



اشتقاق التقييمات الضمنية في تقنية التصفية التعاونية من معاملات الشراء و سجل السلوك

Derivation of implicit ratings in Collaborative Filtering from purchase transactions and behavior history

مروة فاروق عبدالمعال سليمان

Marwa_2t@hotmail.com

كلية علوم الحاسوب و تقانة المعلومات - جامعة النيلين - الخرطوم - السودان

المستخلص :

تعتبر تقنية التصفية التعاونية من أشهر التقنيات المستخدمة في نظم التوصية فهي تعتمد على تشارك الإهتمامات بين المستخدمين لتقديم توصيات ذات علاقة بالمستخدم، و تستخدم لذلك التقييمات التي يقدمها المستخدم بصورة صريحة إلا أن هذه التقييمات قد تكون مجده للمستخدم أو قد لا يتحرجي الصحة عند تقديمها مما ينتج عنه توصيات تفتقر إلى الدقة. تستهدف هذا الورقة حل مشكلة قلة تقييمات المستخدم في مصفوفة تقييمات التصفية التعاونية، تم إقتراح طريقة لإستغلال بيانات معاملات الشراء و بيانات تدفق نقر المستخدم لإشتقاق تقييمات ضمنية للمستخدم بحيث تمثل هذه التقييمات درجة تفضيل المستخدم للعنصر. يتم إضافة هذه التقييمات الضمنية إلى مصفوفة التقييمات بغرض إثراء المصفوفة و من ثم تجوييد التوصيات. تم إجراء الإختبارات على بيانات متجر تجاري إلكتروني للبيع بالتجزئة. وفقاً للبيانات المستخدمة أثبتت التجارب أن التقييمات الضمنية التي تم إشتقاقها من بيانات شراء المستخدم و من بيانات تدفق نقر المستخدم تقلل من التأثير السلبي لقلة أو تنافر تقييمات المصفوفة، كما أنها تحسن من دقة التوصيات المقدمة للمستخدم. مستقبلاً يمكن التنبؤ عن بيانات أخرى لتحسين دقة التوصيات مثل الزمن المستغرق في مشاهدة عنصر محدد أو صنف محدد، كما يمكن وضع السياق الزمني للشراء في الإعتبار لتقديم توصيات ترتبط بفترة الشراء.

Abstract:

Collaborative filtering is one of the most popular techniques used in recommender systems. It relies on sharing interests among users to provide recommendations related to the user, and it uses the ratings that the user provides explicitly, but these ratings may be stressful for the user or may not investigate the correctness when presented, which results in inaccurate recommendations. This paper aims to solve the problem of lack of user ratings in the collaborative filter rating matrix; a proposed method exploits user transaction data and clickstream data to derive implicit user ratings, which represent the degree of user preference for the item. These implicit ratings are added to the rating matrix to enrich the matrix and then improve the recommendations. The experiments were conducted on the data of a retail e-commerce store, according to the dataset, experiments have shown that implicit ratings that are derived from user purchase data and clickstream data reduce the negative impact of data sparsity, and improve the accuracy of user recommendations. In the future, other data can be mined to improve the accuracy of recommendations, such as the viewing time of a specific item or category, also the purchase time context can be taken into account to provide recommendations related to the purchase period.

الكلمات المفتاحية :

نظم التوصية (Recommender Systems) ، التصفية التعاونية (Collaborative Filtering) ، التقييمات الضمنية (Data sparsity) ، تاثير البيانات (Implicit ratings) .

-1 المقدمة :

نظراً لغمر المستخدم بمجموعة من المنتجات والخيارات في بيئة التسوق عبر الإنترن特، يحتاج المستخدم إلى وسيلة تدعمه و توجهه في عملية البحث عن المنتجات و اختيار ما يلائمه من العناصر، تؤدي نظم التوصية (Recommender Systems) مهمة تصفية معلومات المستخدم بإستخدام العديد من التقنيات منها تقنية التصفية التعاونية (Collaborative Filtering) والتي تقوم على مبدأ إذا كان المستخدمون قد شاركوا نفس الاهتمامات في الماضي فسيكون لهم أيضاً تفضيلات متشابهة في المستقبل، إذ تعتمد هذه التقنية على التقييمات (ratings) التي يقدمها المستخدم و التي بموجبها يتم تقديم توصيات ذات علاقة بالمستخدم و ترضي تفضيلاته، إلا أن هذه التقييمات يندر تقديمها من المستخدم بصورة صريحة إذ أنها مجده للمستخدم أو قد لا يعبأ المستخدم بتحري الصحة في تقديمها مما ينتج عنه توصيات قد تكون غير ذات مغزى للمستخدم. تهدف هذه الورقة إلى حل مشكلة قلة

تقييمات المستخدم في مصفوفة تقييمات التصفية التعاونية، بحيث يتم إستغلال مصادر المعلومات المتاحة كمعاملات شراء المستخدم و سجل سلوك المستخدم لاستخراج معرفة عن تفضيلات المستخدم و من ثم توظيف هذه المعرفة لتقديم توصيات مخصصة للمستخدم. تم تنظيم الورقة على النحو التالي: في القسم 2 سنتناول الدراسات السابقة، وفي القسم 3 سنوضح نموذج التوصية المقترن، يليه القسم 4 الذي يشرح خوارزمية التوصية المقترنة مع مثال توضيحي لها في القسم 5، أما في القسم 6 سنتناول التجربة و التقييم، يليه القسم 7 و الذي يوضح النتائج التي تم التوصل إليها، و نختتم بالخلاصة في القسم 7.

2- الدراسات السابقة:

تعمل تقنية التصفية التعاونية على إستغلال تقييمات المستخدم للتتبؤ بما سيفضله المستخدم، وفقاً لتصنيف Ricci في [1] فإنه يمكن إستخدام تقييمات المستخدم لبناء و تعلم نموذج تنبؤي و هو ما يُعرف بطرق التصفية بناءً على النموذج (Model-Based methods)، و التي يتم فيها بناء النموذج بإستخدام خوارزميات التعلم الآلي كما في [2] أو قواعد الإرتباط و Naïve Bayes Classifier كما في [3] أو الشبكات العصبية كما في [4]. كذلك يمكن إستخدام تقييمات المستخدم للتتبؤ استناداً إلى التشابه بين المستخدمين أو التشابه بين العناصر وهو ما يُعرف بطرق التصفية بناءً على الذاكرة (Memory-Based methods) ، هذه الطرق تعتمد على تقييمات المستخدم و التي قلما يقدمها المستخدم بصورة صريحة، لذا لجأت بعض الدراسات إلى إشتقاق تقييمات ضمنية لتحديد تفضيلات المستخدم بغرض تجويد التوصيات كما في [5] حيث تم تحليل الأنماط المتسلسلة (sequential pattern analysis) للمستخدم مع بيانات شراء المستخدم تقديم توصيات تتعلق بالمستخدم، و في [6] تم إستخدام بيانات شراء المستخدم و بيانات تدفق نقر المستخدم (clickstream) المتسلسل لتحديد تفضيلات المستخدم، بينما تم الإعتماد على التشابه بين نمط سلوك المستخدمين في الشراء و المقارنة و التشابه بين العناصر من خلال تضمين الكلمات (Word-Embedding) لتحديد التوصيات ذات العلاقة في [7]، و الإعتماد على تشابه سمات العنصر لتحديد تفضيلات المستخدم مما شابهه من السمات [8]. كذلك إستفادت بعض الدراسات من بيانات المحتوى لتدعم القصور في تقنية التصفية التعاونية من خلال إستخدام التقنية المختلطة كما في [9] و [10]. مقارنة بالطرق المذكورة أعلاه، في هذه الورقة تم إشتقاق تقييمات ضمنية للمستخدم بالتقريب في بيانات معاملات المستخدم

بالإضافة إلى بيانات تدفق نقر المستخدم التشاركي بين المستخدمين، بحيث تعكس هذه التقييمات الضمنية درجة تفضيل المستخدم للعنصر، و التي يتم الإستناد إليها لخضيص توصيات المستخدم.

