



كلية علوم الحاسوب وتقانة المعلومات

# نظام توصيه لمساعدة الإرشاد الأكاديمي

## Recommendation System to help Academic Advising

مشروع مقدم كأحد متطلبات الحصول على  
بكالوريوس الشرف في علوم الحاسوب

جامعة السودان للعلوم والتكنولوجيا  
كلية علوم الحاسوب وتقانة المعلومات

# نظام توصيه لمساعدة الإرشاد الأكاديمي

## Recommendation System to help Academic Advising

مشروع مقدم كأحد متطلبات الحصول على  
بكالوريوس الشرف في علوم الحاسوب

إعداد :

١. إيمان عبد الباسط مختار عوض الكريم

٢. سارة العاقب حسين أحمد

٣. عبير محمد عبد الماجد المكاوي

إشراف:

أ. وفاء فيصل مختار

أكتوبر ٢٠١٥

# الآيـة

بسم الله الرحمن الرحيم

(فَهَمَنَاهَا سُلَيْمَانٌ وَكُلَّا آتَيْنَا حُكْمًا وَعِلْمًا وَسَخَرْنَا مَعَ  
دَأْوَدَ الْجِبَالَ يُسَبِّحُنَّ وَالطَّيْرَ وَكُنَّا فَاعِلِينَ)

صدق الله العظيم

سورة الأنبياء الآية (٧٩)

# الحمد لله

الحمد لله الذي لا يحمد على مكر و سواه، الحمد لله الذي به تتم النعم و تكتمل الأعمال، الحمد لله عدد ما كان و عدد ما يكون و عدد الحركات والسكون،  
الحمد لله في الأولى والآخرة.

ولا نرى في الحمد إلا زيادة في العطاء فنحمدك الله على برك الجزيل  
ونشكر فضلك على توفيقك لنا وإنانتنا في إتمام هذا البحث وتقديمه  
بالمصورة المطلوبة.

ربى أدم صلاتك الكاملة وبركاتك الشاملة وسلامك على سيد الخلق أجمعين  
محمد خاتم النبيين "صلى الله عليه وسلم" وعلى آله وصحبه والتابعين،  
وابتعيهم ومن اهتدى بهدية إلى يوم الدين.

## الإِلَهُ

إلهي لا يطيب الليل إلا بشكرك ولا يطيب النهار إلى بطاعتك .. ولا تطيب اللحظات إلا  
بذكرك .. ولا تطيب الآخرة إلا بعفوك .. ولا تطيب الجنة إلا برؤيتك

الله جل جلاله

إلى من بلغ الرسالة وأدى الأمانة .. ونصح الأمة .. إلى نبي الرحمة ونور العالمين

سيدنا محمد صلى الله عليه وسلم

إلى ملاكي في الحياة .. إلى معنى الحب وإلى معنى الحنان والتفاني .. إلى بسمة  
الحياة وسر الوجود

إلى من كان دعائهما سر نجاحي وحنانها باسم جراحى إلى أغلى الحباب  
أمي الحبيبة

إلى من كله الله بالهيبة والوقار .. إلى من علمني العطاء بدون انتظار .. إلى من  
أحمل أسمه بكل افتخار .. أرجو من الله أن يمد في عمرك لترى ثماراً قد حان  
قطافها بعد طول انتظار وستبقى كلماتك نجوم أهتدى بها اليوم وفي الغد وإلى الأبد

(والدي العزيز)

إلى أخواتي ورفقاء دربي في هذه الحياة معكم أكون أنا وبدونكم أكون مثل لا شيء  
.. في نهاية مشواري أريد أنأشكركم على موافقكم النبيلة إلى يا من تطلع  
لنجاحي بنظرات الأمل

(أخوتي)

إلى الأخوات اللواتي لم تلدهن أمي .. إلى من تحلو بالإخاء وتميزوا بالوفاء  
والعطاء إلى ينابيع الصدق الصافي إلى من معهم سعدت ، وبرفقتهم في دروب  
الحياة الحلوة والحزينة سرت إلى من كانوا معي على طريق النجاح والخير  
إلى من عرفت كيف أجدهم وعلموني أن لا أضيعهم

(صديقاتي)

## **الشـكـر والـتـقـدـير**

ولو أتنى أوتيت كل بِلَاغَةٍ \* \* \* \* \*  
وأفنيت بِحُرْ النُّطْقِ فِي النُّظُمِ وَالنُّثُرِ  
لَمَا كُنْتُ بَعْدَ الْقُولِ إِلَّا مَقْصُراً \* \* \* \* \*  
وَمُعْتَرِفًا بِالْعَجَزِ عَنْ وَاجْبِ الشُّكْرِ

شـكـر مـغـلـفـ بـالـامـتنـانـ وـالـعـرـفـانـ وـأـقـولـ لـكـ  
أـنـ لـلنـجـاحـاتـ أـنـاسـ يـقـدـرونـ مـعـناـهـ ،ـ وـلـلـابـدـاعـ أـنـاسـ يـحـصـدـونـهـ ،ـ لـذـاـ نـقـدـرـ جـهـودـكـ  
فـلـكـ مـنـاـ كـلـ الثـنـاءـ وـالـتـقـدـيرـ  
الأـسـتـاذـةـ وـفـاءـ فـيـصـلـ مـخـتـارـ

إـلـيـ منـ أـضـاءـ بـعـلـمـهـ عـقـلـ غـيـرـهـ  
وـاهـدـيـ بـالـجـوـابـ الصـحـيـحـ حـيـرـةـ سـائـلـيـةـ  
فـاظـهـرـ بـسـماـحـتـهـ تـواـضـعـ الـعـلـمـاءـ  
وـبـرـحـابـتـهـ سـماـحـةـ الـعـارـفـينـ  
أـسـتـاذـ أـزـهـريـ فـضـلـ السـيـدـ

# المستخلص

في هذا البحث تم استخدام بعض طرق نظم التوصية لتقديم المساعدة في عملية الإرشاد الأكاديمي بالنسبة للطالب الجامعي بكلية علوم الحاسوب وتقانة المعلومات بجامعة السودان للعلوم والتكنولوجيا. استخدمنا تقنيات جديدة لمعالجة وتحليل البيانات والتوصل لأفضل التوصيات وتقديمها للطلاب للحد من المشكلات، بما يقلل من عبء الإرشاد الأكاديمي على الأساتذة المرشدين. استخدمنا خوارزمية الجار الأقرب (K-NN) في التصفية التعاونية (collaborative filtering) من طرق نظم التوصية، وخوارزمية (Apriori) من قواعد الارتباط (association rule) في أداة تنقيب البيانات مفتوحة المصدر Weka، على بيانات جمعت من استمرارات التسجيل للطلبة المتعثرين في مسيرتهم التعليمية، وتم الحصول على نتائجهم من نظام النتيجة. تحصلنا على نتائج مفيدة لتجنب تكرار القرارات التي لم تفلح في حل مشاكل الطلاب فيما يخص خطتهم الدراسية أو القرارات التي أدت إلى مشاكل أخرى للطلاب والتوصية بالقرارات التي نجحت في مساعدة الطلاب لتخطي مشاكلهم الدراسية والنجاح في مقرراتهم والحصول على نتائج أفضل. نسبة لقلة البيانات المستخدمة نحصل على النتائج المتوقعة من خوارزمية Apriori وخوارزمية (K-NN)، وللحصول على نتائج أفضل نوصي باستخدام كمية كبيرة من البيانات، بحيث يتتوفر ملف كامل لكل طالب، ومن ثم استخدام البيانات في نظام خليط من خوارزميات التصفية التعاونية (collaborative filtering) وقواعد الارتباط (association rules).

# **Abstract:**

In this research we proposed using some recommendation systems techniques that can help the Academic Advising process for the student of the Faculty of Computer Science and Information Technology at the University of Sudan for Science and Technology. New technologies were used to analyze the data and reach to the best recommendations and submit them to reduce the problems to meet the guidance needs of students and to reduce the burden of guidance councilors to teachers. We chose the nearest neighbor algorithm (KNN) from collaborative filtering recommendation systems techniques, and Aproiri algorithm of the association rules, applied in the data mining open source tool Weka. The data have been collected from the registration forms of students who have difficulties, their results were obtained from the records of the results system. Some recommendations results were obtained on directing and guiding the students that might help to avoid the repeating of inappropriate decisions that have not succeeded in solving the problems of students with regard to their plan of study or decisions that led to other problems for students, and some recommendation to help overcome their problems and academic success and getting the best results. Due to small size of information collected, we have not got the expected results after applying the two algorithms, we recommend using of a hybrid technique between KNN and Apriori and be applied on large database consisting of a complete record for each student.

# المصطلحات الموحدة

تعريفه	المصطلح
عبارة عن وحدة تعليمية يقصد بها ساعة محاضره أو ساعتان إلى ثلاثة من ساعات المتابعة أو العملي في الأسبوع لمدة خمسة عشر أسبوع (فصل دراسي).	الساعات المعتمدة
هو كشف يبين المقررات التي درسها الطالب في تسلسل والتقديرات التي أحرزها لهذه المقررات والمعدل الفصلي والتراكمي والمعدل التراكمي في كل فصل دراسي.	السجل الأكاديمي
يقصد بها درجة الطالب في المقرر من 100 مقسمة على 25 (أو على 30 لإزالة الرسوب) مقربه لمنزله عشرية واحدة.	الدرجة النقطية للمقرر:
تساوي حاصل ضرب الدرجة النقطية للمقرر في عدد الساعات المعتمدة	نقط المقرر
هي مجموع الساعات المعتمدة للمقررات التي درسها الطالب في الفصل الدراسي المعين وجلس للامتحانات فيه مضافا إليها ساعات المقررات التي جلس لها امتحانا بديلا أو لإزالة الرسوب مع امتحانات الفصل	الساعات المعتمدة الفصلية للطالب
هي مجموع نقاط المقررات التي درسها الطالب في الفصل الدراسي المعين وجلس للامتحانات فيه مضافا إليها نقاط المقررات التي جلس لها امتحانا بديلا أو لإزالة الرسوب مع امتحانات الفصل	النقط الفصلية للطالب :
يقصد به حاصل قسمة النقاط الفصلية للطالب على الساعات المعتمدة الفصلية للطالب على الساعات المعتمدة الفصلية للطالب مقربه لمنزلتين عشرتين	المعدل الفصلي للطالب:
هي مجموع الساعات المعتمدة التراكمية للمقررات التي درسها الطالب وجلس للامتحان فيها لفصلين دراسيين على الأقل.	الساعات المعتمدة التراكمية للطالب :
هي مجموع نقاط المقررات التي سبق للطالب دراستها والجلوس للامتحان فيها لفصلين دراسيين على الأقل مضافا إليها أي مقرر يكرر الطالب الجلوس للامتحان فيه بعد مرات التكرار .	النقط التراكمية للطالب
يقصد به حاصل قسمة النقاط التراكمية على الساعات التراكمية للطالب مقربه لمنزلتين عشرتين.	المعدل التراكمي للطالب
هو ان يخضع الطالب للإنذار بالفصل من الدراسه إذا قل معدله التراكمي عن 2.00.	الإنذار الأكاديمي

# فهرس الأشكال

رقم الصفحة	موضوع الشكل	رقم الشكل
٤	خطوات اكتشاف المعرفة من قواعد البيانات	١.٢
٢٢	<b>Rattle واجهة</b>	٢.٢
٢٢	<b>(Rapid Miner) واجهة</b>	٣.٢
٢٣	<b>Apach Mahout واجهة</b>	٤.٢
٢٤	<b>pspp واجهة</b>	٥.٢
٢٥	<b>R واجهة</b>	٦.٢
٢٦	<b>شاشة بـدء تشغيل WEKA</b>	٧.٢
٢٦	شاشة المستكشف الرسومية قبل الاختيار	٨.٢
٢٧	المستكشف الرسوميـه بعد الاختيار	٩.٢
٤٤	<b>شاشة (classify)</b>	١٠.٢
٤١	استمارـة الطالب الأكـاديمـي	١.٥
٤٢	<b>(apriori) نموذج لـبيانـات</b>	٢.٥
٤٢	<b>(knn) نموذج لـبيانـات</b>	٣.٥
٤٣	<b>طـريـقة إختـيار خـوارـزمـيـة (Apriori)</b>	٤.٥
٤٤	<b>شاشة (confidence) و (support)</b>	٥.٥
٤٨	<b>شاشة (classify)</b>	٦.٥
٤٨	<b>نتائج الخوارزمية (Apriori)</b>	١.٦
٤٩	<b>مخطط نسب خوارزمية (KNN)</b>	٢.٦

