

تحديات تقنيتي التصفية التعاونية والتصفية بناءً علي المحتوى

مروة فاروق عبدالمعتال سليمان و فخرالدين عباس محمد سعيد

كلية علوم الحاسوب و ثقافة المعلومات - جامعة النيلين - الخرطوم - السودان Marwa_2t@hotmail.com

المستخلص

أصبحت أنظمة التوصية (Recommender Systems) الحل لمواجهة مشكلة التحميل الزائد للمعلومات وتخصيص الخدمات في تطبيقات الويب، فهي تساعد المستخدم في عملية البحث عن المعلومات واتخاذ القرار، وتستخدم لذلك العديد من التقنيات منها تقنية التصفية التعاونية (Collaborative Filtering) وتقنية التصفية بناءً علي المحتوى (Content-Based Filtering)، هذه الورقة تلخص وتعرض التحديات التي تواجه هاتين التقنيتين والحلول المقترحة التي تطرقت إليها بعض الدراسات لمواجهة تلك التحديات، خلصت هذه الورقة إلي أن هذه التحديات ما زالت بيئة خصبة للبحث والتطوير وذلك بغرض زيادة دقة نظم التوصية وتقديم مقترحات أقرب للمستخدم، إذ أن بعض الحلول أظهرت تحديات أخرى، مثل دقة التوصيات في حالة التجميع وجودة البيانات في حالة ملء تقييمات مصفوفة البيانات.

الكلمات المفتاحية: Keywords: نظم التوصية (Recommender Systems)، التوصية التعاونية (Collaborative Filtering)، التوصية بناءً علي المحتوى (Content-Based Filtering).

1- المقدمة:

تستخدم نظم التوصية في العديد من تطبيقات الويب مثل التجارة الإلكترونية وبوابات الأخبار وإعلانات وما إلى ذلك، فهي تعتبر أداة تساعد المستخدم علي التغلب علي التحميل الزائد للمعلومات كما تساعده في عملية البحث عن المعلومات واتخاذ القرار مثلاً : أي منتج سيشترى؟ أو أي كتاب سيقراء؟ حيث تقوم نظم التوصية باستخدام تقنيات تصفية البيانات لتقديم مقترحات لعناصر تتوافق مع ما يفضلها المستخدم. لخص (Jannach, D) وآخرون، (2010) هذه التقنيات في ثلاث تقنيات وهي: تقنية التصفية التعاونية (Collaborative Filtering) وتقنية التصفية بناءً علي المحتوى (Content-Based Filtering) وتقنية التصفية بناءً علي المعرفة (Knowledge-Based Filtering) (لا تشملها هذه الورقة)، كما يمكن تصفية البيانات عن طريق دمج التقنيات السابقة وذلك فيما يُعرف بتقنية التصفية المختلطة (Hybrid Filtering). تختلف نظم التوصية باختلاف التقنية المستخدمة لتصفية البيانات، إذ أن لكل تقنية طريقة مغايرة عن التقنية الأخرى، مثلاً تعتمد تقنية التصفية التعاونية علي بيانات المستخدم وبيانات المستخدمين الآخرين، أما تقنية التصفية بناءً علي المحتوى فتعتمد علي بيانات المستخدم وبيانات العناصر. في هذه الورقة سوف نستعرض التحديات التي تواجه تقنية التصفية التعاونية وتقنية التصفية بناءً علي المحتوى ونوضح الحلول المقترحة التي تناولتها بعض الدراسات ذات العلاقة.


تم تنظيم الورقة على النحو التالي: في القسم 2 سوف نوضح طريقة عمل كل تقنية، يليه القسم 3 يوضح التقنيات الفرعية والتقنيات المختلطة، أما القسم 4 يتناول مزايا كل تقنية، في القسم 5 سنتناول التحديات والحلول المقترحة في التقنيتين، نختم بالخلاصة في القسم 6.

2- طريقة تصفية البيانات في تقنية التصفية التعاونية و

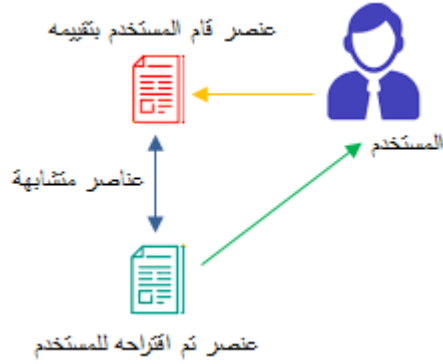
تقنية التصفية بناءً علي المحتوى :

1-2 طريقة تصفية البيانات في تقنية التصفية التعاونية:

الفكرة الأساسية لتقنية التصفية التعاونية هي أنه إذا كان المستخدمون قد شاركوا نفس الاهتمامات في الماضي فسيكون لهم أيضاً تفضيلات متشابهة في المستقبل. إذ تعتمد هذه التقنية على جمع وتحليل بيانات سلوك المستخدمين تجاه العناصر، حيث يتم التعبير عن العلاقة بين المستخدمين والعناصر من خلال التقييم (Rating)، وهو يمثل درجة تفضيل المستخدم للعنصر التي قد يُعبر عنها المستخدم صراحةً أو ضمناً. يعتبر المستخدمون متشابهون في حال إشتراكهم في تقييم نفس العناصر، عندها يمكن التوصية بالعناصر التي يقيمها أحد المستخدمين بشكل إيجابي للمستخدم الآخر، كما في (الشكل-1).




الشكل-1: تقنية التصفية التعاونية



الشكل-2 : تقنية التوصية بناءً على المحتوى.