3- نموذج التوصية المقترن:

يعلم النموذج المقترن على حل مشكلة قلة بيانات التقييم في مصفوفة التقييمات في تقنية التصفيه التعاونية، تم إقتراح طريقة لإشتقاق تقييمات ضمنية من سجل سلوك المستخدم بحيث تمثل هذه التقييمات درجة تفضيل المستخدم للعنصر حسب تفاعلاته، تعمل هذه التقييمات ضمنية و بخلاف التقييمات الصريحة على إثراء مصفوفة التقييمات بمتغيرات يسهل الحصول عليها، كما أنها متاحة بصورة كافية من كل المستخدمين. بإضافة تقييمات المستخدم الضمنية إلى مصفوفة تقييمات التصفيه التعاونية تصبح المصفوفة غنية بالمتغيرات مما يعكس إيجاباً على دقة التوصيات المقدمة للمستخدم.

يهدف النموذج المقترن إلى إستغلال بيانات معاملات شراء المستخدم و سجل سلوك المستخدم لإشتقاق تقييمات المستخدم بصورة ضمنية، تعمل هذه التقييمات الضمنية على إثراء مصفوفة التقييمات التعاونية بتقييمات تعبر عن درجة تفضيل المستخدم للعناصر التي تفاعل معها أو التي قام بشرائها مسبقاً، و ذلك بغرض مساعدة و توجيه المستخدم عن طريق تقديم توصيات بعناصر تقع ضمن اهتمامات المستخدم.

٤- خوارزمية التوصية المقترنة:

تستقبل الخوارزمية جدول الشراء و النقر و مصفوفة الشراء كمدخلات، يتم إستخدام مصفوفة الشراء لتوليد التقييمات الضمنية المستخدم بناءً على بيانات معاملات الشراء، بينما يتم إستخدام بيانات جدول الشراء و النقر لتوليد التقييمات الضمنية بناءً على تدفق نقر المستخدم، و من ثم يتم إمداد مصفوفة الشراء بالتقييمات الضمنية المشتقة و ذلك للتبؤ بتقييمات المستخدم للعناصر التي لم يقييمها و التي تعتبر مخرج للخوارزمية. فيما يلي سنوضح بالتفصيل مدخلات و مخرجات هذه الخوارزمية و خطوات تنفيذها.

المدخلات: 1-4

جدول الشراء:

يحتوي جدول الشراء على بيانات معاملات الشراء و التي توضح العناصر المشترأة لكل مستخدم في كل جلسة كما يوضح الجدول التالي.

جدول-1: جدول الشراء

session_id	user_id	item_id	Time	quantity
1	1	b	2014-04-03T10:26:07.632Z	1
1	1	a	2014-04-03T10:26:07.753Z	1
2	1	a	2014-04-07T09:22:28.132Z	1
3	2	b	2014-04-07T09:22:28.176Z	2
3	2	c	2014-04-03T11:04:11.417Z	1
4	3	c	2014-04-02T10:42:17.227Z	1
5	3	d	2014-04-02T13:17:46.940Z	1

(2) جدول النقر:

يحتوي جدول النقر على بيانات تدفق نقر المستخدم والتي توضح أحداث النقر على العناصر خلال كل جلسة للمستخدم كما يوضح الجدول التالي.

جدول-2: جدول النقر

session_id	user_id	item_id	Category	Time
1	1	a	2	2014-04-07T10:51:09.277Z
1	1	b	3	2014-04-07T10:54:09.868Z
2	1	c	1	2014-04-07T10:54:46.998Z
2	1	d	4	2014-04-07T10:57:00.306Z
3	2	c	1	2014-04-07T13:56:37.614Z
3	2	a	2	2014-04-07T13:57:19.373Z
4	2	d	4	2014-04-07T13:58:37.446Z
5	3	d	4	2014-04-02T13:17:46.940Z
6	3	b	3	2014-04-02T13:26:02.515Z

(3) جدول الشراء و النقر:

يحتوي جدول الشراء و النقر على بيانات الجلسة كاملة فهو تكامل لأحداث النقر و الشراء لكل مستخدم وفقاً للتسلسل الزمني كما يوضح الجدول التالي.

جدول-3: جدول الشراء و النقر

session_id	user_id	clicks	purchases

1	1	a,b,c,a,c	b,a,a
2	1	c,d,a	
3	2	b,c,d,b	b,b,c
4	2	b,c,e,e	c,c
5	3	d,b,c	c,d
6	3	b,e,e	
7	4	c,d,a,a	

4) مصفوفة الشراء:

وهي عبارة عن مصفوفة تقييمات المستخدم التي تعتمد على بيانات الشراء، تمثل الصفوف المستخدمين، بينما تمثل الأعمدة العناصر المشتراء من قبل المستخدمين، يتم تمثيل تقييمات المستخدم في هذه المصفوفة بالمتغير المتضمن داخل بيانات معاملة الشراء وهو متغير الكمية المشتراء من العنصر المحدد خلال جلسات المستخدم المختلفة كما يوضح الجدول التالي، في الجدول يشار لتقييم العناصر غير المشتراء و التي ليست لها قيمة لكمية المشتريات بالرمز (?).

جدول-4 مصفوفة الشراء

	a	b	c	d
1	2	1	?	?
2	?	2	3	?
3	?	?	1	1

2- المخرجات:

تبعد الخوارزمية عدة خطوات يتم تفزيذها على المدخلات المحددة لتحديد تقييمات المستخدم الضمنية حسب تفاعلات المستخدم، ومن ثم يتم استخدام هذه التقييمات المشتقة للتبؤ بدرجة تفضيل المستخدمين للعناصر غير معروفة التقييم، تنتج الخوارزمية مصفوفة بالتقديرات المتوقعة للعناصر التي لم يقييمها المستخدمون كمخرج.

3- خطوات تنفيذ خوارزمية التوصية المقترحة:

المدخلات: جدول الشراء، جدول النقر، جدول الشراء و النقر، مصفوفة الشراء.

المخرجات: مصفوفة التقديرات المتوقعة للعناصر التي لم يقييمها المستخدمون بناءً على التقديرات الضمنية للمستخدمين.