# فهرس المحتويات

الصفحة	المقدمة	الباب الأول
١		١.١ مقدمة.
١		٢.١ مشكلة وأهمية البحث.
١		٣.١ أهداف البحث.
١		٤.١ منهجية البحث.
٢		٥.١ حدود البحث.
٢		٦.١ هيكلية البحث.
	<b>الباب الثاني تنقية البيانات</b>	
	<b>الفصل الأول تنقية البيانات</b>	
٦		١.١.٢ مقدمه
٦	٢.١.٢ خطوات استكشاف المعرفة من قواعد البيانات	
٦		١.٢.١.٢ اكتشاف البيانات
٦		٢.٢.١.٢ تصفية البيانات
٧		٣.٢.١.٢ تكامل البيانات
٧		٤.٢.١.٢ اختيار البيانات
٧		٥.٢.١.٢ تحويل البيانات
٧		٦.٢.١.٢ التنقية عن البيانات
٨		٧.٢.١.٢ تقييم النمط
٨		٨.٢.١.٢ تمثيل المعرفة وتقديمها
٨		٣.١.٢ أهداف التنقية
٨		٤.١.٢ أنواع تنقية البيانات
٨		١.٤.١.٢ التنقية التنبؤي
٨		٢.٤.١.٢ التنقية الوصفي
٨		١.٢.٥.١.٢ مهام تنقية البيانات
٨		١.٥.١.٢ العنقدة
٩		٢.٥.١.٢ اكتشاف التسلسل
٩		٣.٥.١.٢ التصنيف
٩		٤.٥.١.٢ الانحدار
٩		٥.٥.١.٢ التخلص
٩		٦.٥.١.٢ قاعدة الارتباط
١١		١.٦.٥.١.٢ قياسات قواعد الارتباط
١٢		٢.٦.٥.١.٢ خوارزمية (Apriori)
١٢		٦.١.٢ وسائل التنقية عن البيانات
١٢		٦.١.٦.١.٢ الاستدلال المبني على الحالات
١٢	١.١.٦.١.٢ الكشف عن القانون (Rule Discovery)	
١٢	٢.١.٦.١.٢ معالجة الإشارات (Signal Processing)	
١٢	٣.١.٦.١.٢ شبكات عصبية (Neural Net)	
١٢	٤.١.٦.١.٢ منحنيات غير ثابتة (Fractals)	
	<b>نظم التوصية</b>	<b>الفصل الثاني</b>
١٤		١.٢.٢ مقدمه
١٤		٢.٢.٢ تاريخ نظم التوصية

١٥	٣.٢.٢ نظم التوصية
١٥	٤.٢.٢ أنواع نظم التوصية
١٦	١.٤.٢.٢ الفلترة التعاونية (Collaborative Filtering)
١٧	١.١.٤.٢.٢ أنواع الفلترة التعاونية
١٧	٢.١.٤.٢.٢ تحديات الفلترة التعاونية
١٨	٢.٤.٢.٢ الفلترة على المحتوى (Content-based filtering)
١٨	٣.٤.٢.٢ نظم التوصية المختلطة (Hybrid Recommender System)
	أدوات تنقية البيانات
	الفصل الثالث
٢٠	١.٣.٢ مقدمة
٢٠	Rattle ٢.٣.٢
٢١	Rapid Miner ٣.٣.٢
٢١	Apache Mahout ٤.٣.٢
٢١	PSPP ٥.٣.٢
٢٢	R ٦.٣.٢
٢٣	Weka ٧.٣.٢
٢٤	١.٧.٣.٢ ملف (ARFF)
٢٤	٢.٧.٣.٢ تحميل البيانات في weka
	الباب الثالث الدراسات السابقة
٢٧	١.٢ دراسة أولى
٢٩	٢.٢ دراسة ثانية
٣٠	٣.٢ دراسة ثالثة
٣١	٤.٢ دراسة رابعة
	الباب الرابع الإرشاد الأكاديمي
٣٣	٤.١ مقدمة
٣٣	٤.٢ الإرشاد الأكاديمي
٣٣	٤.٣ أهمية الإرشاد الأكاديمي
٣٣	٤.٤ المرشد الأكاديمي
٣٤	٤.٥ مهام المرشد الأكاديمي
٣٤	٤.٦ المشاكل التي تواجه المرشد الأكاديمي
٣٤	٤.٧ بعض السمات الأساسية للساعات المعتندة
٣٥	٤.٨ حساب النتيجة
	الباب الخامس جمع البيانات
٣٧	٤.٩ مقدمة
٣٨	٤.١٠ اختيار البيانات
٣٨	٤.١١ تهيئة البيانات لقواعد الارتباط
٣٩	٤.١٢ تهيئة البيانات للفترة التعاونية
٣٩	٤.١٣ تنقية البيانات
٤٠	٤.١٤ طريقة اختيار خوارزمية الـ (Apriori)
٤٢	٤.١٥ كيفية عمل خوارزمية K-NN
	الباب السادس النتائج والتوصيات
٤٥	٤.١٦ مقدمة
٤٥	٤.١٧ نتائج خوارزمية (Apriori)
٤٥	٤.١٨ مناقشة نتائج خوارزمية Apriori
٤٦	٤.١٩ التوصيات

٤٦	<b>٦.٣.٣ مخطط يوضح نسب خوارزمية (KNN)</b>
٤٧	<b>١.٣.٦ مناقشة نتائج المخطط</b>
٤٧	<b>٢.٣.٦ التوصيات</b>
٤٨	<b>الخاتمة</b>
٥٠	<b>المراجع</b>

# الباب الأول

المقدمة

## **١. المقدمة**

مع زيادة أهمية الإرشاد الأكاديمي لنجاح الطالب ونجاح نظام الساعات المعتمدة الذي يعتمد نجاحه بالكامل على الإرشاد الجيد لتعريف الطلاب بالأنظمة الدراسية، ومساعدتهم على اتخاذ القرارات التي تتناسب مع قدراتهم وإمكاناتهم، وكذلك معاونتهم على السير في الدراسة على أفضل وجه ممكن، والتغلب على ما يعترضهم من عقبات، ولتمكن الطالب على التكيف الأكاديمي وال النفسي مع الواقع التعليمي لهذا النظام الذي يختلف كلياً عما اعتاده الطالب في المراحل السابقة لدراسته الجامعية، أصبح من الضروري إيجاد تقنيات وطرق ووسائل تساعد المرشد الأكاديمي في القيام بمهمنه تقديم التوصيات باستخدام تطبيقات الحاسوب، وجاءت فكرة نظم التوصية (recommender system) بطرق ذكية للمساعدة في حل المشاكل واتخاذ القرارات. ومن أجل تقديم التوصيات المناسبة، يجب على النظام أن يتعلم أولاً تقنيات المستخدم من خلال تحليل الأنشطة التصنيفية أو التوصيات الماضية.

## **٢. مشكلة البحث**

عدم توفر التدريب الكافي للمرشدين الأكاديميين والاعتماد على قدراتهم الشخصية في إكتساب الخبرة في الإرشاد كما يمثل الإرشاد عبئاً إدارياً إضافياً. وبشكل بعض المرشدين من زيادة عدد طلابهم مما يتذرع على المرشد الأكاديمي أحياناً القيام بمهمة الإرشاد بسبب كثرة المهام المسندة إليه أو لأي سبب آخر.

## **٣. أهداف البحث**

استخدام تقنيات جديدة لمساعدة المرشد الأكاديمي بتحليل البيانات والتوصل لأفضل التوصيات وتقديمها للحد من المشكلات بما يلبي الحاجات الإرشادية للطالب والتقليل من عبء الإرشاد على الأساتذة المرشدين، وتوجيه الطالب ومساعدته في اختيار المقررات الدراسية المناسبة في كل فصل.

## **٤. منهجية البحث**

في هذا المشروع سيتم إقتراح طريقة جديدة لمساعدة المرشد الأكاديمي قائمة على الطرق المستخدمة حالياً في نظم التوصية (recommender systems). هذه الطريقة المقترحة تهدف إلى بناء قرارات ونتائج ذات صلة بالارشاد الأكاديمي.

## **١.٥ حدود البحث**

تشمل الدراسة تطبيق طريقة واحدة من طرق نظم التوصية (collaborative filtering) على الإشراف الأكاديمي وذلك بإستخدام خوارزمية الجار الأقرب (K-NN)، وخوارزمية قواعد الارتباط في تنقيب البيانات وهي (apriori).

تتركز الدراسة على جامعة السودان للعلوم والتكنولوجيا في جوانب الإرشاد الأكاديمي، وقد إستخدمنا إستمارات طلاب كلية علوم الحاسوب وتقانة المعلومات في السنوات السابقة.

وقد تم إجراء هذا البحث في العام الدراسي ٢٠١٥م، بإجراء مقابلات شخصية مع مسئولين على الإشراف الأكاديمي والإداري، والشئون العلمية.

## **١.٦ هيكلية البحث**

يتضمن البحث بالإضافة إلى هذا الباب الأبواب :-

الباب الثاني : ويتضمن ثلاثة فصول تنقيب البيانات ونظم التوصية وأدوات تنقيب البيانات.

الباب الثالث : الدراسات السابقة

الباب الرابع: الإرشاد الأكاديمي.

الباب الخامس: منهجية البحث.

الباب السادس : مناقشة النتائج والتوصيات.

# **الباب الثاني**

**تنقیب البيانات**

**نظم التوصية**

**أدوات تنقیب البيانات**

٢.١ الفصل الأول: تنقیب البيانات

٢.٢ الفصل الثاني : نظم التوصية

٢.٣ الفصل الثالث: أدوات التنقیب البيانات

# **الفصل الأول**

## **تنقیب البيانات**

## ١.١.٢ مقدمة

التنقيب في البيانات هو عملية تحليل كمية بيانات (عادة ما تكون كمية كبيرة) لإيجاد علاقة منطقية تلخص البيانات بطريقة جديدة تكون مفهومة ومفيدة لصاحب البيانات. يطلق اسم "نماذج models" على العلاقات والبيانات الملخصة التي يتم الحصول عليها من التنقيب في البيانات. يتعامل تنقيب البيانات عادة مع بيانات قد تم الحصول عليها بغرض غير غرض التنقيب في البيانات (مثلاً قاعدة البيانات لمعاملات في مصرف ما) مما يعني أن طريقة التنقيب في البيانات لا تؤثر مطلقاً على طريقة تجميع البيانات ذاتها. هذه هي أحد النواحي التي يختلف فيها التنقيب في البيانات عن الإحصاء. يشير التعريف أيضاً إلى أن كمية البيانات تكون عادة كبيرة، أما في حال كون كمية البيانات صغيرة فيفضل استخدام الطرق الإحصائية العادية في تحليلها [1].

## ٢.١.٢ خطوات استكشاف المعرفة من قواعد البيانات

### Knowledge Discovery in Database (KDD):

بعد تنقيب البيانات (Data Mining) مرحلة من مراحل اكتشاف المعرفة في قواعد البيانات [2] التي تشير إلى استخراج المفاهيم الضمنية غير الاعتيادية والتي لم تكن معروفة سابقاً. اكتشاف المعرفة في قواعد البيانات (KDD) ليس بالعملية السهلة والتي قد يعتقد البعض أنها تتوقف عند تجميع البيانات وإدارتها، بل نراها تمتد إلى التحليل والتوقع والتنبؤ بما سيحدث مستقبلاً. وتتضمن خطوات (KDD) عدد من المراحل تبدأ من جمع البيانات الخام إلى مرحلة الحصول على المعرفة الجديدة كما موضح بالشكل (١.٢) :

#### ١.٢.١.٢ اكتشاف البيانات (Data discovery ) :

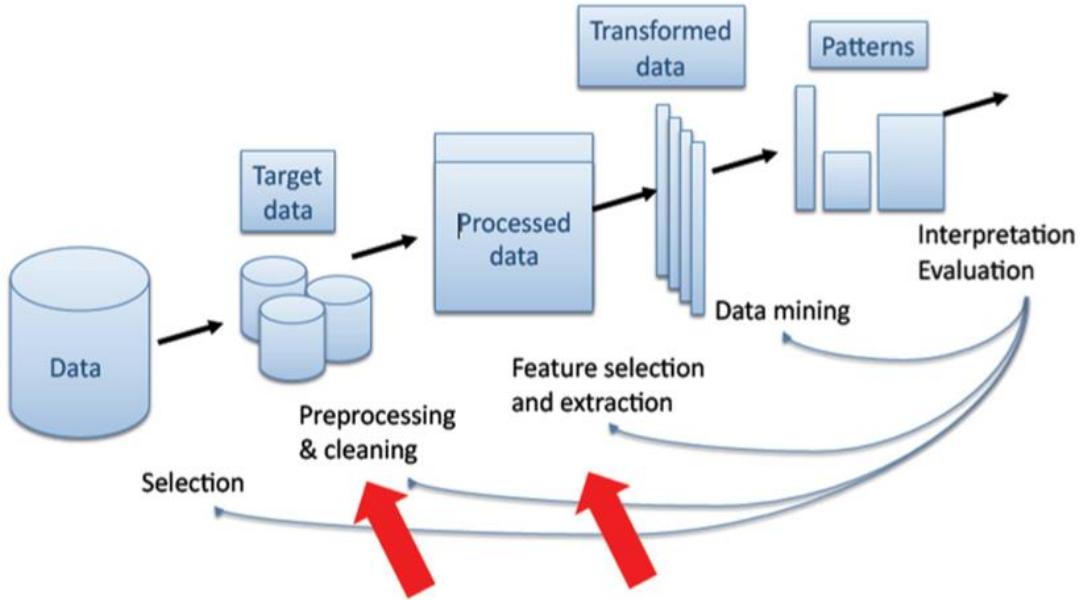
وهي مرحلة جمع البيانات وتشمل كشف وتحديد وتصنيف البيانات المتاحة.