3- التقنيات الفرعية و المختلطة في تقنية التوصية التعاونية و تقنية التوصية بناءً على المحتوى:

تحتوي كل من تقنية التوصية التعاونية و تقنية التوصية بناءً على المحتوى علي تقنيات فرعية و نماذج تنبؤية يتم استخدامها لتصفية البيانات في نظم التوصية، كما يمكن تصفية البيانات من خلال دمج هذه التقنيات و ذلك فيما يعرف بالتقنية المختلطة. (الشكل-3) يوضح التقنيات الفرعية و التقنيات المختلطة لكلا التقنيتين و التي سنتناولها بالشرح في هذا القسم.



الشكل-3: التقنيات الفرعية و التقنيات المختلطة في تقنية التوصية التعاونية و تقنية التوصية بناءً على المحتوى – تمت ترجمته من

(2019 . Sinha,B., Dhanalakshmi, R.)

لتصفية البيانات وذلك فما يعرف باسم تحليل القيمة الفردية (Singular Value Decomposition).

2-3 التقنيات الفرعية في تقنية التصفية بناءً على المحتوى:

لا تحتوي تقنية التصفية بناءً على المحتوى على تقنيات فرعية غير أنه كما بين (Aggarwal, C.) (2016) من الممكن إنشاء الملف التعريفي للمستخدم عبر بناء نموذج للتنبؤ باهتمامات المستخدم، إذ يتم استخدام تقييمات المستخدم بالإضافة إلى مواصفات العناصر لبناء النموذج ومن ثم تدريبه. تستخدم تقنية التصفية بناءً على المحتوى العديد من الأساليب لبناء نموذج التصفية، مثل استخدام نموذج مساحة المتجه (Vector Space Model) كما في (Lops, P.) وآخرون، (2011) حيث تم بناء ملفات تعريف المستخدمين عن طريق تحويل تمثيل الكلمات المفتاحية إلى تمثيل معاني هذه الكلمات وذلك باستخدام المعرفة المعجمية المخزنة في قاعدة البيانات المعجمية MultiWordNet. كذلك من الممكن بناء النموذج باستخدام شجرة القرار Decision Tree كما في (Pazzani, M.) وآخرون، (1996) و (Cantador, I.) وآخرون، (2009). كذلك يمكن بناء النموذج باستخدام الشبكات العصبية مثل (Musto, C.) وآخرون، (2016) فقد قاموا ببناء شبكة عصبية عميقة قادرة على تقديم مقترحات تم تعلمها من المعلومات النصية عن طريق السؤال والجواب، وذلك بإستغلال التشابه بين الأسئلة وملفات تعريف المستخدمين مع الإجابات والعناصر. أيضاً من أساليب بناء النموذج استخدام النماذج الإحصائية كما في (Pazzani, M.) وآخرون، (1996) و (Jayeck, K., Mahjoub, M.) (2012) و (Nguyen, S.) (2019).

3-3 التقنيات المختلطة في تقنية التصفية التعاونية و تقنية التصفية بناءً على المحتوى:

يقصد بتقنية التصفية المختلطة (Hybrid Filtering Technique) الجمع بين تقنيتين أو أكثر بطرق مختلفة وذلك لتعزيز نقاط الضعف التي تنطوي على استخدام هذه التقنيات بصورة مفردة، أوضح (Burke, R.) (2002) أنه يمكن دمج هذه التقنيات بعدة طرق وهي:

- 1) **الدمج الموزون (Weighted)**: يتم فيه جمع نتائج العديد من تقنيات التوصية بصورة عددية.
- 2) **الدمج بالتبديل (Switching)**: يتم فيه التبديل بين تقنيات التوصية وفقاً للوضع الحالي.
- 3) **الدمج المختلط (Mixed)**: يتم فيه تقديم توصيات من عدة تقنيات مختلفة في نفس الوقت.
- 4) **الدمج بجمع الميزات (Feature combination)**: يتم فيه تجميع الميزات من مصادر بيانات التوصية المختلفة معاً في خوارزمية توصية واحدة.
- 5) **الدمج بزيادة الميزات (Feature augmentation)**: يتم استخدام تقنية توصية واحدة لحساب ميزة أو مجموعة من الميزات، والتي تعد جزءاً من الإدخال للتقنية التالية.
- 6) **الدمج بالتتالي (Cascade)**: يتم فيه التوصية بالتتالي بحيث يتم استغلال التوصيات المسبقة كأساس لإشتقاق التوصيات الحالية.

1-3 التقنيات الفرعية من تقنية التصفية التعاونية:

تعمل تقنية التصفية التعاونية على استغلال تقييمات المستخدم بصورة مباشرة أو غير مباشرة للتنبؤ بما سيفضله المستخدم، ففي حالة استخدام التقييمات بصورة مباشرة وهو النوع الأول من طرق التصفية التعاونية يكون التنبؤ استناداً إلى تشابه أو تجاوز المستخدم أو العنصر وهي ما عرّفه (Francesco و آخرون، 2010) بطرق التصفية بناءً على التجاور (neighborhood-Based) أو طرق التصفية بناءً على الذاكرة (Memory-Based methods)، وتستخدم هذه الطرق العديد من الخوارزميات لقياس التشابه منها خوارزمية الجار الأقرب (k-Nearest Neighbors) والتي يمكنها قياس التشابه بين المستخدم والمستخدمين الآخرين وهو ما يسمى بالتصفية بناءً على المستخدم (User-Based Filtering) أو التشابه بين العنصر والعناصر الأخرى وهو ما يسمى بالتصفية بناءً على العنصر (Item-Based Filtering). أما في النوع الثاني من طرق التصفية التعاونية يتم فيه إستغلال تقييمات المستخدم للعناصر بصورة غير مباشرة وذلك عن طريق استخدام تقييمات المستخدم لتعلم نموذج تنبؤي وتسمى بطرق التصفية بناءً على النموذج (Model-Based methods)، وفي هذه الطريقة يتم بناء نموذج لتفاعلات المستخدم مع العنصر بالإضافة إلى العوامل التي تمثل الخصائص الكامنة للمستخدمين أو للعناصر، مثل فئات المستخدمين حسب التفضيل أو فئات العناصر حسب الأصناف، يلي ذلك تدريب هذا النموذج على استخدام البيانات المتاحة كي يستخدم لاحقاً للتنبؤ بتقييمات المستخدمين للعناصر الجديدة. إستخدمت العديد من الدراسات أساليب مختلفة لبناء نظم توصية تعاونية تعتمد على النموذج مثلاً استخدام (Covington, P.) وآخرون، (2016) الشبكات العصبية (Neural Networks) حيث تم بناء شبكة عصبية لتوليد العناصر المرشحة للاقتراح وشبكة عصبية أخرى لترتيب تلك المقترحات، أما (Gao, C.) وآخرون، (2018) فقد استخدموا الشبكات العصبية لتعلم تفاعلات وسلوك المستخدمين تجاه العناصر. كما يمكن بناء نموذج توصية باستخدام قواعد الارتباط (Association Rules) مثلاً (Cho, Y.) وآخرون، (2002) استخدموا قواعد الارتباط لتحديد الفئة التي ينتمي إليها العنصر، أما (Davidson, J.) وآخرون، (2010) فقد استخدموها لتعريف العناصر المتشابهة. كذلك من الممكن استخدام تقنيات التجميع (Clustering Techniques) مثلاً قام (Li, Q., Kim, B.) (2003) بتجميع العناصر وتقديم معلومات عن المحتوى للعناصر التي تم تجميعها و (Das, A.) وآخرون، (2007) قاموا بتجميع المستخدمين بناءً على تفاعلهم مع العناصر. أيضاً من نماذج التصفية التعاونية استخدام شبكات النظرية الافتراضية (Bayesian Networks) فلقد استخدمها (Decampos, L.) وآخرون، (2010) لتمثيل كيفية ارتباط المستخدمين والعناصر وقياس قوة هذا الارتباط. كما يمكن استخدام نموذج التحليل الدلالي الكامن (Latent Semantic Analysis) لبناء نظم توصية، حيث فرض (Hofmann, T.) (2004) احتمالية تواجد مشترك بين متغيرات مخفية ومجموعة الأزواج المتكونة من (مستخدم، عنصر). أما (Funk, S.) (2006) فقد استخدم طريقة معالجة عوامل مصفوفة البيانات

إهتماماً بهذه العناصر، مما يضفي بعض التنوع في العناصر المقترحة. و بالمقابل تتغلب تقنية التصفية بناءً على المحتوى علي تقنية التصفية التعاونية في أنها تضمن إستقلالية المستخدم إذ أنها تقدم توصية أو مقترحات بالإعتماد علي الملف التعريفي للمستخدم و الذي يستند علي تقييمات المستخدم الحالي دون الحاجة لتقييمات مستخدمين آخر (المستخدمين المشاهدين/المجاورين). علاوة علي ذلك تمتاز هذه التقنية بالشفافية إذ أنها يمكن أن تقدم توضيحات للمستخدم عن سبب اختيار العناصر التي تم التوصية بها أو اقتراحها وذلك من خلال توضيح مواصفات تلك العناصر والتي تطابق مواصفات العناصر الموجودة بالملف التعريفي للمستخدم أي العناصر التي تم تقييمها مسبقاً من قبل المستخدم نفسه و ليس من قبل مستخدمين آخر (المستخدمين المشاهدين/المجاورين). كذلك يمكن لهذه التقنية تقديم توصية أو مقترحات لعناصر لم يتم تقييمها من قبل أي مستخدم، أو تقديم مقترحات لعناصر غير شائعة أو غير رائجة، إذ أنها تعتمد علي مواصفات العنصر و الملف التعريفي للمستخدم دون التأثير بتقييمات مستخدمين آخر (المستخدمين المشاهدين/المجاورين)، مما يجعل من السهل التوسع إلي عدد كبير من المستخدمين.

يمكن تلخيص ما سبق في (الجدول-1) حيث نقارن بين تقنية التصفية التعاونية و تقنية التصفية بناءً علي المحتوى وفقاً للمزايا المذكورة لتوضيح إمكانية توفر كل ميزة أو عدم توفرها في كل تقنية.

7) **الدمج عن طريق Meta-level**: يتم تطبيق تقنية توصية واحدة وتنتج نوعاً من النموذج ، وهو ما يمثل عندئذ المدخلات المستخدمة في التقنية التالية.

يُن (Çano, E. , Morisio, M.) (2017) أن الجمع بين تقنيتي التصفية التعاونية و التصفية بناءً علي المحتوى من التقنيات الناجحة في كثير من الأنظمة، وفقاً لما ذكره (Burke, R.) (2002) يعتبر الدمج الموزون و الدمج بالتبديل و الدمج بجمع الميزات و الدمج بزيادة الميزات من أكثر طرق الدمج المتكررة بين هاتين التقنيتين.