- 1: تطبيق تقييمات مصفوفة الشراء في مصفوفة جديدة هي مصفوفة التقييمات الضمنية، ينتج (عنصر، التقييم الضمني للشراء).
- 2: لكل جلسة نقر تتبعها إلى جدول الشراء و النقر:
- 3: أحسب معدل النقر لكل عنصر، ينتج (مستخدم، عنصر ، معدل النقر)
- 4: لكل جلسة شراء تتبعها إلى جدول الشراء قارن مع جلسة النقر التي تتبعها إلى جدول النقر:
- 5: إذا كان العنصر مشترك بين جلسة النقر و جلسة الشراء:
- 6: أحسب معدل الإشتراك للعناصر المفردة المشتركة بين جلسة النقر و جلسة الشراء، ينتج (عنصر ، معدل الإشتراك)
- 7: وإلا:
- 8: أحسب معدل عدم الإشتراك للعناصر المفردة غير المشتركة بين جلسة النقر و جلسة الشراء، ينتج (عنصر ، معدل عدم الإشتراك)
- 9: نهاية الشرط.
- 10: نهاية تكرار جلسة الشراء.
- 11: التقييم الضمني للنقر = معدل النقر + معدل الإشتراك + معدل عدم الإشتراك، ينتج (مستخدم، عنصر ، تقييم ضمني للنقر)
- 12: نهاية تكرار جلسات النقر.
- 13: لكل تقييم للعنصر يتبعها إلى التقييم الضمني للنقر اختبر:
- 14: إذا لم يوجد تقييم مسبق من المستخدم للعنصر في مصفوفة التقييمات الضمنية، (عنصر، تقييم ضمني للشراء):
- 15: أضاف التقييم الضمني للنقر في مصفوفة التقييمات الضمنية، (مستخدم، عنصر، تقييم ضمني للنقر).
- 16: نهاية الشرط.
- 17: نهاية تكرار التقييم الضمني للنقر.
- 18: طبق خوارزمية التصفية التعاونية على مصفوفة التقييمات الضمنية.
- 19: مصفوفة التقييمات المتوقعة للعناصر التي لم يقييمها المستخدمون هي المصفوفة الناتجة عن التصفية التعاونية وفقاً للتقييمات الضمنية.

20: أرجع: مصفوفة التقييمات المتوقعة للعناصر التي لم يقييمها المستخدمون بناءً على التقييمات الضمنية للمستخدمين.

الشكل-1: خطوات تنفيذ خوارزمية التوصية المقترنة

الخطوات التالية تشرح الخوارزمية الموضحة في الشكل-1:

(1) تستقبل الخوارزمية مصفوفة الشراء كمدخل و التي يتم فيها تمثيل الكميات المشتراه من كل عنصر خلال جلسات المستخدم كتقييم للمستخدم، يتم تطبيق هذه التقييمات بتحويلها لتقييمات في شكل مقياس رقمي لقيمة بين 0 و 1 بإستخدام معادلة متوجه الوحدة Unit Vector المعادلة-1، تمثل هذه القيمة درجة تفضيل المستخدم للعنصر من ضمن العناصر المشتراه. تحتوي مصفوفة التقييمات الضمنية وهي المصفوفة الجديدة الناتجة عن عملية التطبيع على التقييمات الضمنية للشراء المشتقة من كمية المشتروات (سطر رقم 1).

$$\hat{u} = \frac{u}{|u|}$$

معادلة-1: معادلة متوجه الوحدة

\hat{u} تشير إلى متوجه الوحدة، u تشير إلى المتجه، $|u|$ تشير إلى حجم المتجه.

(2) لكل جلسة نقر للمستخدم يتم حساب معدل النقر لكل عنصر من عناصر جلسة النقر (سطر رقم 3) وفقاً للمعادلة-2، تم إستبعاد العناصر ذات معدلات النقر التي تقل عن الحد الأدنى لمعدل النقر (0.3):

معدل النقر = عدد مرات تكرار العنصر في الجلسة / عدد عناصر جلسة النقر

معادلة-2: معادلة معدل النقر

(3) لحساب معدل الإشتراك (سطر رقم 6) يتم مقارنة جلسة نقر المستخدم مع جلسات الشراء لتحديد العناصر المشتركة بين جلسة النقر و بين جلسات الشراء، حيث يتم حساب معدل الإشتراك للعنصر المشترك بين جلسة النقر و بين أي جلسة شراء وفقاً للمعادلة-3، ثم يتم إيجاد مجموع معدلات الإشتراك للعنصر مع جميع جلسات الشراء، و من ثم يتم تطبيق معدلات إشتراك العناصر المشتركة بتحويل مجموع معدل إشتراك كل عنصر مشترك إلى قيمة بين 0 و 1 بإستخدام معادلة min-max scaler وفق الصيغة الموضحة في المعادلة-4:

معدل إشتراك العنصر = عدد العناصر المفردة المشتركة في جلسة النقر / عدد العناصر المفردة في جلسة النقر و

جلسه الشراء

معادلة-3: معادلة معدل الإشتراك

$$\hat{x} = \frac{x - \min}{\max - \min}$$

معادلة-4: معادلة min-max scaler

\hat{x} تشير إلى القيمة بعد التطبيع، x تشير إلى القيمة الفعلية، \min تشير إلى أقل قيمة، \max تشير إلى أعلى قيمة.

(4) لحساب معدل عدم الإشتراك (سطر رقم 8) يتم مقارنة جلسة نقر المستخدم مع جلسات الشراء لتحديد العناصر غير المشتركة بين جلسة النقر و بين جلسات الشراء، حيث يتم حساب معدل عدم الإشتراك للعنصر غير المشترك بين جلسة النقر و بين أي جلسة شراء وفقاً للمعادلة (13-5)، ثم يتم إيجاد مجموع معدلات عدم الإشتراك للعنصر مع جميع جلسات الشراء، و من ثم يتم تطبيق معدلات عدم إشتراك العناصر غير المشتركة بتحويل مجموع معدل عدم إشتراك كل عنصر غير مشترك إلى قيمة بين 0 و 1 باستخدام المعادلة-4:

معدل عدم إشتراك العنصر = عدد العناصر المفردة غير المشتركة في جلسة النقر / عدد العناصر المفردة في جلسة النقر و جلسة الشراء

معادلة-5: معادلة معدل عدم الإشتراك

(5) لإستفادة التقييمات الضمنية المشتقة من بيانات تدفق نقر المستخدم يتم جمع معدل النقر و معدل الإشتراك و معدل عدم الإشتراك لكل عنصر (سطر رقم 11) وفقاً للمعادلة-6، بحيث يمثل المجموع الكلي للمعدلات الثلاث هو تقييم المستخدم الضمني لجلسة النقر أو التقييم الضمني للنقر، تم جمع معدل النقر و معدل الإشتراك و معدل عدم الإشتراك باستخدام الأوزان التالية (0.2، 0.3، 0.5) على التوالي، تم تجربة الأوزان (0.5، 0.3، 0.2)، (0.35، 0.3، 0.2)، (0.35، 0.35، 0.3) إلا أن الأوزان المستخدمة (0.2، 0.3، 0.5) أعطت نتائج أفضل. تم إستبعاد العناصر ذات التقييمات الضمنية للنقر التي تقل عن الحد الأدنى للتقييم الضمني للنقر (0.3).

