Springer, Boston, MA.* 2009, [https://doi.org/10.1007/978-0-387-39940-9\\_488](https://doi.org/10.1007/978-0-387-39940-9_488).
- [52] D. Parra and S. Sahebi, "Recommender Systems: Sources of Knowledge and Evaluation Metrics," January 2013, DOI:10.1007/978-3-642-33326-2\_7.
- [53] N. Webster, Webster's New Twentieth Century Dictionary of the English Language Unabridged, Springfield, Massachusetts, U.S.A.: G. & C. Merriam Company., 1980.
- [54] K. Stefanidis, I. Ntoutsis, K. Nørnvåg and H.-P. Kriegel, "A Framework for Time-Aware Recommendations, In: Liddle, S.W., Schewe, KD., Tjoa, A.M., Zhou, X. (eds) Database and Expert Systems Applications. DEXA 2012. Lecture Notes in Computer Science," *Springer*, vol. 7447, 2012, [https://doi.org/10.1007/978-3-642-32597-7\\_29](https://doi.org/10.1007/978-3-642-32597-7_29).
- [55] M. Unger, A. Tuzhilin and A. Livne, "Context-Aware Recommendations Based on Deep Learning Frameworks," *ACM Transactions on Management Information Systems*, vol. 11, no. 2, pp. pp 1–15., June 2020, Article No.: 8, <https://doi.org/10.1145/3386243>.

**Syrian Arab Republic**

**Higher Institute For Applied Sciences and Technology**

**Department of Information Systems**



Add different page numbers or number formats to different sections

## **Time-Aware Recommendation System**

Submitted By

**Eng. Basel Mohammad Mariam**

Supervised By

**Dr. Yasser Rahal**

**Dr. Mustapha Dakkak**

**November 2022**