4- مزايا تقنية التصفية التعاونية و تقنية التصفية بناءً علي المحتوى:

لدي كل من تقنية التصفية التعاونية و تقنية التصفية بناءً علي المحتوى العديد من المزايا التي تجعل كل تقنية تختلف عن التقنية الأخرى، أوضح (Ricci, F.) وآخرون، (2010) أن تقنية التصفية التعاونية تتغلب على بعض القيود المفروضة على تقنية التصفية بناءً علي المحتوى، فالعناصر التي قد لا تتوفر لها محتوى أو يصعب الحصول عليه، يمكن لتقنية التصفية التعاونية تقديم توصية أو مقترحات بهذه العناصر من خلال تقييمات المستخدمين الآخرين. علاوة على ذلك تعتمد التوصيات التعاونية على جودة العناصر التي يتم تقييمها من قبل المستخدمين بدلاً من الاعتماد على المحتوى الذي قد يكون مؤشراً سيئاً لجودة العنصر، كذلك و بخلاف الأنظمة بناءً على المحتوى يمكن لأنظمة التصفية التعاونية أن توصي بعناصر ذات مواصفات مختلفة تماماً طالما أبدى المستخدمون الآخرون

الجدول-1: مزايا تقنية التصفية التعاونية و تقنية التصفية بناءً علي المحتوى:

الرقم	الميزة	تقنية التصفية التعاونية	تقنية التصفية بناءً علي المحتوى
1	عدد المستخدمين	تعتمد علي عدد من المستخدمين المشاهدين	تعتمد علي مستخدم واحد
2	إضافة عنصر جديد	لا تقدم مقترحات للعنصر الجديد لأنها تعتمد علي وجود تقييمات مسبقاً للعنصر	تقدم مقترحات للعناصر الجديد لأنها تعتمد علي مواصفات العنصر
3	مواصفات العنصر	تقدم مقترحات لعناصر ليست لديها مواصفات لأنها تعتمد علي تقييمات هذه العناصر	لا تقدم مقترحات لعناصر ليست لديها مواصفات لأنها تعتمد عليها في التوصية
4	جودة العناصر المقترحة	تعتمد جودة العناصر المقترحة علي تقييمات المستخدمين المشاهدين (مؤشرو قوي)	تعتمد جودة العناصر المقترحة علي مواصفات المحتوى (مؤشر ضعيف)
5	إستقلالية المستخدم	تقدم مقترحات مرتبطة بإختيارات المستخدمين المشاهدين	تقدم مقترحات مرتبطة بإختيارات المستخدم لأنها تعتمد علي الملف التعريفي للمستخدم
6	الشفافية	لا تقدم تفسير للمستخدم عن سبب إختيار المقترحات لأنها تعتمد علي إختيارات المستخدمين المشاهدين	تقدم تفسير للمستخدم عن سبب إختيار المقترحات لأنها تطابقها مع مواصفات عناصر المستخدم
7	تنوع المقترحات	تقدم مقترحات قد تتنوع لأنها تعتمد علي إختيارات المستخدمين المشاهدين	تقدم مقترحات تطابق مواصفات العناصر التي قام المستخدم بتقييمها مسبقاً
8	تغير سلوك المستخدم	تدرك التغيير في سلوك المستخدم على مدى الزمن (Sinha, B., Dhanalakshmi, R.) (2019)	لا تدرك التغيير في سلوك المستخدم على مدى الزمن

مجموعة من مجموعات المستخدمين تكون المقترحات غير دقيقة و ذلك لعدم أو لقلّة تواجد المستخدمين المشابهين/المجاورين.

تناولت العديد من الدراسات هذه التحديات و طرحت بعض الحلول تم توضيحها في الجدول (2)، ففي حالة قلّة البيانات عمدت بعض الدراسات إلى استخدام ملء التقييمات المفقودة بقيم إفتراضية كما في (Konstan, J.) وآخرون، (1997)، أما (Li, Q., Kim, B.) و (Xue, G.) وآخرون، (2005) فقد إستخدموا تقنيات التجميع للملء التقييمات المفقودة ببيانات المجموعات. في بعض الدراسات تم ملء التقييمات المفقودة باستخدام معلومات المحتوى باعتبارها أكثر موثوقية كما في (Degemmis, M.) وآخرون، (2007) و (Kula, M.) (2015) البعض الآخر إستخدم تقييمات ناتجة من تقنية أخرى للملء التقييمات المفقودة مثل (Geetha, G.) وآخرون، (2018). ركزت بعض الدراسات علي إستغلال مصادر المعلومات الضمنية لجمع بيانات المستخدم إذ يحتوي هذا النوع من المصادر علي قدر كبير من المعلومات، ومن ثم تحويل تلك البيانات التي تم جمعها إلى تقييمات لتغذية مصفوفة البيانات، كما في (Wang, B.) وآخرون، (2018). ولمواجهة مشكلة التحيز للعناصر الشائعة فقد وضعوا (Gautam, A.) وآخرون، (2014) معيار لقياس درجة حداثة العنصر لتفادي اقتراح العناصر الشائعة، أما (Abdollahpouri, H.) وآخرون، (2019) فقد أعادوا ترتيب المقترحات و ذلك للترويج للعناصر الأقل شيوعاً. ولمواجهة تحدي قابلية التوسع تم استخدام تقنيات التجميع (Clustering) حيث تم تجميع المستخدمين باستخدام خوارزمية K-means كما في (Xue, G.) وآخرون، (2005)، أما (Das, A.) وآخرون، (2007) فقد قاموا بتجميع المستخدمين أو العناصر ثم قياس التشابه بين المستخدم و مجموعات التجميع ليتم اختيار المستخدمين المشابهين/المجاورين من المجموعة الأقرب للمستخدم. أما بالنسبة لمشكلة Gray Sheep لجأت بعض النظم إلى تقديم مقترحات بالعناصر الأكثر شيوعاً بين هذه المجموعة كما في (Kim, M., Im, I.)، (2014)، البعض الآخر عمد إلى تحويل المستخدمين الذين تختلف تفضيلاتهم مع المستخدم المستهدف إلى جيران متشابهين جدد و ذلك بفرض التشابه في الاختلاف مع المستخدم المستهدف كما في (Faziziki, A.) وآخرون، (2019).