#### ٢.٢.١.٢ تصفيّة البيانات (Data filtering) :

ويتم في هذه المرحلة إزالة البيانات التي لا أهمية لها، كما يتم حذف البيانات المتضاربة والبيانات الغير متناسقة.

#### ٣.٢.١.٢ تكامل البيانات (Data Integration) :

وتم في هذه المرحلة تجميع البيانات المتشابهة وذات الصلة من مصادر البيانات المتعددة ودمجها معاً.



شكل(1.2) خطوات اكتشاف المعرفة من قواعد البيانات

#### **٢.١.٤ اختيار البيانات : (Data selection)**

في هذه المرحلة، يتم تحديد واسترجاع البيانات الملائمة من مجموعة البيانات.

#### **٢.١.٥ تحويل البيانات : (Data Conversion)**

في هذه المرحلة يتم تحويل البيانات إلى نماذج مخصصة ملائمة لإجراءات البحث والاسترجاع بواسطة خلاصة الإنجاز أو عمليات التجميع.

#### **٢.١.٦ التنقيب عن البيانات : (Data mining)**

أي استخدام طرق ذكية تطبق لاستخلاص أنماط البيانات لاستخراج نماذج مفيدة قدر الإمكان.

#### **٢.١.٧ تقييم النمط : (Evaluate pattern)**

يتم في هذه المرحلة تحديد الأنماط المهمة حقا والتي تمثل قاعدة المعرفة لاستخدام بعض المقاييس المهمة.

## **٨.٢.١ تمثيل المعرفة وتقديمها**

### **:(Knowledge representation and submission)**

وهي المرحلة الأخيرة من مراحل اكتشاف المعرفة في قواعد البيانات وهي المرحلة التي يراها المستفيد، هذه المرحلة الأساسية تستخدم الأسلوب المرئي لمساعدة المستفيد في فهم و تفسير نتائج استخراج البيانات.

## **٩.١.٣ أهداف التنقيب**

هناك ثلاثة أهداف للتنقيب في البيانات:[1]

- ١ - من أجل تعليم بعض الظواهر المرئية.
- ٢ - من أجل التثبت من نظرية ما. مثل: التثبت من النظرية التي تقول بأن الأسر الكبيرة تهتم بالضمان الصحي أكثر من الأسر الصغيرة عدداً.
- ٣ - من أجل تحليل البيانات للحصول على علاقات جديدة وغير متوقعة .مثل: كيف سيكون الانفاق العام إن كان ملزماً لعمليات خداع واسعة من قبل البطاقات الائتمانية

## **٩.٤ أنواع التنقيب في البيانات**

يوجد نوعين من تنقيب البيانات وهما التنقيب التنبؤي والتنقيب الوصفي.

### **٩.٤.١ التنقيب التنبؤي**

يحاول إيجاد أفضل التنبؤات اعتماداً من المعطيات كمعرفة المنتج الأفضل لزيتون معين، باختصار يعتمد هذا التنقيب على استخدام معلومات قديمة لتوقع ما سيحدث في المستقبل وتكون لدى مثل هذه البيانات هدف.

### **٩.٤.٢ التنقيب الوصفي**

ينتج عنه معلومات جديدة بناء على المعلومات الموجودة داخل البيانات المستخدمة في عملية التنقيب.

## **٩.٥ مهام تنقيب البيانات**

يوجد العديد من مهام تنقيب البيانات ومنها:

## **١.٥.١ العنقة**

الهدف منها هو تحديد الاتجاهات داخل البيانات، ويحاول هذا الاسلوب العثور على مجموعات من العناصر التي توجد عادة معاً. وهي عملية تقسيم البيانات إلى مجموعه من الأصناف اعتماداً على اشتراكها بالخواص المتشابهة وأن العنقة هي تقسيم غير موجه للبيانات ، وهي عكس التصنيف ، كما أنها تساعد المستفيد على فهم التركيب الطبيعي للمجموعات من البيانات.

## **١.٥.٢ اكتشاف التسلسل**

في هذه الطريقة يتم البحث لاكتشاف نماذج تحدث بالتسلسل اذا تكون المدخلات عبارة عن بيانات تشكل مجموعة متسلسلة و تستخدم تقنيات التسلسل التحليل القائم على الوقت لانتزاع معلومات مفيدة ، وهي مماثلة للتجميع في انها تستخدم لتحديد العناصر التي تحدث معاً ، ولكن الاهم من ذلك انها تستخدم لتحديد أي من العناصر يحدث أولاً.

## **١.٥.٣ التصنيف**

يستخدم التصنيف بشكل واسع في حل كثير من المشكلات من خلال تحليل مجموعة من البيانات ووضعها في شكل أصناف أو أقسام يمكن استخدامها فيما بعد لتصنيف البيانات المستقبلية وهناك عدد من الطرق التي يمكن استخدامها في تصنيف البيانات باستخدام الخوارزميات مثل الخوارزمية الإحصائية، وخوارزميات الشبكات العصبية، والعديد من خوارزميات تعلم الآلة.

## **١.٥.٤ الانحدار**

يستخدم للعثور على دالة تمذج البيانات بأقل خطأ.

## **١.٥.٥ التلخيص**

يوفر عرضاً محكماً للبيانات يحتوي على التصور الكامل وتوليد التقرير

## **١.٥.٦ قاعدة الارتباط**

هي أحد التقنيات الواudedة من تنقية البيانات كاداه من أدوات اكتشاف المعرفة ولديها القدرة على تحليل كميات هائلة من البيانات، وهي تسمح بالتقاط كل القوانين الممكنة التي تشرح بعض الصفات الموجودة اعتماداً على وجود الصفات الأخرى، بمعنى آخر أنها قواعد ارتباطية معينة بين مجموعه من البيانات في قواعد البيانات.

## ١.٦.٥.١ قياسات قواعد الارتباط

تعتبر قاعدة الارتباط (Association Rule) [3] أحد أهم مجالات التقيب في البيانات فهي طريقة بحث جيدة وعامة لاكتشاف العلاقات الهامة بين المتحولات في قواعد البيانات الضخمة بإنتاج قواعد ارتباط لاكتشاف الانظام بين المنتجات في بيانات العمليات الكبيرة فإن قواعد الارتباط تستخدم في تطبيقات عديدة مثل التقيب في الويب ومجال المعلومات الحيوية (bioinformatics).

تعريف أساسى لمسألة التقيب عن قاعدة الارتباط حيث لتكن لدينا المجموعة  $I = \{i_1, i_2, i_3, i_4, \dots, i_n\}$  (items)

ولتكن لدينا مجموعة من العمليات (transactions) : والتي هي بمثابة قاعدة البيانات

$$D = \{t_1, t_2, \dots, t_m\}$$

حيث كل عملية ( $t_i$ ) من المجموعة ( $D$ ) لها اسم يميزها وتحوي مجموعة جزئية من المواد الموجودة في المجموعة ( $I$ ).

عندما القاعدة (Rule) تعرف بالصيغة:

$$x \Rightarrow y \text{ where } x, y \in I \text{ and } x \cap y = \emptyset$$

لتوضيح هذه المفاهيم نستخدم مثال صغير من السوق المركزي (supermarket) حيث مجموعة المواد  $I = \{ \text{milk}, \text{bread}, \text{butter}, \text{beer}, \text{cheese} \}$  هي

وقاعدة بيانات صغيرة تتضمن المواد (items) حيث:

[الرمز (١) موجود ، الرمز (٠) غائب عن الصفات (المادة غير موجودة)]

: { milk , bread }  $\Rightarrow$  { butter } مثلاً القاعدة في هذه الحالة هي

ذلك يعني أنه إذا تم شراء الحليب والخبز فإن الزبون أيضاً يشتري الزبدة، لذلك فإن مجموعات المواد (items) تعتبر هامة من الناحية الإحصائية ومجموعات البيانات (datasets) غالباً تحوي آلاف أو ملايين من مجموعات المواد ولاختيار القواعد الهامة من مجموعة القواعد المحتملة يوجد بعض القيود الهامة أفضل هذه القيود هي:

- الدعم (support) ومعامل الثقة (confidence).

• الدعم (support)

الدعم $(x)$  لمجموعة الموارد $(x)$  يدل على عدد مرات تكرار القاعدة في جميع المعاملات في قاعدة البيانات. ففي المثال لدينا : مجموعة الموارد $\{ \text{milk}, \text{bread} \}$  item set =

$$\text{supp}(x) = (x \cup y) / n$$

حيث $n$ =المجموع الكلي للمعاملات.

$$\text{SUPPORT} = 2/4 = 0.5$$

أي يمكن أن تحدث بمقدار 50%

لكل عملية (transactions).

## • معامل الثقة (confidence)

معامل الثقة لقاعدة (confidence) يعرف بالعلاقة:

$$\text{Conf}\{ x \Rightarrow y \} = \text{SUPP}(X \cup Y) / \text{SUPP}(X)$$

ففي مثالنا السابق مدى: confidence {milk , bread }  $\Rightarrow$  {butte }

عند ظهور {milk , bread , butter } مره واحدة في قاعدة البيانات

$$\text{Confidence} = 1/2 = 0.5$$

ومن خوارزميات قواعد الارتباط خوارزمية (Apriori) وفيما يلي سنتحدث عنها بالتفصيل:

## ٢.٦.١.٢ خوارزمية (Apriori)

هي خوارزمية للتنقيب عن العناصر المتكررة وتطبيق قوانين الارتباط على (transactional databases) وتعمل عن طريق تحديد العناصر الفردية المتكررة في قاعدة البيانات وتوسيعها لتشمل مجموعات اكبر. واكبر عنصر هو العنصر الاكثر ظهورا في قاعدة البيانات ومجموعات العنصر المتكررة يتم تحديدها عن طريق خوارزمية (Aproiri)[4] التي تستخدم لتحديد قوانين الارتباط، هذه الخوارزمية مصممة للعمل على قواعد البيانات التي تحتوي على (transactions) وتم تصميم الخوارزميات الاخرى لايجاد قوانين الارتباط في حالة عدم وجود (transactions) أو عدم وجود (item set) (timestamp) وينظر إلى كل (Transaction) على أنها مجموعة من الوحدات (item set)،

تستخدم الخوارزمية منهج "bottom up" حيث يتم تمديد مجموعات فرعية للعنصر الواحد في اللحظة المعينة وهي خطوة تولد الفلترة (candidate generation) ويتم اختبار هذه المجموعات المرشحة. وتنتهي هذه الخوارزمية عندما لا يتم العثور على أي تمديدات أخرى ناجحة.

```

Apriori( $T, \epsilon$ )
 $L_1 \leftarrow \{\text{large 1 - itemsets}\}$ 
 $k \leftarrow 2$ 
while  $L_{k-1} \neq \emptyset$ 
     $C_k \leftarrow \{a \cup \{b\} \mid a \in L_{k-1} \wedge b \notin a\} - \{c \mid \{s \mid s \subseteq c \wedge |s| = k-1\} \not\subseteq L_{k-1}\}$ 
    for transactions  $t \in T$ 
         $C_t \leftarrow \{c \mid c \in C_k \wedge c \subseteq t\}$ 
        for candidates  $c \in C_t$ 
             $count[c] \leftarrow count[c] + 1$ 
         $L_k \leftarrow \{c \mid c \in C_k \wedge count[c] \geq \epsilon\}$ 
         $k \leftarrow k + 1$ 
    return  $\bigcup_k L_k$ 

```

:Apriori توضيح رموز خوارزمية

. Transaction=(T) .١

. support=( $\epsilon$ ) .٢

.  $L_k$  = المجموعة المرشحة في المستوى .٣

.  $C_k$  = حقل هيكلة البيانات التي تمثل المجموعات المرشحة  $c$  ، الذي من المفترض أن

تكون قيمة الإبتدائية تساوي صفرًا.