التقييم الضمني للنقر = $\alpha * \text{معدل النقر} + \beta * \text{معدل الإشتراك} + \gamma * \text{معدل عدم الإشتراك}$

حيث $0 < \gamma, \beta, \alpha < 1$

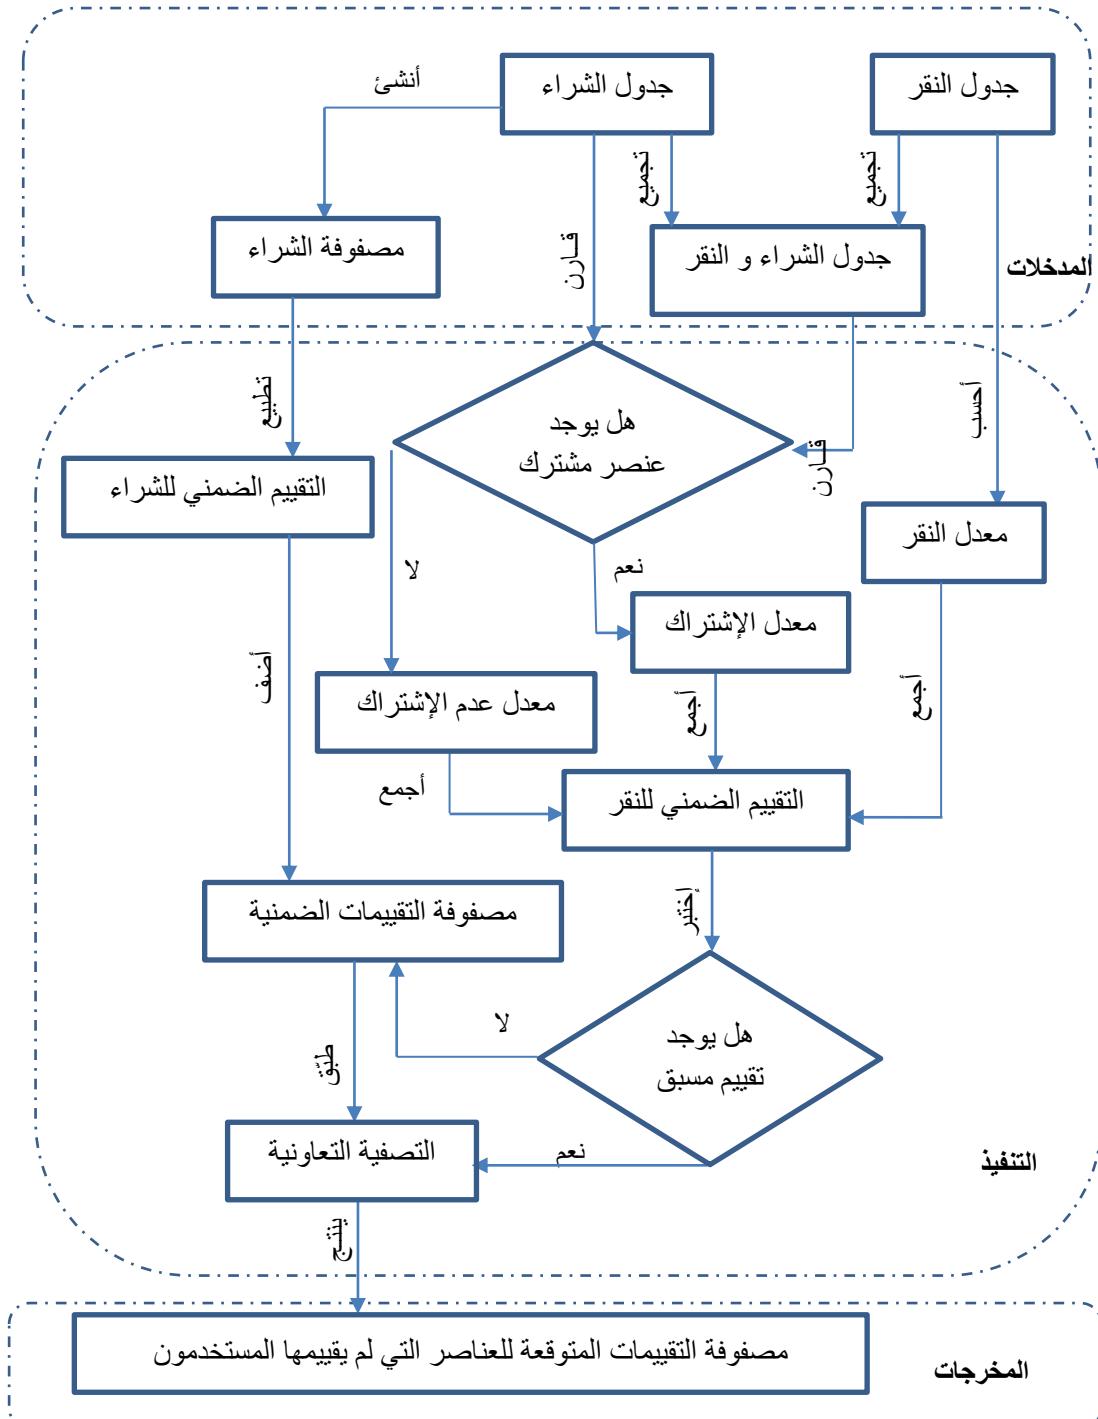
معادلة-6: معادلة التقييم الضمني للنقر

(6) أضف التقييمات الضمنية للنقر إلى مصفوفة التقييمات الضمنية في سطر رقم 1، بحيث يضاف التقييم الضمني للعناصر التي لم يسبق المستخدم تقييمها، أو بمعنى آخر في حال لم يشتري المستخدم تلك العناصر من قبل (سطر رقم 14، 15).

(7) طبق خوارزمية التصفية التعاونية على مصفوفة التقييمات الضمنية الناتجة عن تكامل تقييمات المستخدم الضمنية للشراء و تقييمات المستخدم الضمنية للنقر للتباو بالتقىيمات غير المعروفة للمستخدمين (سطر رقم 18). في مصفوفة تقييمات المستخدم المدخلة إلى خوارزمية التصفية التعاونية تم إستبدال كل القيم غير الصفرية بالقيمة 1 لأغراض تجريبية.

(8) تنتج مصفوفة التقييمات المتوقعة للعناصر التي لم يقييمها المستخدمون بناءً على التقييمات الضمنية للمستخدمين كمخرج لخوارزمية (سطر رقم 20).

الشكل (3-5) التالي يوضح مخطط خوارزمية التوصية المقترحة و الذي يشتمل على مدخلات و مخرجات و خطوات تنفيذ الخوارزمية المقترحة.



شكل-2: مخطط خوارزمية التوصية المقترحة

5- مثال توضيحي لخوارزمية التوصية المقترحة:

سنوضح خوارزمية التوصية المقترحة لإستفادة تقييمات ضمنية للمستخدمين بإستخدام جدول الشراء (الجدول-1) و جدول النقر (الجدول-2) و جدول الشراء و النقر (الجدول-3) و مصفوفة الشراء (الجدول-4) في القسم 4-1.

- لتطبيع مصفوفة الشراء (الجدول-5) يتم استخدام المعادلة-1، مثلاً لحساب التقييم الضمني للشراء للمستخدم (1) يتم بحساب متجة الشراء للعناصر (a, b) كالتالي:

$$\hat{a} = \frac{2}{\sqrt{2^2 + 1^2}}, \quad \hat{b} = \frac{1}{\sqrt{2^2 + 1^2}}$$

الجدول-5 التالي يوضح التقييمات الضمنية للشراء، نجد أن نسبة تاثير التقييمات في مصفوفة التقييمات الضمنية تمثل 50%. في الجدول يشير الرمز (?) للتقييمات المفقودة للعناصر التي ليس لها تقييمات ضمنية للشراء.