5- التحديات و الحلول المقترحة في تقنية التصفية التعاونية و تقنية التصفية بناءً علي المحتوى:

تواجه كلا التقنيتين العديد من التحديات التي تتعلق بجمع البيانات و تحديد المقترحات وغيرها، سوف نتناول هذه التحديات و نستعرض الحلول التي تطرقت إليها بعض الدراسات.

1-5 التحديات و الحلول المقترحة في تقنية التصفية التعاونية:

تواجه دقة نظم التوصية التي تستخدم طرق التصفية بناءً علي الذاكرة (Memory-Based methods) عدد من التحديات نوضحها فيما يلي:

(1) **قلّة البيانات (Data sparsity):** و هو ما يعرف بمشكلة قلّة أو تناثر البيانات وهي مشكلة شائعة في معظم أنظمة التوصية من هذا النوع و ذلك بسبب أن المستخدمين يقيمون عادة نسبة صغيرة فقط من العناصر المتاحة و بالتالي يكون من الصعب تقديم مقترحات دقيقة، و ذلك لقلّة المعلومات المتوفرة حول تقييمات المستخدمين الآخرين.

(2) **البداية الباردة (Cold-Start):** تظهر هذه المشكلة بسبب أن المستخدمين أو العناصر المضافة حديثاً إلى النظام قد لا تحتوي على تقييمات على الإطلاق مما يفاقم مشكلة قلّة البيانات، لذا فمن المرجح أن لا تتوفر تقييمات مشتركة للمستخدمين أو للعناصر المضافة حديثاً لمقارنتها مع الموجودة مسبقاً.

(3) **التحيز للعناصر الشائعة (Popularity Bias):** و هي الحالة التي يتم تقديم المقترحات بالعناصر الشائعة بشكل متكرر، تظهر هذه المشكلة عندما لا تتوفر تقييمات مشتركة للمستخدمين أو للعناصر، و بالتالي يكون التنبؤ لعدد محدود من العناصر وهي العناصر الأكثر شيوعاً أو رواجاً بين المستخدمين المشابهين/المجاورين.

(4) **قابلية التوسع (Scalability):** ظهرت هذه المشكلة مع نمو أعداد المستخدمين و العناصر بصورة كبيرة، إذ تحتاج العديد من الأنظمة إلى الاستجابة الفورية للمتطلبات عبر الإنترنت وتقديم توصيات لجميع المستخدمين بغض النظر عن سجلهم التاريخي و تقييماتهم، الأمر الذي يتطلب زيادة إمكانية التوسع لدي هذه الأنظمة.

(5) **Gray Sheep:** يقصد بها حالة عدم وجود مجموعة مشابهة للمستخدم، ففي حالة عدم الإتفاق أو عدم الإشتراك في التقييم مع أي

الجدول-2: تحديات تقنية التصفية التعاونية وبعض الحلول المقترحة ومصادرها

التحدي	الحلول المقترحة	المصدر
قلة البيانات		
● ملء التقييمات المفقودة بقيمة متوسط تقييمات المستخدم.		(Konstan, J. وآخرون، 1997)
● تجميع العناصر و ادخال تقييمات مجموعة العناصر التي تم تجميعها إلي تصفية تعاونية.		(Li, Q. , Kim, B.) (2003،
● ملء التقييمات المفقودة من خلال تجميع المستخدمين ثم إستخدام تقنيات تجانس المجموعة (Cluster-Based Smoothing Technique) و معالجة اللغات الطبيعية (Nature Language Processing) لتقدير تلك التقييمات بناء علي المواضيع ذات العلاقة بالمجموعة.		(Xue, G.) وآخرون، (2005
● إستخدام بيانات المحتوى لمعرفة التشابه بين المستخدمين وذلك من خلال دمج المعرفة اللغوية (Linguistic Knowledge) في عملية تعلم ملفات تعريف المستخدمين.		(Degemmis, M.) وآخرون، (2007
● إستخدام بيانات المحتوى لملء مصفوفة العوامل بالخصائص الكامنة (Latent Factors) المشتقة من بيانات تعريف العنصر و المستخدم.		(Kula, M.) (2015 ،
● تحويل سلوك المستخدم وتسلسل العناصر إلي تقييمات لتغذية مصفوفة البيانات.		(Wang, B.) وآخرون، (2018
البداية الباردة		
● ملء التقييمات المفقودة بقيمة متوسط تقييمات المستخدم وذلك للتمكن من تقديم مقترحات للمستخدم الجديد.		(Konstan, J. وآخرون، 1997)
● تجميع العناصر و ادخال تقييمات مجموعة العناصر التي تم تجميعها إلي تصفية تعاونية.		(Li, Q. , Kim, B.) (2003،
● إستخدام بيانات المحتوى لملء مصفوفة العوامل بالخصائص الكامنة (Latent Factors) المشتقة من بيانات تعريف العنصر و المستخدم.		(Kula, M.) (2015 ،
● ملء التقييمات المفقودة بالتقييمات المتوقعة الناتجة عن تطبيق تقنية التصفية بناءً علي المحتوى بالإضافة إلي تقنيات التجميع و التصنيف و من ثم إجراء تصفية تعاونية علي مصفوفة البيانات الناتجة.		(Geetha,G.) وآخرون، (2018
● تحويل سلوك المستخدم وتسلسل العناصر إلي تقييمات لتغذية مصفوفة البيانات.		(Wang, B.) وآخرون، (2018