.  $L$  = أكبر بند (Large item set) .٤

تعمل خوارزمية Apriori (أپریوری) بإيجاد مجموعات العناصر المتكررة (العناصر التي ظهرت في قاعدة البيانات والتي أكبر من أو يساوي الحد الأدنى من حد الدعم)، وتولد مرشح من عناصر متكررة، ومن ثم تهذيب النتائج للعثور على مجموعات العنصر المتكررة. وتوليد قواعد ارتباط قوية من مجموعات العنصر المتكررة

## ٦.١.٢ وسائل التقيب في البيانات

هناك عدة وسائل مختلفة من أجل التقيب في البيانات. اختيار الوسيلة المناسبة يعتمد على طبيعة البيانات تحت الدراسة وعلى حجمها. يمكن إجراء عملية التقيب في البيانات بالمقارنة مع سوق البيانات ومخزن البيانات. بعض من هذه الوسائل هي: (كل وسيلة يتبعها وظيفة).

## **١.٦.١.٢ الاستدلال المبني على الحالات**

**الاستدلال المبني على الحالات ( Case-Based reasoning )** التفكير واستخلاص النتائج والقوانين من أمثلة حية وقضايا تم حلها سابقاً.

## **١.٦.١.٣ الكشف عن قانون ( Rule Discovery )**

البحث عن منوال معين أو علاقة معينة في جزئية كبيرة من البيانات.

## **٢.١.٦.١.٢ معالجة الإشارات ( Signal Processing )**

ايجاد الظواهر المتشابه مع بعضها البعض.

## **٣.١.٦.١.٢ شبكات عصبية ( Neural Net )**

وهي نماذج قابلة لتنبؤ النتائج، تم تصويرها على أساس الاستنباط من عقل الإنسان.

## **٤.١.٦.١.٢ منحنيات غير ثابتة ( Fractals )**

تصغير البيانات الكبيرة من دون ضياع المعلومات.

# **الفصل الثاني**

## **نظم التوصية**

## ٢.٢ مقدمة

قدرة أجهزة الكمبيوتر لتقديم التوصيات في تاريخ الحوسبة كانت في وقت مبكر، هذه الحواسيب تستند على (librarian)، وهي خطوة مبكرة نحو نظام المذكي الآلي (automatic system). وكان بدائي إلى حد ما، ولكنه قدم إدخال مبكر هام في فضاء التوصيات (recommender).

## ٢.٢ تاريخ نظم التوصية (System)

في أوائل ١٩٩٠، بدأت الفلترة التعاونية (collaborative filtering) [5] للتعامل مع المعلومات الزائدة في أماكن المعلومات على الإنترنت. كان نظام الفلترة التعاونية اليدوي يسمح للمستخدم بالاستعلام عن العناصر الموجودة في مجال المعلومات، مثل البريد الإلكتروني للشركات، على أساس آراء المستخدمين الآخرين أو الإجراءات وهي لا تتطلب جهداً من جانب مستخدميها، وأيضاً سمح لهم بالاستفادة من ردود فعل القراء السابقة لتحديد أهميتها بالنسبة لهم.

وسرعان ما تبع نظم الفلترة التعاونية الآلية (Automated collaborative filtering systems) تحديد الآراء ذات الصلة أو توماتيكياً وتجميعها لتقديم التوصيات وتنستخدم هذه التقنية لتحديد المواد من الأعضاء التي من المحتمل أن تكون مثيرة للإهتمام لمستخدم معين، يحتاج المستخدمين فقط إلى توفير تقييمات أو تنفيذ إجراءات أخرى يمكن ملاحظتها؛ النظام يجمع بين هذه الآراء مع هذا التقييم أو تصرفات المستخدمين الآخرين لتقديم نتائج ذات طابع شخصي. مع هذه الأنظمة لا يحتاج المستخدمون الحصول على أي معرفة مباشرة لأراء المستخدمين الآخرين، كما أنها لا تحتاج إلى معرفة مستخدمين أو غيرهم من البنود في النظام من أجل الحصول على التوصيات.

خلال هذا الوقت نظم التوصية والفلترة المتعاونة أصبحا موضوعاً مثيراً للإهتمام المتزايد بين تفاعل الإنسان والحواسوب، والتعلم الآلي، وإسترجاع المعلومات للباحثين، وأنتج هذا الإهتمام عدداً من نظم التوصية لمختلف المجالات، مثل (Ringo) للموسيقى، (Core Video Recommender the Bell) للأفلام، والأدب و التسويق وتحليل التوصية للقدرة على زيادة المبيعات.

في أواخر ١٩٩٠، التطورات التجارية من تقنيات التوصية بدأت في الظهور. ربما كان التطبيق الأكثر شهرة على نطاق واسع من تقنيات نظم التوصية هي الأمازون (Amazon.Com)، وهذا البند للمستخدم هو يشاهد حالياً، فإنه يوصي البنود المستخدم للنظرية الشرائية.

نظم التوصية غيرت طريقة الناس في العثور على المنتجات والمعلومات. بدراسة أنماط السلوك لمعرفة ما يفضله شخص ما من بين مجموعة من الأشياء التي لم يجربيها. تطورت التقنية الكامنة وراء أنظمة التوصية على مدى السنوات العشرين إلى مجموعة غنية من الأدوات التي تمكن الباحث لتطوير توصية فعالة.

## ٣.٢.٢ نظم التوصية

نظم التوصية (Recommender system) تمكن الناس من تبادل الآراء والإستفادة من خبرات بعضهم البعض ويمكن تعريفها بأنها أي نظام ينتج توصيات فردية كناتج له أوله تأثير على توجيه المستخدم بطريقة مخصصة لأشياء تثير إهتمامه أو أشياء مفيدة في مساحة واسعة من الخيارات المتاحة.

تم تطوير نظم التوصية في البداية لدعم مستخدمي الإنترنت في عملية صنع القرار في موافق الحياة اليومية فيما يتعلق بإختيارهم للمعلومة التي قد تكون ذات فائدة لهم عندما يواجهون أوضاع ليس لهم فيها خبرة كافية في البدائل المتاحة.

## ٤.٢.٤ أنواع نظم التوصية

و من أنواع نظم التوصية ذكر منها مابلي:

### ٤.٢.١ الفلترة التعاونية (collaborative filtering)

هي توصيات تقوم على نموذج لسلوك مستخدم مسبق. نموذج يمكن بناؤه فقط من سلوك مستخدم واحد أو - على نحو أكثر فعالية - أيضاً من سلوك المستخدمين الآخرين الذين لديهم صفات مماثلة. عندما يأخذ سلوك المستخدمين الآخرين في الإعتبار، الفلترة التعاونية تستخدم معرفة المجموعة (group knowledge) لتشكيل التوصيات على أساس تشابه المستخدمين. وتعتمد التوصيات على التعاون التلقائي لعدد من المستخدمين والمرشحين (automatic collaboration of multiple users and filtered على أولئك الذين يظهرون تفضيلات أو سلوكيات مماثلة).

حق نمو شبكة الإنترنت صعوبة أكثر لاستخراج المعلومات المفيدة من جميع المعلومات المتاحة على الإنترنت بشكل فعال. الكم الهائل من البيانات يتطلب آليات فعالة لتصفيّة المعلومات. ويطلق على كل واحدة من التقنيات المستخدمة للتعامل مع هذه المشكلة الفلترة التعاونية (collaborative filtering). ودافع الفلترة التعاونية يأتي من فكرة أن الناس في كثير من الأحيان يحصلون على أفضل التوصيات من أشخاص مع أذواق مماثلة لأذواقهم، والفلترة التعاونية يستكشف التقنيات لمطابقة الناس

مع مصالح مماثلة وتقديم توصيات على هذا الأساس. غالباً ما تحقق خوارزميات الفلترة التعاونية المشاركة الفعالة وطريقة سهلة لتمثيل مصالح المستخدمين على النظام.

الخوارزميات التي تكون قادرة على تطابق المستخدمين مع مصالح مماثلة، وواحدة من طرق نظم التوصية هي خوارزمية الجار الأقرب.

## خوارزمية الجار الأقرب (K-Nearest Neighbor)

طريقة الجار الأقرب (K-NN) تعتبر من تقنيات التقريب في البيانات التي تهدف للتنبؤ عن طريق مقارنة العناصر الشبيهة بالعنصر المراد التنبؤ به وتقدير القيمة المجهولة لهذا العنصر بناءً على معلومات لتلك العناصر. وهي تقنية تنبؤية مناسبة لنماذج التصنيف، تصنف كائن من خلال تصويت الأغلبية من جيرانها، مع الكائن الذي يتم تعينه إلى الطبقة الأكثر شيوعاً بينها كأقرب جيرانها، إذ تمثل  $k$  عدد الحالات المشابهة، وتعد معطيات التدريب في طريقة الجار الأقرب هي النموذج فلا يتم بناؤه عندما يتم تقديم حالة جديدة للبرنامج، تبحث الخوارزمية في المعطيات كلها لإيجاد علاقة جزئية من الحالات التي هي أكثر تشابهاً بها، وتستخدمها لتوقع الخرج.

محددات خوارزمية الجار الأقرب

١. عدد الحالات الأقرب ليتم استخدامها ( $k$ ).

٢. وحدة قياس التشابه.

يتطلب كل إستخدام لخوارزمية الجار الأقرب أن يتم تحديد قيمة موجبة لـ  $k$ ، وهذا يحدد عدد الحالات الموجودة التي يتم البحث عنها عند تحديد حالة جديدة لخوارزمية.

### ١.٤.٢.٢ أنواع الفلترة التعاونية

الفلترة التعاونية [6] لديها ثلاثة أنواع هي:-

#### • القائم على الذاكرة (Based on memory)

يستخدم هذا النهج بيانات تقييم المستخدم لحساب التشابه بين المستخدمين أو العناصر، ويستخدم لتقديم التوصيات. كان هذا النهج في وقت مبكر يستخدم في كثير من النظم التجارية وهو فعال وسهل التنفيذ. أمثلة نموذجية لهذا النهج هي (item-based/user-based CF) و (neighborhood-based CF) و (.top-N

ومن مزايا هذا النهج توضيح النتائج وهو جانب هام من جوانب نظم التوصية؛ إنشاء سهولة الإستخدام؛ تيسير البيانات الجديدة بسهولة؛ إستقلال المحتوى من العناصر التي يوصى بها وتوسيع نطاق جيد مع تصنيف العناصر المشتركة.

هناك أيضا العديد من العيوب مع هذا النهج. ينخفض أدائها عندما يحصل على البيانات المترفرقة، والذي يحدث في كثير من الأحيان مع العناصر ذات الصلة على شبكة الإنترنت، وهذا يعيق قابلية هذا النهج ويخلق مشاكل مع مجموعات البيانات الكبيرة. على الرغم من أنه يمكن التعامل مع المستخدمين الجدد بكفاءة لأنها تعتمد على بنية البيانات فإن بإضافة عناصر جديدة يصبح أكثر تعقيداً، وإضافة عناصر جديدة يتطلب إدراج جديد وإعادة الإدراج لجميع العناصر في البنية.

## • القائم على النموذج (model Based on)

يتم فيه وضع نماذج باستخدام التقريب عن البيانات، باستخدام خوارزميات تعلم الآلة لإيجاد أنماط تستند إلى بيانات التدريب. وتستخدم هذه لجعل التوقعات للبيانات حقيقة. وتستند معظم النماذج على خلق أسلوب تصنيف أو تجميع لتعريف المستخدم استناداً إلى مجموعة الاختبار. هناك العديد من المزايا مع هذا النموذج يتعامل بها مع تبعثر أفضل من القائم على الذاكرة. وهذا يساعد على تطويره مع مجموعات كبيرة من البيانات، وهو يحسن أداء التنبؤ، إذ أنه يعطي المبرر بدليلاً للتوصيات.

## • المختلط (Hybrid)

يجمع بين القائم على الذاكرة والقائم على النموذج، وهو يحسن أداء التنبؤ، الأهم من ذلك أنه يتغلب على مشاكل (CF) مثل تبعثر وفقدان المعلومات. ومع ذلك، فإنه زاد من التعقيد وتكلفة التنفيذ. عادة معظم نظم التوصية التجارية هي مختلطة مثل، (Google news recommender system).

# ٢.٤.٢.٢ تحديات الفلترة التعاونية

يوجد العديد من التحديات التي واجهت الفلترة التعاونية [6] منها:

## ○ تبعثر البيانات (Scattering Data)

في الممارسة العملية، تقوم العديد من نظم التوصية التجارية على مجموعات البيانات الكبيرة، وهي كبيرة للغاية ومتفرقة، وهذا الذي يجلب التحديات في أداء هذه التوصية. ويوجد مشكلة واحدة نموذجية ناجمة عن تبعثر البيانات هي مشكلة (cold start) (الأنظمة التي توجد بها cold start غالباً ما تتطلب كمية كبيرة من البيانات للمستخدم من أجل تقديم توصيات دقيقة).