جدول-5: التقييمات الضمنية للشراء

User/item	a	b	c	d
1	0.894	0.447	?	?
2	?	0.554	0.832	?
3	?	?	0.707	0.707

- من الشراء و النقر (الجدول-3) نجد أن هناك جلسات نقر لا تنتهي بالشراء تخص المستخدمين (1، 3، 4)، لإشتقاق التقييمات الضمنية لهذه الجلسات سنقارن هذه الجلسات مع

كل جلسات الشراء لحساب معدل النقر و معدل الإشتراك و معدل عدم الإشتراك لكل جلسة، فيما يلي سنحسب المعدلات الثلاث التي تخص كل مستخدم على حدا، و من ثم نحدد العناصر ذات التقييم الضمني للنقر لكل مستخدم ليتم إضافتها لاحقاً إلى مصفوفة التقييمات:

- الجدول-5 و الجدول-6 و الجدول-7 توضح على التوالي معدلات النقر و معدلات الإشتراك

و معدلات عدم الإشتراك للمستخدم رقم (1) من جلسة النقر رقم (2) و جلسات الشراء (1،

3، 4، 5)، سنشير لمعدل العنصر غير المضمن ضمن عناصر الجلسة بالرمز (-)، حسابياً

سنحدد المعدل لهذه العناصر بالقيمة 0.

جدول-5: معدل النقر للمستخدم رقم (1)

User/ item	a	b	c	d
1	0.33	-	0.33	0.33

جدول-6: معدل الإشتراك للمستخدم رقم (1)

Session_id/ item	a	b	c	d
1	1/4	0/4	0/4	0/4
3	0/4	0/4	1/4	0/4
4	0/3	0/4	1/3	0/3
5	0/3	0/4	2/3	2/3
sum	0.25	0.0	1.25	0.6
Min-max scaler	0.2	0.0	1.0	0.48

- من الجدول-6 نجد أن معدل إشتراك العناصر لا يتأثر بتكرار شراء العنصر كما في حالة العنصر(a) في جلسة الشراء رقم (1)، إذ أن تكرار العنصر تم أخذه في الإعتبار من خلال تضمين الكمية المشتراء من كل عنصر في التقييم الضمني للشراء.

جدول-7: معدل عدم الإشتراك للمستخدم رقم (1)

Session_id/ item	a	b	c	d
1	0/4	1/4	2/4	2/4
3	1/4	1/4	0/4	1/4
4	1/3	-	0/3	1/3
5	1/3	-	0/3	0/3
sum	0.917	0.5	0.5	1.08
Min-max scaler	0.719	0.0	0.0	1.0

لحساب التقييمات الضمنية للمستخدم (1) نجمع المعدلات السابقة بإستخدام الأوزان المحددة لكل معدل كما يلي:

$$a = (0.33 * 0.2) + (0.2 * 0.5) + (0.719 * 0.3) = 0.381$$

$$b = (- * 0.2) + (0.0 * 0.5) + (0.0 * 0.3) = 0.0$$

$$c = (0.33 * 0.2) + (1.0 * 0.5) + (0.0 * 0.3) = 0.566$$

$$d = (0.33 * 0.2) + (0.48 * 0.5) + (1.0 * 0.3) = 0.606$$

- الجدول-8 و الجدول-9 و الجدول-10 التالية توضح على التوالي معدلات النقر و معدلات الإشتراك و معدلات عدم الإشتراك للمستخدم رقم (3) من جلسة النقر رقم (6) و جلسات

الشراء (1، 3، 4، 5)، سنشير لمعدل العنصر غير المضمن ضمن عناصر الجلسة بالرمز (-)، حسابياً سنحدد المعدل لهذه العناصر بالقيمة 0.

جدول-8: معدل النقر للمستخدم رقم (3)

User/ item	a	b	c	d	e
3	-	0.33	-	-	0.67

جدول-9: معدل الإشتراك للمستخدم رقم (3)

Session_id/ item	a	b	c	d	e
1	0/3	1/3	-	-	0/3
3	-	1/3	0/3	-	0/3
4	-	0/3	0/3	-	0/3
5	-	0/4	0/4	0/4	0/4
sum	0.0	0.6	0.0	0.0	0.0
Min-max scaler	0.0	1	0.0	0.0	0.0

- من الجدول-9 نجد أن معدل إشتراك العناصر لا يتتأثر بتكرار النقر على العنصر كما في حالة العنصر(e) في جلسة النقر رقم (6)، إذ أن تكرار النقر على العنصر تم أخذها في الاعتبار من خلال حساب معدل النقر لكل عنصر في التقييم الضمني للنقر.

جدول-10: معدل عدم الإشتراك للمستخدم رقم (3)

Session_id/ item	a	b	c	d	e
1	1/3	0/3	-	-	1/3
3	-	0/3	1/3	-	1/3
4	-	1/3	1/3	-	1/3
5	-	1/4	1/4	1/4	1/4
sum	0.33	0.583	0.917	0.25	0.917
Min-max scaler	0.119	0.449	1.0	0.0	1.0

لحساب التقييمات الضمنية للمستخدم (3) نجمع المعدلات السابقة بإستخدام الأوزان المحددة

لكل معلم كما يلي:

$$a = (- * 0.2) + (0.0 * 0.5) + (0.119 * 0.3) = 0.036$$

$$b = (0.33 * 0.2) + (1.0 * 0.5) + (0.449 * 0.3) = 0.716$$

$$c = (- * 0.2) + (0.0 * 0.5) + (1.0 * 0.3) = 0.3$$

$$d = (- * 0.2) + (0.0 * 0.5) + (0.0 * 0.3) = 0.0$$

$$e = (0.67 * 0.2) + (0.0 * 0.5) + (1.0 * 0.3) = 0.434$$

- الجدول-11 و الجدول-12 و الجدول-13 التالية توضح على التوالي معدلات النقر و معدلات الإشتراك و معدلات عدم الإشتراك للمستخدم رقم (4) من جلسة النقر رقم (7) و جلسات الشراء (1، 3، 4، 5)، سنشير لمعدل العنصر غير المضمن ضمن عناصر الجلسة بالرمز (-)، حسابياً سنحدد المعدل لهذا العنصر بالقيمة 0.

جدول-1: معدل النقر للمستخدم رقم (4)

User/ item	a	b	c	d
3	0.5	-	0.25	0.25

جدول-12: معدل الإشتراك للمستخدم رقم (4)

Session_id/ item	a	b	c	d
1	1/4	0/4	0/4	0/4
3	0/4	0/4	1/4	0/4
4	0/3	-	1/3	0/3
5	0/3	-	2/3	2/3
sum	0.25	0.0	1.25	0.6
Min-max scaler	0.2	0.0	1.0	0.48

جدول-13: معدل عدم الإشتراك للمستخدم رقم (4)

Session_id/ item	a	b	c	d
1	0/4	1/4	2/4	2/4

3	1/4	1/4	0/4	1/4
4	1/3	–	0/3	1/3
5	1/3	–	0/3	0/3
sum	0.917	0.5	0.5	1.08
Min-max scaler	0.719	0	0	1

لحساب التقييمات الضمنية للمستخدم (4) نجمع المعدلات السابقة بإستخدام الأوزان المحددة

لكل معدل كما يلي:

$$a = (0.5 * 0.2) + (0.2 * 0.5) + (0.7719 * 0.3) = 0.416$$

$$b = (- * 0.2) + (0.0 * 0.5) + (0.0 * 0.3) = 0.0$$

$$c = (0.25 * 0.2) + (1.0 * 0.5) + (0.0 * 0.3) = 0.55$$

$$d = (0.25 * 0.2) + (0.48 * 0.5) + (1.0 * 0.3) = 0.59$$

بعد جمع المعدلات يتم تحديد التقييمات الضمنية للنقر لكل مستخدم لمجموعة العناصر، يتم تحديد المستخدمين و العناصر في مصفوفة التقييمات الضمنية للنقر حسب تفاعل المستخدم مع العنصر، الجدول-14 التالي يوضح التقييمات الضمنية للنقر المشتقة لكل من المستخدم (1، 3، 4) للعناصر الموضحة في الجدول التالي، في الجدول يشير الرمز (?) للتقييمات المفقودة للعناصر التي ليس لها تقييمات ضمنية للنقر.