Gautam, A.) وآخرون، (2014)	● وضع مقياس لدرجة حداثة العنصر (Novelty Score) والذي يزداد مع ازدياد شيوخ العنصر بين المستخدمين ويتناقص مع ازدياد نسبة المستخدمين الذين قاموا بتقييم العنصر، يتم اقتراح العناصر المرتبطة بالمستخدم والتي لم يرها أو لم يقيّمها من قبل.	التحيز للعناصر الشائعة
Abdollahpouri, H.) وآخرون، (2019)	● تخصيص المقترحات للمستخدم عن طريق إعادة ترتيب المقترحات بالترويج للعناصر ذات الذيل الطويل (Long-Tail Items) وذلك بزيادة تمثيل العناصر الأقل شيوعاً والتي تقع ضمن اهتمامات المستخدم.	
Xue, G.) وآخرون، (2005)	● تجميع المستخدمين باستخدام خوارزمية K-means ثم استخدام تقنيات تجانس بيانات المجموعة ملء التقييمات المفقودة.	قابلية التوسع
Das, A.) وآخرون ، (2007)	● تجميع المستخدمين بناءً على تداخل تقييمات المستخدمين لنفس مجموعة العناصر.	
Kim, M. , Im, I.) (2014)	● تحديد المستخدمين ذوي التفضيلات الفريدة من خلال درجة مركزية المستخدم والتي تقاس بعدد الإرتباطات المباشرة من وإلى العقدة ثم تقديم مقترحات بالعناصر الشائعة بين هؤلاء المستخدمين.	Gray Sheep
Fazizki, A.) وآخرون، (2019)	● اختيار مشاهير جدد بجامع التشابه في عدم الاتفاق و بالتالي يتم ايجاد مستخدمين مشاهيرين.	

التي تم تقييمها بالفعل، أي بصيغة أخرى لا توجد توصيات تتجاوز ملف تعريف المستخدم.

(3) المستخدم الجديد (New User): وهي حالة من مشكلة البداية الباردة وذلك حين يضاف مستخدم جديد للنظام ففي هذه الحالة لا تتوفر للنظام تقييمات كافية للمستخدم مما يجعل من الصعب معرفة تفضيلات المستخدم.

تطرق بعض الدراسات إلى هذه التحديات منها (M. Degemmis وآخرون، 2007) و (M. Degemmis وآخرون، 2015) الذين عكفوا على زيادة حدود المحتوى وذلك عن طريق تفسير وإدراك معاني المفردات في ملف المستخدم التعريفي باستخدام مصادر معرفية مختلفة، أما (Singh, V. وآخرون، 2011) فقد استخدموا تقنيات التحليل العاطفي (Sentiment Analysis) لفهم وتفسير آراء المستخدم.

و للتغلب على مشكلة التخصيص الزائد استخدم (Adamopoulos, P., Tuzhilin, A. ، 2014) تقنية إختيار الجار الإحتمالي Probabilistic Neighborhood Selection Technique لإختيار المستخدمين المشاهير بدلاً عن استخدام تقنية الجار الأقرب K-Nearest Neighbors، كذلك استخدم (Son, J., Kim, S. ، 2017) شبكة متعددة المسارات لربط العناصر ثم قياس أوجه الشبه بينها.

لجأت بعض الدراسات إلى استخدام التقنية المختلطة لمعالجة مشكلة المستخدم الجديد فقد اقترح (Sun, D. وآخرون، 2011) استخدام تقييمات

2-5 التحديات والحلول المقترحة في تقنية التصنيف بناءً على المحتوى: أما تقنية التصنيف بناءً على المحتوى فتواجه العديد من التحديات التي تم توضيحها مع بعض الحلول المقترحة في الجدول (3)، وتمثل هذه التحديات في:

- (1) محدودية المحتوى (Limited Content Analysis): وذلك عندما يتم تحليل عدد ونوع محدد من المواصفات المرتبطة بالعناصر المقترحة، والتي يتم اكتسابها إما بصورة تلقائية أو تقديمها من قبل المستخدم، إذ أنه لا يمكن لهذه التقنية تقديم توصية أو مقترحات مناسبة إذا كان المحتوى الذي تم تحليله يحتوي على معلومات غير كافية، مثل استخراج الصفات الجمالية من النص أو استخراج معلومات عن الوسائط المتعددة كالصوت والصورة، ففي مثل هذه الحالات لا تتوفر معلومات كافية لتمييز العناصر التي قد يفضلها أو لا يفضلها المستخدم.
- (2) التخصيص الزائد (Over-Specialization): تقدم هذه التقنية مقترحات بالعناصر التي تكون درجة مطابقتها بالملف التعريفي للمستخدم عالية و بالتالي تكون المقترحات ذات درجة محدودة من الحداثة لأن العناصر المقترحة تكون مماثلة لتلك

المستخدمين بالإضافة إلى معلومات المستخدم الديموغرافية، أما Geetha,G.) و آخرون، (2018) فقد إستخدموا معلومات مجموعات المستخدمين لإجراء تصفية تعاونية.