## ○ قابلية التوسيع (Scalability)

أن أعداد المستخدمين و البنود تنمو بسرعة كبيرة، وخوارزميات (CF) التقليدية تعاني من مشاكل (Scalability) الخطيرة وكذلك تحتاج العديد من الأنظمة للرد على الفور لمتطلبات الإنترن特 وتقدم توصيات لجميع المستخدمين بغض النظر عن مشترياتهم ودرجات التقييم، والتي تتطلب قابلية أعلى من نظام (CF).

## ○ المرادفات (Synonyms)

المرادفات تشير إلى اتجاه عدد من البنود ذاتها أو مماثله لها التي لها أسماء أو إدخالات مختلفة. على سبيل المثال، على ما يبدو عناصر مختلفة "فيلم الأطفال" و "سينما الأطفال" يحيط في الواقع إلى نفس البند، ودرجة التباين في استخدام مصطلح وصفي أكبر مما كان يعتقد عادة. وانتشار المرادفات يقلل من أداء أنظمة التوصية (CF). وبأسلوب النمذجة (مثل تقنية Dirichlet Allocation) يمكن حل ذلك عن طريق تجميع كلمات مختلفة تنتهي إلى نفس الموضوع.

## ○ اعتداءات (SHILLING)

في نظام التوصية حيث يمكن لأي شخص أن يعطي تقييمات، والناس قد تعطي الكثير من التصنيفات الإيجابية للعناصر الخاصة بهم ودرجات تقييم سلبية على منافسيهم. فمن الضروري في كثير من الأحيان لأنظمة (CF) تقديم الاحتياطات للحد من هذا النوع من التلاعب.

## ٤.٢.١ فلترة على المحتوى (Content-based filtering)

الفلترة على المحتوى [7] (Content-based filtering) يشار لها أيضاً بالتصفيه المعرفية (cognitive filtering)، وتوصي بالعناصر بناءً على مقارنة بين محتوى العناصر وملف تعريف المستخدم. ويمثل محتوى كل عنصر أنه مجموعة من أوصاف أو مصطلحات. وملف تعريف المستخدم يمثل بنفس الشروط ويتم بناؤه من خلال تحليل محتوى العناصر التي قد يراها المستخدم.

مصدر المعلومات الذي يستخدم أنظمة الفلترة على المحتوى في الغالب مع (Text documents) وثائق النصونهج موحد لتحليل المدى الذي يتم فيه اختيار عبارة واحدة من الوثائق.

نموذج ناقلات الفضاء (latent semantic indexing) (The vector space) وفهرسة الدلالات الكامنة (latent semantic indexing) (indexing) الطريقةان اللتان تستخدمان لتمثيل الوثائق.

## ٤.٢.١ نظم التوصية المختلطة (Hybrid Recommender System)

وقد أثبتت الأبحاث الحديثة أن إتباع النهج المختلط [7] يجمع بين الفلترة التعاونية والفلترة على المحتوى ويمكن أن يكون أكثر فعالية في بعض الحالات. ويمكن تنفيذ النهج المختلط بعدة طرق: عن طريق جعل تنبؤات الفلترة على المحتوى والفلترة التعاونية كلٍ على حدة ومن ثم الجمع بينهما؛ بالإضافة قدرات على الفلترة على المحتوى للنهج القائم على الفلترة التعاونية (والعكس بالعكس)، أو عن طريق توحيد النهج في نموذج واحد.

مثال جيد على الأنظمة المختلطة هو (Netflix)، يعطي التوصيات بمقارنة و مراقبة وتفتيش عادات المستخدمين المماثلة (أي CF)، وكذلك من خلال تقديم العناصر التي تشتراك مع خصائص العناصر التي قام مستخدم بها بدرجات عالية (content-based filtering).

يستخدم نظام (hybrid recommender) لوصف أي نظام توصية يجمع بين تقنيات توصية متعددة معاً لإنتاج المخرجات الخاص به. لا يوجد أي سبب يمكن أن يمنع (hybrid) أن يعمل بعدة تقنيات مختلفة من نفس النوع، على سبيل المثال، يمكن لإثنين من أنواع الفلترة على المحتوى المختلفة أن تعمل معاً، وحققت عدداً من مشاريع هذا النوع (hybrid) News Dude (News Dude)، والذي يستخدم كلاً naive ومصنفات (KNN) (Bays) في توصيات أخبارها.

## **الفصل الثالث**

**أدوات تنقية البيانات**

## ٢.٣.١ مقدمة

تطوير وتطبيق خوارزميات التنقيب عن البيانات يتطلب استخدام أدوات برمجية قوية. كما لا يزال عدد من الأدوات المتاحة تزايـد في النمو، مما يصبح اختيار الأداة الأكثر ملائمة من أكثر الأمور صعوبة، وفيما يلي سنتطرق لعدد من أدوات تنقيب البيانات.

## ٢.٣.٢ Rattle

هي البرمجيات الحرة والمفتوحة المصدر وحزمة ت توفير واجهة المستخدم الرسومية (GUI) لإستخراج البيانات بإستخدام لغة البرمجة الإحصائية R. يستخدم (Rattle)[8] في مجموعة متنوعة من الحالات. يقدم (Rattle) ملخصات إحصائية ومرئية من البيانات مع (2D) و (3D)، ويوفر وظائف كبيرة لإستخراج البيانات من خلال تعريض قوة البرنامج الإحصائي R خلال واجهة المستخدم الرسومية. كما يستخدم كمنشأة تعليمية لتعلم لغة البرمجة R.

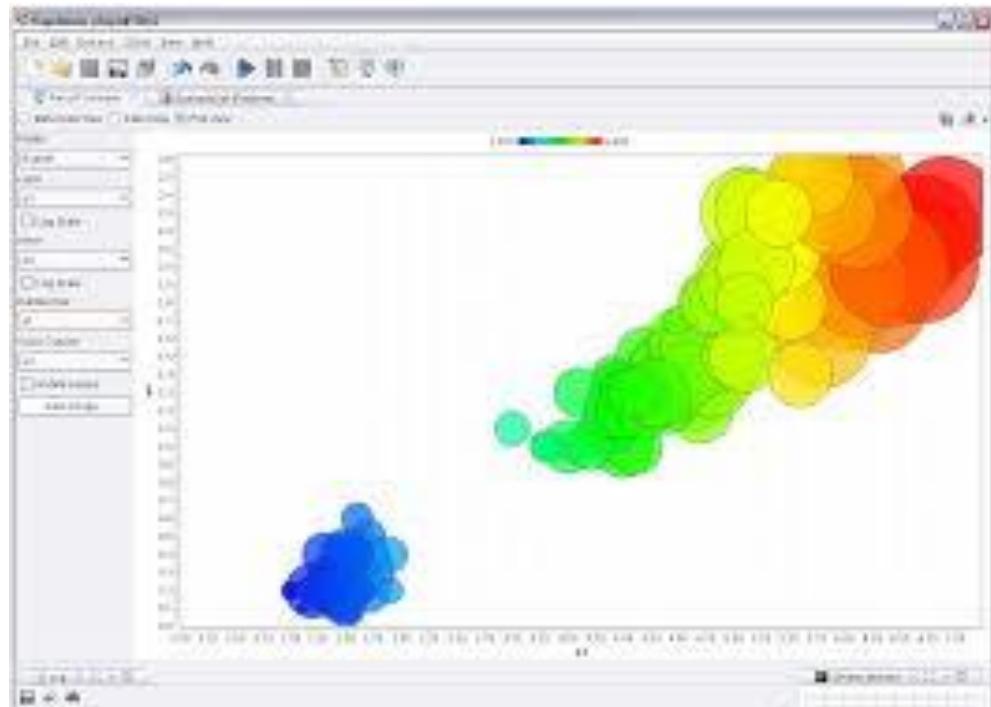
يتحول البيانات التي يمكن أن تكون منمندة(model) بسهولة، في التمودجين(supervised) و(unsupervised)، أما الغير خاضع للرقابة (unsupervised) يستخدم طريقة التحليل العنقودي أو قواعد الارتباط، والخاصع للرقابة (supervised) يستخدم لتوقع الأنماط المستقبلية للسلوك من البيانات، ويقدم أداء النماذج بالرسوم والصور، ونتائج مجموعات البيانات الجديدة. ويمكن استخدامه لأغراض التحليل الإحصائي، أو توليد نموذج. ويسمح لمجموعة البيانات أن تقسم في التدريب، والتحقق والإختبار.



شكل(٢.٢)واجهة ال Rattle

## Rapid Miner ٣.٣.٢

بالإضافة إلى استخراج البيانات يوفر [9] (Rapid Miner) وظائف مثل تجهيز البيانات والتصور، والتحليلات التنبؤية والنماذج الإحصائية والتقييم والنشر. مما يجعلها أكثر قوة هو أنه يوفر التعلم بالمخططات والنماذج والخوارزميات من البرامج النصية.



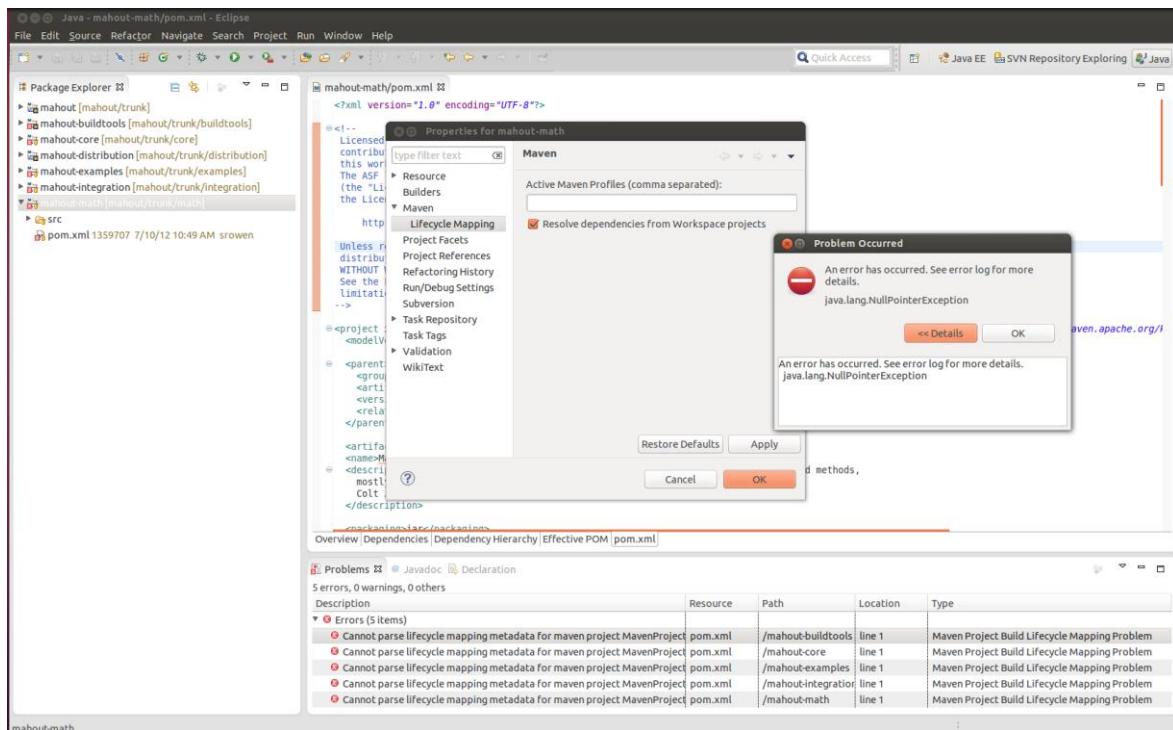
شكل (٣.٢) واجهة Rapid Miner

## Apache Mahout ٤.٣.٢

يقدم (Apache Mahout) [10] بيئة الرياضيات الجديدة التي تسمى (Samsara). شعاره التجديد الشامل، وهو يعكس إعادة التفكير بشكل أساسي . والقابلية لبناء خوارزميات تعلم الآلة حسب الطلب. وهو يساعد الناس على خلق رياضيات خاصة مع توفير بعض حالات التنفيذ الجاهزة للخوارزمية.