جدول-14: مصفوفة التقييمات الضمنية للنقر

User/ item	a	b	c	d	e
1	0.381	0.0	0.566	0.606	?
3	0.036	0.716	0.3	0.0	0.434
4	0.416	0.0	0.55	0.59	?

سيتم تغذية مصفوفة التقييمات الضمنية بالتقديرات الضمنية التي تم إستtractionها من جلسات نقر المستخدم، بحيث يراعي عند إضافة التقييمات إضافة تقييمات العناصر التي لم يسبق للمستخدم تقييمها (بمعنى آخر ليس لديها تقييمات في مصفوفة الشراء)، كذلك إضافة التقييمات التي لا تقل عن الحد الأدنى للتقدير الضمني (0.3)، في الجدول (5-19) تم تطبيق العناصر التي لا تحقق شروط الإضافة.

الجدول-15 التالي يوضح مصفوفة التقييمات الضمنية الناتجة بعد إضافة التقييمات الضمنية للنقر. في الجدول يشير الرمز (؟) إلى التقييمات المفقودة للعناصر التي ليس لها تقييمات ضمنية للشراء أو للنقر.

جدول-15: مصفوفة التقييمات الضمنية

User/item	a	b	c	d	e
1	0.894	0.447	0.566	0.606	؟
2	؟	0.554	0.832	؟	؟
3	؟	0.716	0.707	0.707	0.434
4	0.416	؟	0.55	0.59	؟

- تمثل مصفوفة التقييمات الضمنية المدخل لخوارزمية التصفية التعاونية و التي تنتج مصفوفة التقييمات المتوقعة بناءً على تلك التقييمات الضمنية للعناصر التي لم يقييمها المستخدمون. نلاحظ في الجدول-15 لمصفوفة التقييمات الضمنية أنه تمت إضافة تقييمات لعناصر جديدة للمستخدمين مثل العنصر (C) للمستخدم رقم (1)، كذلك تم إضافة عناصر جديدة لمصفوفة كالعنصر(e) للمستخدم رقم (3)، كما تم إضافة مستخدمين جدد لمصفوفة كالمستخدم رقم (4). تمثل نسبة تأثير التقييمات في مصفوفة التقييمات الضمنية نسبة 35% و هي نسبة أقل من نسبة مصفوفة الشراء مما يعني أن التقييمات الضمنية تقلل من تأثير مشكلة قلة بيانات مصفوفة التقييمات.

6- التجربة و التقييم:

تم إجراء التجارب لحساب نسبة تأثير التقييمات في مصفوفة التقييمات و لاختبار مدى كفاءة النموذج المقترن و الذي يعتمد على التقييمات الضمنية مقارنة مع أسلوب التوصية الأساسي و الذي يعتمد على مشتريات المستخدم كتقييمات صريحة للمستخدم. تم استخدام مجموعة البيانات التجارية التي تخص بائع تجزئة عبر الإنترت في أوروبا و التي أنشئت بواسطة شركة YOOCHOOSE GmbH لدعم المشاركين في تحدي RecSys 2015 [11]، تتضمن مجموعة البيانات على (87,318) جلسة شراء و (2,152,741) جلسة نقر، ليصبح العدد الكلي للجلسات بعد تجميع جلسات النقر و جلسات الشراء هو (2,235,663) جلسة، نظراً لنقص بيانات المستخدم في مجموعة البيانات المستخدمة تم إضافة

بيانات المستخدم و توزيعها بشكل عشوائي. تم تقسيم مجموعة البيانات بإستخدام طريقة K-Fold Cross Validation، حيث تم تقسيم البيانات إلى 10 مجموعات متساوية الحجم تقريرًا، يتم اختيار إحدى المجموعات لتمثل بيانات الإختبار، بينما تمثل بقية المجموعات و عددها 9 مجموعات بيانات التدريب. تم تقييم النموذج المقترن بإستخدام مكتبة CaseRecommender [12]، تم مراعاة طرق التوصية التعاونية المختلفة (التوصية بناءً على المستخدم، التوصية بناءً على العنصر)، كما تم مراعاة طرق قياس التشابه المختلفة (معامل إرتباط بيرسون، مقياس جيب التمام).

7- النتائج:

بحساب نسبة تناثر البيانات كما في الجدول-16 و الجدول-17 نجد أن إضافة التقييمات الضمنية المشتقة من بيانات شراء المستخدم و من تفاعلاتة إلى مصفوفة التقييمات قد قلل من نسبة تناثر التقييمات في المصفوفة من نسبة (99.78%) إلى نسبة (99.71%) في مرحلة التدريب و ذلك بإضافة (37,553) تقييم ضمني، و من نسبة (99.92%) إلى نسبة (99.91%) في مرحلة الإختبار و ذلك بإضافة (4,173) تقييم ضمني كما يوضح الشكل-3. هذه النسب و إن كانت ضئيلة إلا أنها تقلل من تأثير فجوة تناثر تقييمات المستخدم في المصفوفة مقارنة مع تقييمات مشتروعات المستخدم، كما أنها تساهم في زيادة المعرفة المكتسبة عن المستخدم.

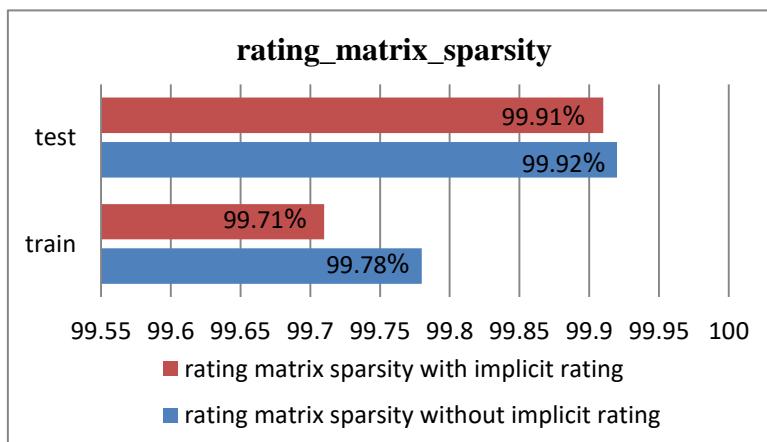
جدول-16: نسبة تناثر التقييمات لنموذج التوصية المقترن

	users	items	interactions	sparsity
QV_user_cosine				
train data	6457	9381	173190	99.71%
test data	6070	3489	19244	99.91%
QV_user_correlation				
train data	6457	9381	173190	99.71%
test data	6070	3489	19244	99.91%
QV_item_cosine				
train data	6457	9381	173190	99.71%
test data	6070	3489	19244	99.91%
QV_item_ correlation				