الجدول-3: تحديات تقنية التصفية بناءً علي المحتوى وبعض الحلول المقترحة و مصادرها

التحدي	الحلول المقترحة	المصدر
محدودية المحتوى	دمج المعرفة اللغوية في عملية تعلم ملفات تعريف المستخدمين وذلك من خلال تفسير وإدراك معاني المفردات في ملف المستخدم التعريفي باستخدام المعرفة المعجمية المخزنة في قاعدة البيانات المعجمية WordNet.	Degemmis, M.) (و آخرون، 2007)
	تصنيف معاني المفردات، إما من أعلى لأسفل وفيه يعتمد المعنى علي مصادر معرفة خارجية، أو من أسفل لأعلي وفيه يعتمد معني المفردات على استخدامها في مجموعة كبيرة من المستندات النصية.	Degemmis, M.) (و آخرون، 2015)
	إستخدام تقنيات التحليل العاطفي (Sentiment Analysis) لفهم و تفسير آراء المستخدم.	(Singh, V.) (آخرون، 2011)
التخصيص الزائد	إستخدام تقنية إختيار الجار الإحتمالي (Probabilistic Neighborhood Selection Technique) لإختيار المستخدمين المشابهين بدلاً عن إستخدام تقنية الجار الأقرب (K-Nearest Neighbors) أو الأكثر تشابهاً ، بحيث يتم أخذ عينات مرجحة من المستخدمين المشابهين مع الأخذ في الإعتبار مستويات التشابه بين المستخدم المستهدف و جميع المستخدمين المشابهين المرشحين، وبالتالي تقديم مقترحات عن طريق إختيار مجموعات متنوعة من المستخدمين المتشابهين.	Adamopoulos,) , P., Tuzhilin, A. (2014
	إستخدام شبكة متعددة المواصفات (multi attribute network) لتمثيل مواصفات العناصر تستخدم هذه الشبكة تقنيات المركزية (centrality) والتجميع (Clustering) لتمثيل العلاقات المشتركة بين العناصر، في تحليل هذه الشبكة يتم قياس أوجه التشابه بين العناصر المرتبطة بشكل مباشر و غير مباشر مما يضمن تنوع العناصر المقترحة.	Son, J., Kim, S.) (2017 ،
المستخدم الجديد	إستخدام تقنية مختلطة حيث يتم تجميع المستخدمين استنادًا إلى اهتماماتهم ثم استخدام نتائج المجموعات و معلومات المستخدمين الديموغرافية (الجنس، العمر، المهنة) لإنشاء شجرة قرار لربط المستخدمين الجدد بالمستخدمين الحاليين ثم إجراء تصفية تعاونية.	Sun, D.) (آخرون، 2011)

- استخدام تقنية مختلطة بالإضافة إلى تقنيات التجميع و التصنيف بحيث يتم تغذية مصفوفة بيانات التصفية التعاونية بالتقييمات الناتجة عن التقنية بناءً علي المحتوى.

و Geetha,G.)
آخرون، (2018)

Burke, R. 2002. *Hybrid Recommender Systems: Survey and Experiments*. User Modeling and User-Adapted Interaction. 12. 10.1023/A:1021240730564.

Çano, E. and Morisio, M. 2017. *Hybrid Recommender Systems: A Systematic Literature Review*. Intelligent Data Analysis. 21. 1487-1524. 10.3233/IDA-163209.

Cantador, I., Elliott, D. and Jose, J. 2009. *A Case Study of Exploiting Data Mining Techniques for an Industrial Recommender System*.

Cho,Y. , Kim,J. and Kim,S. 2002. *A personalized recommender system based on web usage mining and decision tree induction*. Expert Syst Appl, 23, pp. 329-342.

Covington, P., Adams, J. and Sargin, E. 2016. *Deep Neural Networks for YouTube Recommendations*. In Proceedings of the 10th ACM Conference on Recommender Systems (RecSys '16). Association for Computing Machinery, New York, NY, USA, 191–198. DOI:<https://doi.org/10.1145/2959100.2959190>.

Das, A., Datar, M., Garg, A. and Rajaram, S. 2007. *Google news personalization: scalable online collaborative filtering*, Proceedings of the 16th International Conference on World Wide Web (WWW '07) (New York), ACM Press, pp. 271–280.

Davidson, J., Liebald, B., Liu, J., Nandy,P., Vleet,T., Gargi,U., Gupta,S., He,Y., Lambert, M., Livingston, B. and Sampath, D. 2010. *The YouTube video recommendation system*. In Proceedings of the fourth ACM conference on Recommender systems (RecSys '10). Association for Computing Machinery, New York, NY, USA, 293–296. DOI:<https://doi.org/10.1145/1864708.1864770>.

Decampos, L., Fernández-Luna, J., Huete, J. and Rueda-Morales, M. 2010. *Combining content-based and collaborative*

6- الخلاصة:

تساعد أنظمة التوصية المستخدمين في العثور على العناصر المهمة حسب اهتماماتهم و رغباتهم فهي تعمل علي تصفية البيانات باستخدام تقنيات تصفية البيانات مثل تقنية التصفية التعاونية و تقنية التصفية بناءً علي المحتوى، تستخدم كل تقنية طريقة مختلفة عن الأخرى لتقديم المقترحات، لذلك كل تقنية تمتاز بمزايا تختلف عن الأخرى، مثلاً تعتمد تقنية التصفية التعاونية علي تقييمات مستخدمي الجوار و بالتالي يمكنها تقديم مقترحات متنوعة، بينما تعتمد تقنية التصفية بناءً علي المحتوى علي مواصفات المحتوى مما يمكنها من تقديم مقترحات للعناصر المضافة حديثاً للنظام. تناولت هذه الورقة التحديات التي تواجه كلا التقنيتين و قد استعرضت عدد من الدراسات التي اقترحت بعض الحلول لمواجهة تلك التحديات، إلا أن هذه الدراسات واجهت تحديات أخرى مثل دقة و موثوقية المقترحات في حالة التجميع، و جودة البيانات المستخدمة للمصفوفة التقييمية، و بذلك تجلي مدي الحاجة لمزيد من البحث و التطوير في هذا الإتجاه و ذلك بغرض زيادة دقة و موثوقية نظم التوصية، و تقديم توصيات ذات علاقة بالمستخدم.

المصادر والمراجع

Abdollahpouri, H., Burke, R. and Mobasher, B. 2019. *Managing Popularity Bias in Recommender Systems with Personalized Re-ranking*, The Thirty-Second International Florida Artificial Intelligence Research Society Conference (FLAIRS-32).

Adamopoulos, P., and Tuzhilin, A. 2014. *On Over-Specialization and Concentration Bias of Recommendations: Probabilistic Neighborhood Selection in Collaborative Filtering Systems*. In 8th ACM Conference on Recommender Systems: RecSys 2014 Association for Computing Machinery (ACM). <https://doi.org/10.1145/2645710.2645752>.