آلة تعلم مفتوحة المصدر، يلتفت الخوارزميات الأساسية لنظم التوصية، والتصنيف، والمجموعات في المكتبات الجاهزة القابلة للاستخدام، وهو يدعم تنقيب التوصيات (recommendation mining)، ومع (Mahout) يمكن أن يطبق تطبيق مباشر إلى المشاريع الخاصة بتقنيات التعلم الآلي التي توجه الأمازون، ونتفليكس، وغيرها. في جوهرها هي الجبر الخطى العام والعمليات الإحصائية إلى جانب هيكل البيانات لتقديم الدعم لهم، وجعل النماذج أو مهمة التقديم أسهل بكثير وسمح للمستخدمين تخصيص

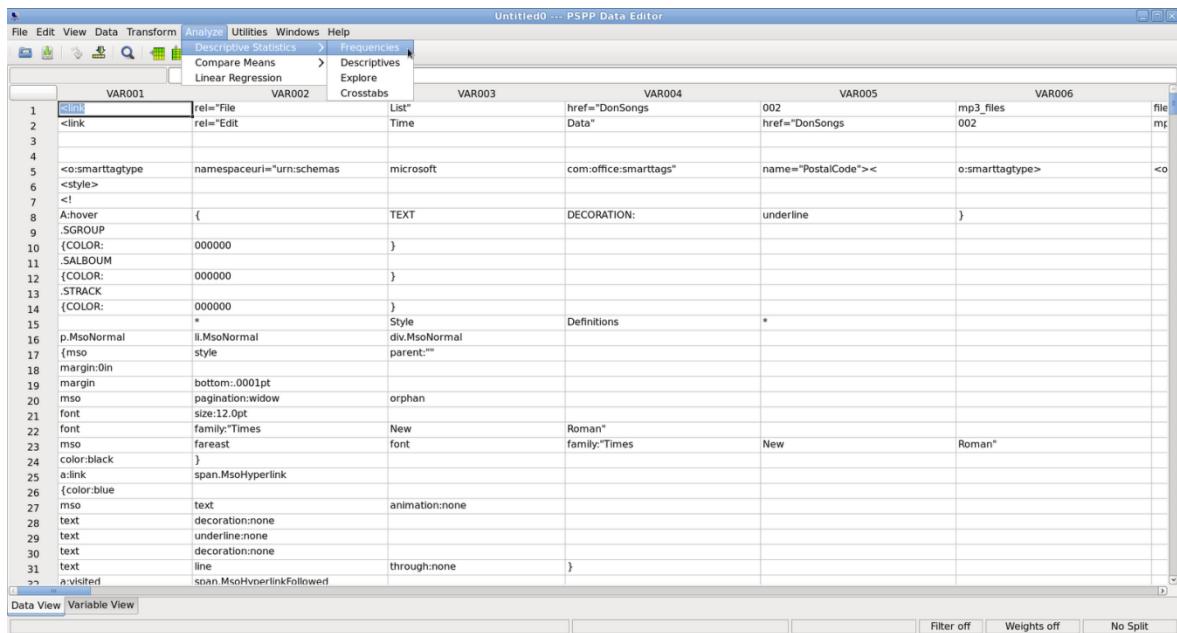
**الخوارزميات مع درجة جديدة كاملة من الحرية. تشمل خوارزميات (Mahout) العديد من التطبيقات الجديدة التي بنيت للسرعة، والسرعة فيه زادت بمقدار ١٠ أضعاف عن الخوارزميات التي سبقتها**



شكل (٤). واجهة Apatch Mahout

## PSPP ٥.٣.٢

PSPP هو برنامج للتحليل الإحصائي لبيانات العينة. أنه يحتوي على واجهة المستخدم الرسومية التقليدية. مكتوب في C، ويستخدم (plotutils) لتوليد الرسوم البيانية. وهو بديل مجاني لبرنامج الملكية SPSS (من IBM)، ويتبني بثقة لما سيحدث ثم بعد ذلك يمكنك من إتخاذ قرارات أكثر ذكاءً، و يقدم حلًا للمشاكل وتحسين النتائج [11].

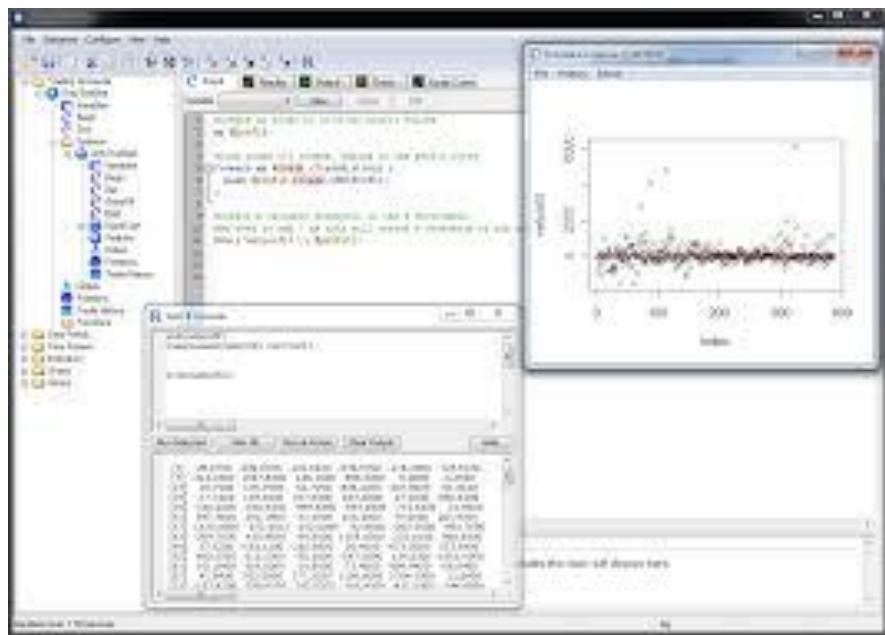


شكل(٥.٢)واجهة Pspp

## R ٦.٣.٢

هي لغة وبيئة الحوسبة الإحصائية والرسوم البيانية، يتم استخدام لغة [12] R على نطاق واسع بين تعدين البيانات لتطوير البرامج الإحصائية وتحليل البيانات، وأثار سهولة الإستخدام والتعدد. يوفر R مجموعة واسعة من الإحصائية (النمذجة الخطية وغير الخطية ، والإختبارات الإحصائية الكلاسيكية، وتحليل السلاسل الزمنية، والتصنيف، والتجميع، ...) والتقنيات الرسومية.

واحدة من نقاط قوة R هي السهولة التي يمكن أن تنتج تصميمًا جيداً ، بما في ذلك الرموز الرياضية والصيغ. وقد تم الحرص الشديد على الإعدادات الإفتراضية لخيارات التصميم الثانية في الرسومات، ولكن يحتفظ المستخدم بالسيطرة الكاملة.



شكل (٦.٢) واجهة R

## Weka ٦.٢

هو عبارة عن برنامج خاص بخوارزميات التقيب عن البيانات وتعلم الآلة[13]. كما يحتوي هذا البرنامج على أدوات قادرة على التعامل مع الأمور التالية :

(pre-processing) ،(classification) ،(clustering) ،(association rules) ،(visualization) .  
و يمكن استخدامه من خلال الواجهة الرسومية للتفاعل مع ملفات البيانات وتحقيق نتائج بصرية، وهو يعمل تحت عدة بيئات (جنو\لينوكس، ويندوز، ماك). ليعمل الملف يجب أن يكون في صيغ معينة ومن هذه الصيغ صيغة (arff).

## ١.٧.٣.٢ ملف (ARFF)

لتحويل الملف إلى الصيغة (arff) يجب حفظ ملف (csv) أو (excel) إلى الصيغة (Arff) هي صيغ تكون في شكل صفوف يتم فيها توضيح السمات الأساسية لملف أعلى التعليقات وهي يجب أن تكون مسبوقة بالعلامة @ ويمكن أن تحتوي السمات على فراغات،السمات الإسمية تكون (string) والرقمية (numeric).

مثال لصيغ ملف (arff) للمواد

```
@attribute security numeric
@attribute os numeric
@attribute ai numeric
```

```

@attribute hci numeric
@attribute physics1 numeric
@attribute hardware numeric
@attribute math1 numeric
@attribute Entrance PC

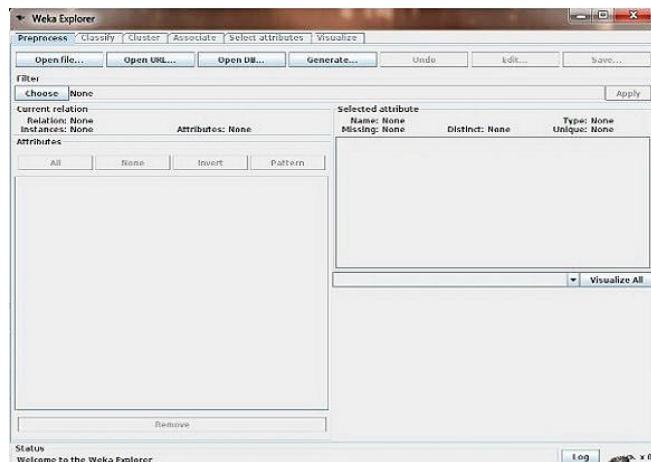
```

## ٢.٧.٣.٢ تحميل البيانات في weka



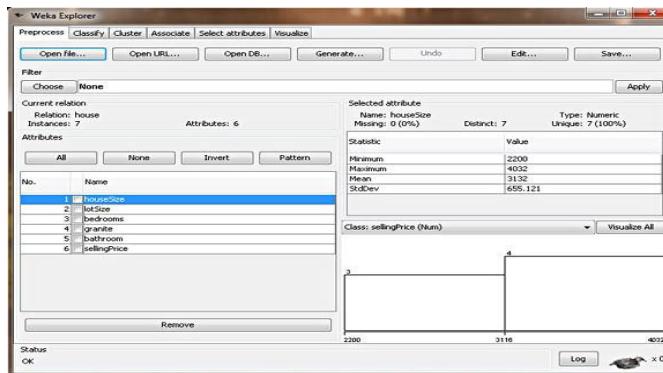
الشكل (٢) شاشة بدء تشغيل WEKA

عند بدء تشغيل Weka تظهر في البداً واجهة الإختيار الرسومية تتيح لك إختيار أربع طرق للعمل مع Weka والبيانات الخاصة بك، وسوف نختار خيار واحد والختار(explorer) أكثر من كافي لكل ما نحتاج للقيام به في هذه البيانات. وعند إختيار إكسپلورر تفتح شاشة المستكشف الرسومية والشكل يوضح شاشة المستخدم قبل بدء الإختيار.



الشكل (٨.٢) شاشة المستكشف الرسومية قبل الإختيار

لتحميل البيانات إلى WEKA، يجب وضعها في الشكل الذي سوف يكون مفهوماً الأسلوب المفضل لتحميل البيانات أن يكون الملف (ARFF)، في البدء اختيار (open) لإختيار الملف ذو الإمتداد (ARFF) الذي من خلاله يمكن أن تختار الملف الذي تريد تحميله. ثم اختيار (apply) بعد تحديد نوع البيانات التي يتم تحميلها من الخيار (choose) لعمل الخوارزمية. الشكل يوضح weka بعد إختيار البيانات.



الشكل (٩.٢) شاشة المستكشف الرسومية بعد الإختيار

# **البَابُ الثَّالِثُ**

**الدراسات السابقة**

## **٣.١ مقدمة**

أثبتت نظم التوصية النجاح في العديد من المجالات التي توجد فيها مشكلة الحمل الزائد من المعلومات (information overload). وعلى الرغم من أن أنظمة التوصية التعليمية (Recommendation educational systems) تشتراك في نفس الأهداف الرئيسية مع التوصية لتطبيقات التجارة الإلكترونية، هنالك بعض الخصائص التي ينبغي النظر فيها قبل تطبيق الحلول الحالية مباشرة من تلك التطبيقات. على سبيل المثال، لا ينبغي أن تسترشد التوصيات في المجال التعليمي فقط من خلال تفضيلات المتعلمين ولكن أيضاً من خلال المعايير التعليمية [14].

## **٣.٢ دراسة عن تطبيق التوصية المختلطة في التعليم الإلكتروني**

### **E-Learning personalization Based On Hybrid Recommendation Strategy And Learning Style Identification:**

من المهم جداً توفير نظام مخصص يمكنه أن يتكيف تلقائياً مع أساليب التعلم للمتعلمين ومستويات معرفتهم وذكاءهم، يوصي بالأنشطة عبر الإنترنت أو المواد التي يفضلونها ويحسن التعلم. في سياق التعليم اعتبر الباحثين [15] أن المتعلمين يمكن أن يكون لديهم إحتياجات فردية مختلفة وخصائص مختلفة مثل مستويات مختلفة من الخبرة والمعرفة السابقة، والقدرات المعرفية، وأساليب التعلم، والتحفيز، وأنهم يريدون تحقيق اختصاص معين في وقت معين. وبالتالي، فإنه لا يمكن أن يعاملوا بطريقة موحدة، يسمى علماء النفس هذه الفروق المختلفة بأنماط التعلم.