train data	6457	9397	173190	99.71%
test data	6057	3453	19244	99.91%

جدول-17: نسبة تناثر تقييمات أسلوب التوصية الأساسي

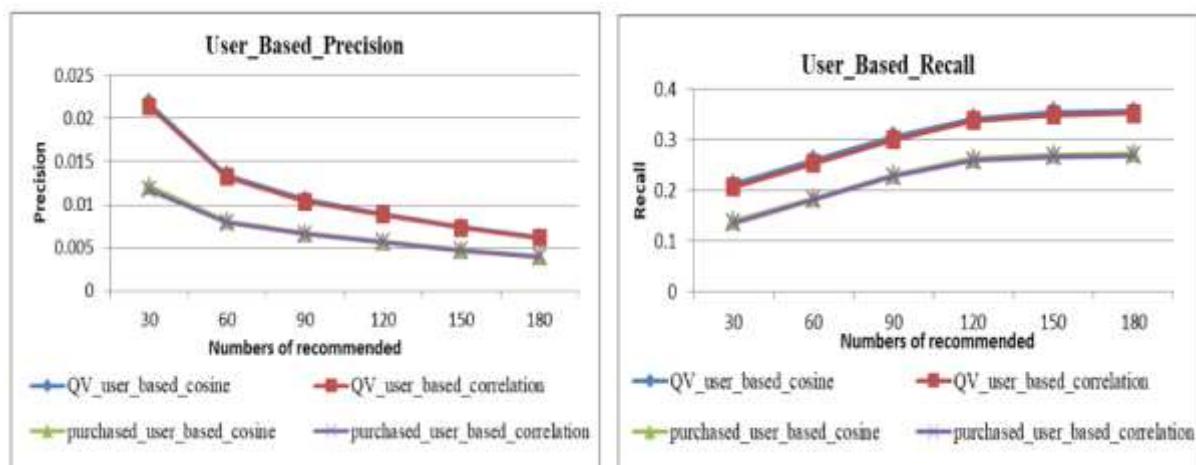
	users	items	interactions	sparsity
purchase_user_based_cosine				
train data	6457	9358	135637	99.78%
test data	5701	3427	15071	99.92%
purchase_user_based_correlation				
train data	6457	9377	135637	99.78%
test data	5749	3449	15071	99.92%
purchase_item_based_cosine				
train data	6457	9342	135637	99.78%
test data	5733	3425	15071	99.92%
purchase_item_based_correlation				
train data	6457	9399	135637	99.78%
test data	5700	3414	15071	99.92%

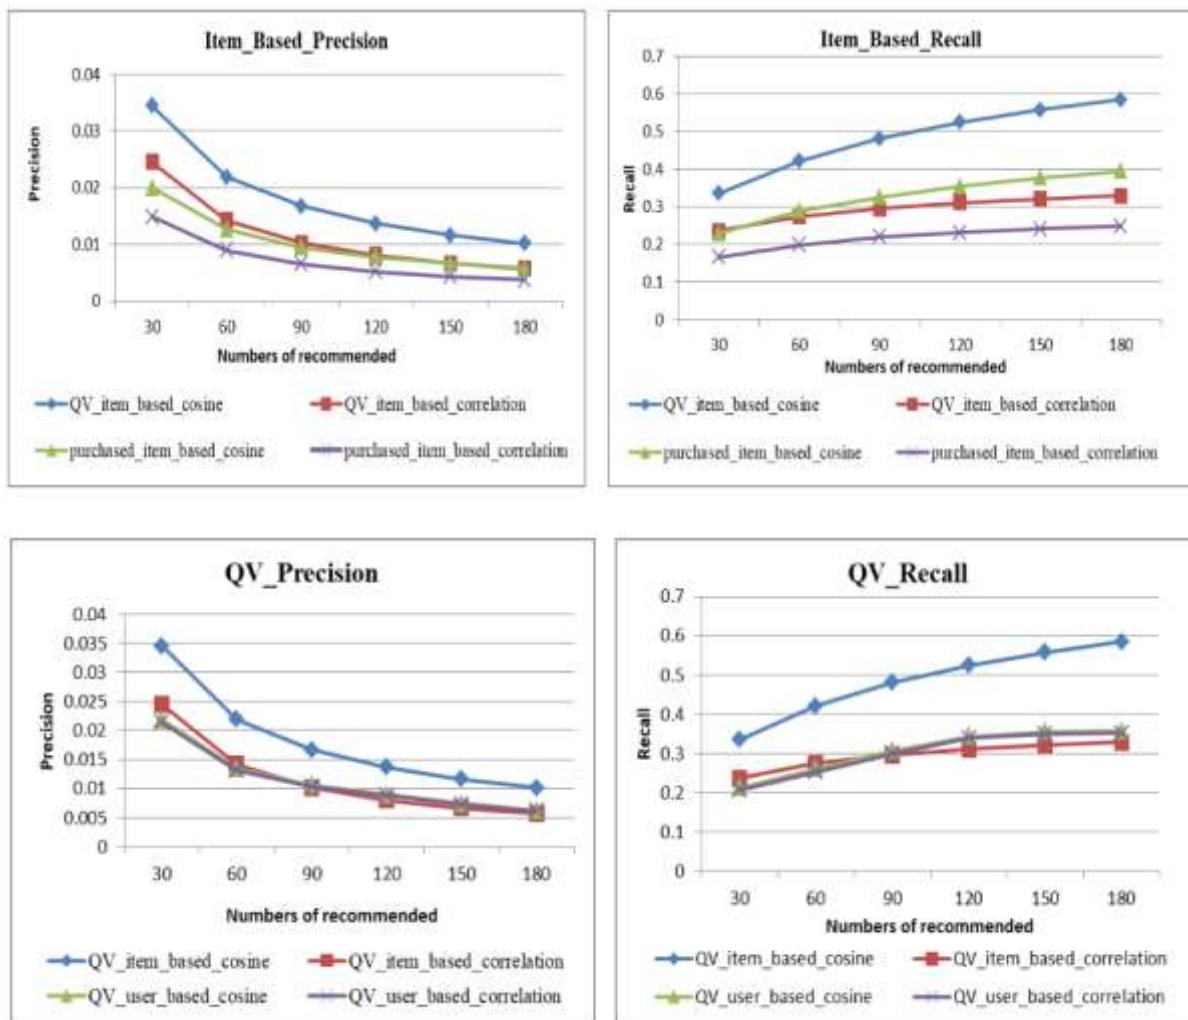


شكل-3: نسبة تناثر البيانات في مصفوفة التقييمات قبل و بعد إضافة التقييمات الضمنية

وفقاً لمقاييس الدقة و الإستدعاء أثبتت التجارب التي تقارن أداء نموذج التوصية المقترن مع أسلوب التوصية الأساسي تفوق نموذج التوصية المقترن (QV_based) على نموذج التوصية الأساسي