Aggarwal,C. 2016. *Recommender Systems: The Textbook* .1st. ed. Springer Publishing Company, Incorporated.

- Kim, M. and Im, I. 2014. *Resolving the 'Gray sheep' Problem Using Social Network Analysis (SNA) in Collaborative Filtering (CF) Recommender Systems*. Journal of Intelligence and Information Systems. 20. 137-148. 10.13088/jiis.2014.20.2.137\.
- Konstan, J., Miller, B., Maltz, D., Herlocker, J., Gordon, L. and Riedl, J. 1997. *GroupLens: applying collaborative filtering to usenet news*. Communications of the ACM 40(3), 77–87.
- Kula, M. 2015. *Metadata Embeddings for User and Item Cold-start Recommendations*. 1448.
- Li, Q., Kim, B. 2003. *An approach for combining content-based and collaborative filters*, In Proc. of IRAL2003.
- Lops, P., Musto, C., Narducci, F., Gemmis, M., Basile, P. and Semeraro, G. 2011. *A Semantic Content-based Recommender System for Cross-Language Personalization*.
- Musto, C., Greco, C., Suglia, A. and Semeraro, G. 2016. *Ask me any rating: A content-based recommender system based on recurrent neural networks*. In Proceedings of the IIR.
- Nguyen, S. 2019. *Model-Based Book Recommender Systems using Naïve Bayes enhanced with Optimal Feature Selection*. 217-222. 10.1145/3316615.3316727.
- Pazzani, M., Muramatsu, J. and Billsus, D. 1996. *Syskill and Webert: Identifying Interesting Web Sites*. In: Proceedings of the Thirteenth National Conference on Artificial Intelligence and the Eighth Innovative Applications of Artificial Intelligence Conference, pp. 54–61. AAAI Press / MIT Press, Menlo Park.
- Ricci, F., Rokach, L., Shapira, B. and B. Kantor, P. 2010. *Recommender Systems Handbook* (1st. ed.). Springer-Verlag, Berlin, Heidelberg.
- Singh, V., Mukherjee, M. and Mehta, G. 2011. *Combining a Content Filtering Heuristic and Sentiment Analysis for Movie Recommendations*. 10.1007/978-3-642-22786-8_83.
- Sinha, B., and Dhanalakshmi, R. 2019. *Evolution of recommender paradigm optimization over time*. ISSN 1319-1578, <https://doi.org/10.1016/j.jksuci.2019.06.008>. (<http://www.sciencedirect.com/science/article/pii/S1319157819304963>).
- recommendations: a hybrid approach based on Bayesian networks*. International Journal of Approximate Reasoning, 51(7), 785–799.
- Degemmis, M., Lops, P. and Semeraro, G. 2007. *A content-collaborative recommender that exploits wordnet-based user profiles for neighborhood formation*. User Modeling and User-Adapted Interaction 17(3), 217–255.
- Degemmis, M., Lops, P., Musto, C., Narducci, F. and Semeraro, G. 2015. *Semantics-Aware Content-Based Recommender Systems*. 10.1007/978-1-4899-7637-6_4.
- Fazziki, A., Aissaoui, O., Alami, Y., Alloui, Y. and Benbrahim, M. 2019, *A new collaborative approach to solve the gray-sheep users problem in recommender systems*. Third International Conference on Intelligent Computing in Data Sciences (ICDS), Marrakech, Morocco, pp. 1-4.
- Funk, S. 2006. *Netflix Update: Try this at Home*. <https://sifter.org/~simon/journal/20061211.html>.
- Gao, C., He, X., Gan, D., Chen, X., Feng, F., Li, Y., Chua, T. and Jin, D. 2018. *Learning Recommender Systems from Multi-Behavior Data*.
- Gautam, A., Bedi, P., Singh, R. and Sharma, C. 2014. *Using Novelty Score of Unseen items to Handle Popularity Bias in Recommender Systems*. Proceedings of 2014 International Conference on Contemporary Computing and Informatics, IC3I 2014. 10.1109/IC3I.2014.7019608.
- Geetha, G., Safa, M., Fancy, C. and Saranya, D. 2018. *A Hybrid Approach using Collaborative filtering and Content based Filtering for Recommender System*. Journal of Physics: Conference Series. 1000.012101. 10.1088/1742-6596/1000/1/012101.
- Hofmann, T., *Latent Semantic Models for Collaborative Filtering*, 2004, ACM Transactions on Information Systems 22 89–115.
- Jannach, D., Zanker, M., Felfernig, A. and Friedrich G. 2010. *Recommender Systems – An Introduction*. Cambridge University Press.
- Jayech, K. and Mahjoub, M. 2012. *New approach using Bayesian Network to improve content based image classification systems*. International Journal of Computer Science Issues. 7.

Son, J., and Kim, S. 2017. *Content-based filtering for recommendation systems using multiattribute networks*. Expert Systems with Applications, 89, 404-412. <https://doi.org/10.1016/j.eswa.2017.08.008>.

Sun, D., Li, C. and Luo, Z. 2011. *A content-enhanced approach for cold-start problem in collaborative filtering*. 10.1109/AIMSEC.2011.6010230.

Wang, B., Ye, F. and Xu, J. 2018. *A Personalized Recommendation Algorithm Based on the User's Implicit Feedback in E-Commerce*. Future Internet 10: 117.

Xue, G., Lin, C., Yang, Q., Xi, W., Zeng, H., Yu, Y. and Chen, Z. 2005. *Scalable collaborative filtering using cluster-based smoothing*. In Proceedings of the 28th annual international ACM SIGIR conference on Research and development in information retrieval (SIGIR '05). Association for Computing Machinery, New York, NY, USA, 114–121. DOI:<https://doi.org/10.1145/1076034.1076056>.