تم تقديم نظام توصية ذكي للتكيف على شبكة الإنترنت وهو بروتوكول (نظام برمجة الدروس الخصوصية) لمساعدة المتعلمين في تعلم أساسيات لغات البرمجة. والذي يمكنه التكيف تلقائياً مع مصالح ومستويات المعرفة للمتعلمين، ويأخذ بعين الاعتبار الجوانب التربوية للمتعلم وضرورة أن يوصي بسلسل من أنشطة التعلم بترتيب فعال تربوياً.

من أجل التحقيق في أنشطة التعلم بالتفصيل، اعتمدت خوارزمية تقييم أنماط متتابعة (Apriori All) (Tong & Pi-Lian, 2005) لاستخراج الأنماط (التفاعل) السلوكية من ملف السجل. وهذه الأنماط تكون مفيدة لتحليل كيفية تطور المتعلمين من بداية تعلم وحدة معينة. المتعلمين الذين لديهم أساليب تعلم مختلفة لديهم مجموعات مختلفة من سلسل مختلفة. وبالتالي، تم تجميع المتعلمين في مجموعات على أساس أساليب التعلم الخاصة بهم ثم تم إكتشاف الأنماط السلوكية لكل متعلم بواسطة

خوارزمية (Apriori All). أما مهمة نظام التصفية التعاونية هي التنبؤ بتقييم إستفادة متعلم معين مقارنة بمتعلم مماثل.

استخدمو واحدة من أدوات جمع البيانات تسمى مؤشر أساليب التعلم (ILS) و (Felder) Solomon ، ILS هو سؤال ٤، وهو متاح مجاناً، وسيلة اختيار عدة أساليب و الذي يقيم الإختلافات الفردية في تفضيلات أسلوب التعلم.

قبل مرحلة معالجة البيانات لبناء نموذج المتعلم، يتم جمع البيانات حول النشاطات (مثل الأنماط التتابعية، الصفحات التي زارها، نتائج الاختبارات، والدرجات التي تحصل عليها). صفحات تسجيل المتعلمين. الجزء النظري للدورة والدروس. الأمثلة والاختبارات من معالجة البيانات المدخلة.

نفذوا بعض التجارب على مجموعة البيانات التعليمية. اختاروا ٤٠ من المتعلمين، في مرحلة التخرج من قسم تكنولوجيا المعلومات في المدرسة العليا للدراسات الأعمالي الفنية، Sad Novi University. المتعلمين المشاركون يضمون مبرمجين مبتدئين إجتازوا بنجاح الدورة الأساسية لمحو الأمية المعلوماتية في الفصل الدراسي السابق. وتم تقسيمهم إلى مجموعتين: المجموعة التجريبية والمجموعة السيطرة.

المتعلمين من المجموعة السيطرة عملت بطريقة طبيعية ولم تلق أي توصية أو توجيه من خلال مسارها التعليمي، في حين أنه كان المطلوب من طلب المجموعة التجريبية استخدام نظام بروتنيوس.

المتعلمين من كلا الفريقين لم يتذبذبوا أي مسار تقليدي موازي وطلب منهم عدم استخدام أي مواد إضافية أو مساعدة.

وتتألف المجموعة التجريبية من ٣٤٠ متعلم، بينما تتألف المجموعة الضابطة من ١٠٠ متعلم. استمرت التجربة لمدة أربعة أشهر تقريباً، خلال الفترة من يناير ٢٠١٠ وحتى أبريل ٢٠١٠. يستنتجوا أن الإختلافات بين المجموعتين التجريبية والمجموعة السيطرة تكاد لا تذكر.

أظهرت نتائج التجربة أن المتعلمين في المجموعة التجريبية يجب أن يكونوا قادرين على إتمام الدورة في وقت أقل من المتعلمين في المجموعة السيطرة. وأن المجموعة التجريبية أنهت بإستمرار المزيد من الدروس بنجاح أكثر من المجموعة السيطرة.

كما أظهرت النتائج ملائمة استخدام هذا النموذج للتوصية، من أجل اقتراح أنشطة التعلم عبر الإنترنت للمتعلمين على أساس أسلوب التعلم والمعرفة والتفضيلات. ولقياس الدقة الإحصائية يستخدم متوسط الخطأ المطلق (MAE).

### **٣- مزيج من خوارزميات تعلم الآلة للتوصية بالمقررات في نظام التعليم الإلكتروني اعتماداً على البيانات التاريخية:**

## **Combination Of machine learning Algorithms For Recommendation Of Courses In E-Learning System Based On Historical Data:**

في نظام التوصية للمقررات التي توصي المقررات للطالب على أساس اختيار الطالب الآخرين لمجموعة معينة من المقررات [16]. ونتيجة لنظام التوصية للمقررات، يمكن أن يوصي طالب جديد لم يلتحق مسبقاً بأي مقرر. يستخدموا في طريقتهم مزيج من أسلوب التجميعات (Simple K-means) وخوارزمية (Apriori)، لإيجاد النتيجة. وتمت مقارنة هذه النتائج مع نتائج أداة تنقيب البيانات Weka المفتوحة المصدر.

قاموا بمقارنة نتائج خوارزمية قواعد الإرتباط (Apriori) وهي خوارزمية موجودة في أداة تنقيب البيانات weka مفتوحة المصدر ومجموعة أخرى من خوارزميات التجميع وقواعد الإرتباط مع نتائج خوارزمية الجمع باستخدام تجميع (K-means) وخوارزمية قواعد الإرتباط (Apriori).

أخذ في الاعتبار فئتين، فئة ١٣ مقرر وفئة ١٨ مقرر التي تخص قسمى علوم وهندسة الحاسوب (CSE) وتكنولوجيا المعلومات (IT). بعد جمع البيانات يهتمون فقط لأولئك الطلاب الذين يلتحقون بما لا يقل عن ٥ دورات.

النتيجة باستخدام خوارزمية (Apriori) تحتاج مرحلة إعداد البيانات وكذلك إذا زدنا الدعم فإن عدد قواعد الإرتباط سيكون أقل. والنتائج باستخدام مزيج منمجموعات التجميعات الأخرى لا يتطابق مع الخيارات في العالم الحقيقي للطلاب ولكن إذا استخدمو طريقة مشتركة باستخدام (K-means) و (Apriori) فعندما ليس هناك حاجة لاستخدام مرحلة إعداد البيانات وعدد قواعد الإرتباط سيكون أكثر، هذه الطرق المشتركة ستزيد قوة قواعد الإرتباط لذلك نظام التوصية للمقررات هذا سيساعد الطالب ليختار المقرر المناسب وفقاً لرغبته.

تم عرض النتائج باستخدام Weka إلى جانب نتائج الطريقة المشتركة (Simple K-means) و (Apriori)، ووجد أنها أفضل من النتيجة التي يحصلوا عليها باستخدام الخوارزميات والتجميعات الأخرى منمجموعات أخرى من خوارزميات التجميع وقواعد الإرتباط.

هذا النظام يمكن استخدامه أيضاً ليوصي بالمقررات للطالب في التعلم عن بعد يكون العمل في المستقبل لإيجاد مزيج آخر من تقنيات استخراج البيانات التي قد تكون مزيجاً من التصنيف وخوارزميات قواعد

الإرتباط أو مزيج من التصنيف والتجميع وخوارزميات قواعد الإرتباط. هذا العمل يمكن أيضاً أن يكون أكثر توسيعاً وتطوراً بحيث يدمج مع نظام التعليم الإلكتروني الموجود. لذلك نظام التوصية للمقررات هذا سيساعد في بناء نظام توصية ذكي. هذه الطريقة للتوصية للمقررات للطلاب الجدد تستخدم بشكل كبير في (MOOC) (Massively Open Online Courses).

### ٣. النهج القائم على تصفية التعاونية للتوصية المقررات الاختيارية:

## A Collaborative Filtering Based Approach for Recommending Elective Courses

التتبؤ بالدرجة يكون مفيد جداً للطالب ليقوم بإختيار المواد التي يرغب بها وقد تناسبه، وفي الوقت نفسه يتحصل فيها على درجات أفضل نسبياً. ويواجه الطلبة الذين يسعون إلى درجة التعليم العالي تحديين: عدد لا يحصى من الدورات للإختيار من بينها، وعدم وجود الوعي بالدورات التي يجب أن يدرسوها وبأي ترتيب. فإنه وفقاً لأصدقائهم وتوصيات زملائهم فإن الكثيرين منهم يختاروا مقرراتهم ويسجلوا وفقاً لذلك.

تم تقديم نظام التوصية [17]. لإختيار المقررات الدراسية الإلختيارية ودمجه في نظام التسجيل الحالي لكلية إدارة الأعمال إما عبر الإنترن特 أو بدونه. ويستند نظام التزكية للمقررات على عدة خوارزميات الفلترة التعاونية المختلفة مثل user-based (item - based OC1), (a modified variant of C4.5). وهي تقدم توصيات العنصر أو التوقعات استناداً إلى آراء المستخدمين الآخرين المشابهين للمستخدمين الحاليين في التفكير. كما أنها تتطلب الحد الأدنى من المعلومات، وهي عالية الدقة في التوصيات.

تمت مقارنة نهجين للتصفية التعاونية للتتبؤ بدرجة الطلبة التي قد يتحصلوا عليها في الدورات المختلفة، بناءً على أدائهم في الدورات السابقة. والفرق الأساسي بين الطرفيتين، أن item-based (item-based) تنتج التنبؤات اعتماداً على نموذج تشابه عنصر-عنصر أما user-based (user-based) تعتمد على أساس نموذج تشابه مستخدم لمستخدم وتستخدم أساساً لحل مشكلة التنبؤ. ولحساب التشابه تم استخدام معامل بيرسون.

تصنيفات البيانات يتحصل عليها صراحة أو ضمنياً. صراحة هي تلك التي تعطى تقييمات صريحة مباشرة من قبل المستخدم، في حين أن البيانات الضمنية يمكن جمعها بشكل غير مباشر من خلال دراسة بيانات عن المستخدم من مصادر مختلفة مثل بيانات الشراء، وإستعراض السلوك الخ.

نتائج التجربة لديهم على مجموعة البيانات من الحياة الحقيقية مشجعة للغاية. وهم يعتقدوا أن النهج الذي إتبعته التصفية التعاونية الطلابية للتنبؤ بالدرجة، دقيق. ومن النتائج وقيم MAE تمت ملاحظة أنه لا يوجد فرق كبير في الدقة بين (item\_based) و(user\_based).

للحصول على توصيات دقيقة، لا بد من تقييم العديد من المقررات قدر الإمكان. النظام لا يمكنه التنبؤ بتوصيات للطلاب الذين لم يدرسوا أي من المقررات الدراسية في الجامعة للعمل في المستقبل، يمكن أن يتم البحث في وضع استراتيجيات التكامل للأساليب التي يمكنها التنبؤ بدقة لأداء الطالب في الدورات والمناهج التي تساعد على اختيار مواضيع أو دورات على أساس اهتمامات الطلاب وأهداف التعليم. هذه الطرق يمكن استخدامها لنقديم النصائح القيمة للطلاب وتقديم المشورة والتوجيه المهني وعملية اختيار المقررات.

## ٣.٥ استخدام تنقيب البيانات لتحسين استبقاء الطالب في التعليم العالي

### Use Data Mining To Improve Student Retention In Higher Education

واحدة من أكبر التحديات التي يواجهها التعليم العالي هو تحسين معدلات استبقاء الطالب لمواصلة تعليمه. يستخدم الباحثين [18]. استخراج البيانات وتقنيات معالجة اللغة الطبيعية لمراقبة الطلاب، وتحليل السلوك الأكاديمي للطلاب وتوفير أساس لإستراتيجيات تدخل تتسم بالكافأة. أن وظيفة التنبؤ من إستخراج البيانات يمكن أن تساعد الجامعة لاستبقاء الطلاب أو التخطيط لموارد تستند إلى معرفة كم عدد الذين سينتقلوا أو سيسجلوا لدورة معينة. هدفهم هو تحديد المشاكل المحتملة في أقرب وقت ممكن ومتابعتها مع خيارات التدخل لتحسين استبقاء الطالب.

اكتشاف المعرفة في قواعد البيانات (KDD)، ويمكن العثور على العلاقات والأنمط الموجدة لكنها مخبأة بين الكم الهائل من البيانات التعليمية. فهو يجمع بين التعلم الآلي والتقنيات الإحصائية والتصور لاكتشاف واستخراج المعرفة بمثل هذه الطريقة يمكن للناس فهمه بسهولة. للجامعات، فإن المعرفة التي اكتشفت بواسطة تقنيات استخراج البيانات توفر تعليم مخصص يرضي طالب الطلاب واصحاب العمل.