(purchased_based) في حالتي التوصية بناءً على المستخدم و التوصية بناءً على العنصر و بإختلاف طرق التشابه. كذلك أظهرت النتائج أفضليّة نموذج التوصية المقترن بناءً على العنصر بـإستخدام مقياس جيب التام (QV_item_based_cosine) في تقديم توصيات ذات دقة عالية مقارنة مع طرق التوصية الأخرى و التي تتضمن نموذج التوصية المقترن بناءً على العنصر بـإستخدام معامل إرتباط بيرسون (QV_item_based_correlation) و نموذج التوصية المقترن بناءً على المستخدم بـإستخدام معامل إرتباط بيرسون (QV_user_based_correlation) و نموذج التوصية المقترن بناءً على المستخدم بـإستخدام مقياس جيب التام (QV_user_based_cosine)، إذ أن نموذج التوصية المقترن بناءً على العنصر بـإستخدام مقياس جيب التام و بإختلاف عدد العناصر الموصى بها يعطي القيمة الأعلى للإستدعاء و هو نسبة العناصر ذات الصلة بالمستخدم و التي تم التوصية بها من نسبة جميع العناصر التي تم التوصية بها، حيث تصل نسبة العناصر الموصى بها و التي تقع ضمن تفضيلات المستخدم إلى ما يقارب (60%) كحد أقصى من مجموع العناصر الموصى بها، و هي نسبة جيدة مقارنة مع نسبة الإستدعاء لأسلوب التوصية الأساسي و التي تقارب (40%) كحد أقصى من مجموع العناصر الموصى. وفقاً لهذه التجارب تشير نتائج التقييم إلى أن المستخدم يفضل العناصر التي تشبه العناصر التي تفاعل معها أو قام بشرائها مسبقاً أكثر من العناصر التي تفاعل معها أو قام بشرائها المستخدمون المشابهون له.





شكل-4: الدقة و الإستدعاء لنموذج التوصية المقترن و أسلوب التوصية الأساسي

ما سبق يمكن تلخيص النتائج التالية:

- (1) المعرفة المكتسبة عن المستخدم و المتمثلة في التقييمات الضمنية التي تم إستفادتها من بيانات شراء المستخدم و من بيانات تدفق نقر المستخدم تقلل من تناول تقييمات المستخدم في مصفوفة التقييمات.
- (2) يمكن تخصيص توصيات المستخدم بإستخدام تقنية التصفيحة التعاونية بناءً على التقييمات الضمنية المشتقة من بيانات شراء المستخدم و من بيانات تدفق نقر المستخدم.
- (3) التقييمات الضمنية التي تم إستفادتها من بيانات شراء المستخدم و من بيانات تدفق نقر المستخدم تحسن من دقة التوصيات من نسبة 40% إلى 60% كحد أقصى للتوصيات.

8- الخلاصة:

تستخدم نظم التوصية العديد من طرق تصفية المعلومات منها طريقة التصفية التعاونية، تستند التصفية التعاونية على التقييمات التي يقدمها المستخدم و التي بموجبها يتم تقديم توصيات ذات علاقة بالمستخدم و ترضي تفضيلاته، إلا أن المستخدم قد يضن بتقديم هذه التقييمات، إذ أنها مجده للمستخدم أو قد لا يعبأ المستخدم بتحري الصحة في تقديمها، مما ينبع عنه توصيات تفتقر إلى الدقة. ينصب التركيز الرئيسي لهذه الورقة على تسخير مصادر المعلومات المتوفرة كمعاملات شراء المستخدم و سجل سلوك المستخدم للتعرف على تفضيلات المستخدم، و من ثم إستخدام هذه المعرفة لتقديم توصيات ذات مغزى للمستخدم. تم الإستفادة من بيانات شراء المستخدم متمثلة في كمية المشتريات، و من بيانات تدفق نقر المستخدم متمثلة في عدد مرات النقر لإشتقاق تقييمات ضمنية للمستخدم تعكس درجة تفضيل المستخدم للعنصر، ومن ثم تم إثراء مصفوفة التقييمات التعاونية بهذه التقييمات الضمنية بغرض التقليل من التأثير السلبي لتأثير بيانات التقييم. تم إستخدام بيانات متجر تجاري للبيع بالتجزئة لإشتقاق التقييمات الضمنية للمستخدم و من ثم تم تطبيق تقنية التصفية التعاونية على مصفوفات تقييمات المستخدم الضمنية المشتقة، أظهرت النتائج وفقاً للبيانات المستخدمة أن التقييمات الضمنية المشتقة لعبت دوراً إيجابياً في تقليل نسبة تناثر تقييمات المستخدم في مصفوفة التقييمات من حيث الكم، كذلك أثبتت النتائج كفاءة التقييمات الضمنية المشتقة في تحسين دقة التوصيات المقدمة للمستخدم، و ذلك عن طريق تقديم توصيات بعناصر تشابه العناصر التي تفاعل معها المستخدم أو قام بشرائها مسبقاً.

المصادر و المراجع:

- [1] F. Ricci, L. Rokach, B. Shapira and P. Kantor, "Recommender Systems Handbook", 1st. ed., Springer-Verlag, Berlin, Heidelberg, 2011.
- [2] A. Martínez, C. Schmuck, S. Pereverzyev, C. Pirker and M. Haltmeier, "A machine learning framework for customer purchase prediction in the non-contractual setting". 2020, Eur. J. Oper. Res., 281, 588–596.
- [3] K. Kumari, H. Khajgiwale, S. Umare, A. Kumar, G. Phadtare and V. Chaudhary, "Comportement Analyse And Recommendation Using ClickStream Data". Int. J. of Advance Research and Innovative Ideas in Education, 2017, 3, 1256-1260.
- [4] D. Köhn, S. Lessmann and M. Schaal, "Predicting Online Shopping Behaviour from Clickstream Data using Deep Learning", 2020, Expert Systems with Applications. 150. 113342.
10.1016/j.eswa.2020.113342.
- [5] K. Choi, D. Yoo, G. Kim and Y. Suh, "A hybrid online-product recommendation system: Combining implicit rating-based collaborative filtering and sequential pattern analysis". Electron. Commer. Rec. Appl. 11, 4 (July, 2012), 309–317, 2012, DOI:<https://doi.org/10.1016/j.elerap.2012.02.004>

- [6] Y. Xiao and C. Ezeife, “E-Commerce Product Recommendation Using Historical Purchases and Clickstream Data”, DaWaK, 2018.
- [7] B. Wang, F. Ye and J. Xu, “A Personalized Recommendation Algorithm Based on the User’s Implicit Feedback in E-Commerce”, Future Internet. 10. 117. 10.3390/fi10120117, 2018.
- [8] H. Hwangbo and Y. Kim, "Session-Based Recommender System for Sustainable Digital Marketing", Sustainability, 11, 3336., 2019, <https://doi.org/10.3390/su11123336>
- [9] P. Chavan, B. Thoms and J. Isaacs, “A Recommender System for Healthy Food Choices: Building a Hybrid Model for Recipe Recommendations using Big Data Sets”, 2021, 10.24251/HICSS .2021.458.
- [10] M. Farashah, A. Etebarian, R. Azmi and R. Dastjerdi, “A hybrid recommender system based-on link prediction for movie baskets analysis”. J Big Data 8, 32 (2021), 2021, <https://doi.org/10.1186/s40537-021-00422-0>
- [11] D. Ben-Shimon, A. Tsikinovsky, M. Friedman, B. Shapira, L. Rokach and J. Hoerle, Recsys challenge 2015 and the yoochoose dataset, In Proc. of the 9th ACM Conf. on Recommender systems. ACM, September 2015.

- [12] A. Costa, E. Fressato, F. Neto, M. Manzato and R. Campello, "Case recommender: a flexible and extensible python framework for recommender systems". In Proc. of the 12th ACM Conf. on Recommender Systems (RecSys '18). ACM, NY, USA, 2018 494-495.
DOI: <https://doi.org/10.1145/3240323.3241611>.