نظام جامعة وادي التaimz (Oizilbash, TVU, 2008) لديها كمية كبيرة من البيانات التي يمكن تحليلها واستخراجها لنظام استخراج البيانات. الكليات والأقسام لديها بيانات التفاصيل الهامة أيضاً بشأن الدورات والوحدات وهي في شكل وثيقة. نظام سجل الطالب يحمل معلومات حول سجلات الطلاب

سبيل المثال، نتائج الامتحانات للطالب والتسجيل للدورات. وهو مصدر البيانات الأكثر أهمية لمشروعهم.

(Seidman,1996) وضع سيدمان صيغة لاستبقاء الطالب:

Retention = Early Identification + (Early + Intensive +Continuous) Intervention

يقومون الان بتطوير جزء متداخل من MCMS يحتوي على موقع على الويب لمراقبة الطالب،والوحدة، ومعلومات الدورة عندما يسجل بها الطالب، كما انه يمكن ان يتحقق من المعلومات التفصيلية لكل نتائج النماذج ومخطط تطوره وما اذا كان في خطر ام لا ولماذاما بالنسبة للمدرسين فيمكنهم الدخول لايجاد تفاصيل متعلقة بمعلومات الوحدة، ويمكن ان يتواصلوا مع الطالب عبر النظام، يمكنهم أيضا مقارنة المعلومات من وحدات ذات صلة في فصول دراسية مختلفة.

# الباب الرابع

الإرشاد الأكاديمي

## **٤. ١ مقدمة**

يعد الإرشاد الأكاديمي الركيزة الأولى التي يعتمد عليها نظام الساعات المعتمدة وهو لا يقتصر في وظائفه على التعريف بالخطة الدراسية ومساقاتها فقط، بل يتعداها إلى توثيق العلاقة بين الطلبة وأولياء الأمور من جانب وأعضاء هيئة التدريس من جانب آخر، [19] بما يحقق الأهداف المتواحة من العملية التربوية. وهو عملية مهنية وتربوية تقدم للطلبة الدارسين في الجامعات. ويمثل الإرشاد الأكاديمي واحداً من أهم وسائل مساعدة الطالب للإندماج في البيئة الأكاديمية وتحقيق أعلى معدلات النجاح، كما يساهم في التأكيد من مسيرة الطالب العلمية من حيث تطبيق الخطة الدراسية وكذلك فيما يتعلق بأداء الطالب وتحصيله العلمي في مختلف المساقات. وأيضاً يساهم الإرشاد الأكاديمي في مساعدة الطالب على الإنقال التدريجي والمبرمج من بيئه التعليم في المراحل السابقة لدراسته الجامعية إلى بيئه المرحلة الجامعية التي يعتمد فيها الطالب على نفسه في إتخاذ قراراته وتحديد تخصصه وتطوير مستوىه العلمي والسلوكي. وتقوم الدوائر المختلفة بتعيين مرشد أكاديمي لكل طالب منذ إتحاقه بالجامعة بالفصل الأول.

## **٤. ٢ الإرشاد الأكاديمي**

هو النشاط الذي يقوم به المرشدون الأكاديميون بالكلية لتعريف الطالب بالأنظمة واللوائح الدراسية ومساعدتهم في التقدم الدراسي والتغلب على ما يعترضهم من مشكلات وصعوبات إجتماعية أو نفسية أو صحية أو أكاديمية.

## **٤. ٣ أهمية الإرشاد الأكاديمي**

الطالب هو محور العملية الإرشادية إذ توجه كل الجهود نحو تسجيله وإعداده بالشكل الصحيح لتلافي وقوع أي مشكله ولكنه يستثير بدور مهم في هذا الموضوع. كل العملية التعليمية وما يتبعها من خطوات وإجراءات تبدأ من عند الطالب فإن كان إرشاداً أو تسجيلاً أو حضوراً للدراسة أو أداءً لواجباته الأكademية يجب على الطالب أن يبادر إلى الشروع بالإجراءات الازمة ، وعندما تعرضه أي مشكله عليه مراجعة جهة الاختصاص حسب نوع المشكلة.

## **٤. ٤ المرشد الأكاديمي**

المرشد الأكاديمي يقصد به عضو هيئة التدريس المكلف بإرشاد عدد معين من الطلاب في كل ما يتعلق بشؤونهم الأكاديمية والإجتماعية والصحية منذ قبولهم بالكلية .

أو هو عضو هيئة التدريس الذي يقوم بتقديم العون للطالب في أثناء عملية التسجيل كما يتولى مساعدة الطالب وإرشاده في تنفيذ خطته الدراسية وتقديم النصائح له في الأمور المتعلقة بالشؤون الأكademie ومتابعة تحصيله العلمي وإختيار المساقات التي سوف يسجلها ويساعده في حل ما قد يعترضه من مشكلات. ويوزع الطلبة على المرشدين في القسم العلمي من قبل الكلية.

## ٤.٥ مهام المرشد الأكاديمي

يقوم المرشد بتخصيص زمن محدد للإرشاد يضمن في الجدول الأسبوعي ويعلن للطلاب. على المرشد أن يكون على استعداد للإستماع بתרو لطلابه وعليه أن يهتم بشؤونهم الأكademie والإجتماعية وعليه أن يقوم بشرح نظم ولوائح الامتحانات ودليل الإرشاد الأكاديمي وملحقاته للطالب، يتبع المرشد السير الأكاديمي للطالب منذ تسميته مرشدًا له حتى تخرجه، يراجع المرشد الأداء المستمر للطالب وعمله ليكون على دراية بمدى إنتظام الطالب في الدراسة وفي أدائه للواجبات الأكademie التي يكلف بها، يقوم المرشد بإعداد ملف خاص لكل طالب يحتفظ فيه بأدائه الأكاديمي وسجلات درجاته في المواد وأي أوراق أخرى تتعلق بالطالب.

يقوم المرشد عند بداية كل فصل دراسي بالتوقيع على إستماراة تسجيل الطالب، يقوم المرشد بنصح الطالب وتوجيهه عند تحديد نوع القيد وبالتوقيع على الإقرار عند الحاجة له وتبصير الطالب بكافة العواقب، يقوم المرشد بمساعدة الطالب على تنسيق جدول امتحاناته متى ما يستدعي الوضع الأكاديمي للطالب ذلك ليتوافق مع جدول الامتحانات المعلن، ويقوم المرشد بدراسة أي مشكلة لدى طلابه ويسعى لمعالجتها بالتنسيق مع القسم المعين.

## ٤.٦ المشاكل التي تواجه المرشد الأكاديمي

- عدم توفر الوقت الكافي لدى المرشد للقيام بالعملية الإرشادية.
- أحياناً يتغدر على المرشد الأكاديمي القيام بمهمة الإرشاد بسبب كثرة المهام المسندة إليه.
- يشكو بعض المرشدين من زيادة عدد طلابهم.
- عدم توفر التدريب الكافي للمرشدين الأكاديميين والإعتماد على قدراتهم الشخصية في إكتساب الخبرة في الإرشاد.

## ٤.٧ بعض السمات الأساسية للساعات المعتمدة

ينجح الطالب في المقرر إذا حصل على 42% درجات المقرر، ويعتبر الحصول على 50% من درجات مقرر إزالة الرسوب نجاحاً بتقدير ضعيف.

يسمح الطالب بالانتقال من فصل إلى التالي بما لا يزيد عن 4 من مقررات (أو 10 من ساعات) الرسوب والبديل ويجوز للكلية السماح بالانتقال مع تأجيل الجلوس للإمتحان في ما لا يزيد عن 4 من هذه المقررات (أو 10 من ساعات) شريطة أن لا تزيد ساعات الرسوب عن المؤجلة 4 ساعات معتمدة.

## ٤.٨ حساب النتيجة:

يحسب المعدل الفصلي عن طريق الحصول على الدرجات التي حصل عليها الطالب في نهاية الفصل مقسمة على 25 لحساب الدرجة النقطية لكل مقرر (وفي حالة إزالة الرسوب يتم القسمة على 30) ثم تحسب نقاط المقرر بضرب الدرجة النقطية في عدد الساعات المعتمدة للمادة ثم نقوم بقسمة مجموع نقاط المقررات على مجموع الساعات المعتمدة الفصلية لحساب المعدل الفصلي.

$$\text{المعدل الفصلي} = \frac{\text{المجموع الكلي للنقط}}{\text{المجموع الكلي للساعات}}$$

(مثلاً إذا كان المجموع الكلي للنقط 125 والمجموع الكلي للساعات 150، فإن المعدل الفصلي سيكون 0.83)

أما المعدل التراكمي فيتم حساب النقاط الفصل الدراسي الحالي زائداً النقاط التراكمية وال ساعات المعتمدة زائداً الساعات التراكمية وقسمتها أما في حالة وجود رسوب يتم حساب نقاط المقرر للفصل زائداً نقاط المقرر لم المواد الرسوب لحساب النقاط الفصلية وكذلك الساعات الفصلية عبارة عن مجموع الساعات المعتمدة للفصل زائداً مجموع الساعات المعتمدة لإزالة الرسوب ثم يحسب المعدل التراكمي

$$\text{المعدل التراكمي} = \frac{\text{المجموع الكلي للنقط}}{\text{المجموع الكلي للساعات}}$$

(مثلاً إذا كان المجموع الكلي للنقط 125 والمجموع الكلي للساعات 150، فإن المعدل التراكمي سيكون 0.83)

# **الباب الخامس**

**جمع البيانات**

## **٥.١ مقدمة**

في هذا البحث تم التعامل مع إستماراة التسجيل للطلاب الأكاديمي وتم التعامل مع البيانات المتعلقة بالمواد التي لم ينجح بها مع المعدل التراكمي (GPA) والوضع الأكاديمي.

## **٢. اختيار البيانات**

تم الحصول على البيانات من مكتب المسجل للأقسام المختلفة في كلية علوم الحاسوب جامعة السودان، وتمثل هذه البيانات في إستمارات التسجيل للطلاب خلال دراستهم الجامعية علي مدار الأربع سنوات الشكل رقم(٤-١) يوضح إستماراة الطالب الأكاديمي، التي تحتوي على ثلات أجزاء الجزء الأول خاص بالطالب ويحتوي على إسم الطالب ورقم التسجيل والقسم الذي ينتمي إليه الطالب و الفصل الدراسي الذي درسه. الجزء الثاني يحتوي على عدد مقررات البديل والرسوب التي إمتحنها الطالب يحددها المرشد الأكاديمي مع الطالب ويحدد الفصل الذي سيمتحنها فيه، ويحتوي إسم المرشد وتوقيعه وإعتماد رئيس القسم، أما الجزء الثالث خاص بمسجل الكلية.

تهمنا فقط الإستمارات التي تم التعليق عليها من قبل المشرفين الأكاديميين لوضع خطة دراسية للطالب تتناسب مع معدله والمواد التي واجه مشاكل بها أما الطلاب الذين تم التوقيع علي إستماراتهم من دون تعليق أو ملاحظات ليسجلوا للفصل الدراسي الجديد بنفس الخطة الدراسية الأصلية للكلية لا يحتاجون للإرشاد الأكاديمي لوضع خطة دراسية أخرى. والإستمارات يمكن أن تكون متالية أو متفرقة علي مدار الفصول الدراسية للطالب.

## **٣. تهيئة البيانات لقواعد الإرتباط**

بعد إكمال جمع البيانات من مصادرها وإستبعاد الإستمارات للطلاب الناجحين من مجموعة الإستمارات التي كانت في شكل ملفات ورقية قمنا بحوسبتها في منظومة (Excel) الصف الأول عبارة عن المقررات الدراسية التي درسها الطالب منذ إتحاقه بالكلية إلي التخرج،الشكل رقم(٢-٥) يوضح نموذج للبيانات في (Excel) من أول فصل دراسي إلي آخر فصل.أما العمود الأول يمثل أرقام الطلاب الجامعية والعمود الثاني يمثل المعدلات التراكمية للطلاب علي حسب الفصل الذي درسوه، بقية الخلايا في (Excel) تم وضع الرقم واحد في الخلية لتمثل المادة التي درسها الطالب المعين علي حسب الفصل الدراسي والخلايا الخالية تعني أن المواد المعينة في الفصل المعين لن يدرسها الطالب إما لأنه درسها ونجح فيها أو أنها تدرس في فصل قادم. قمنا بعمل صورة لملف (Excel) من دون إظهار أرقام الطلاب الجامعية بسبب سرية هذه البيانات. ثم تمت تهيئة الملف لتناسب أداة تنقيب البيانات (weka).

استماره تسجيل طالب نظامي (نظام الساعات المعتمدة)

العام الدراسي .....  
.....

الجزء الأول: بيانات خاصة بالطالب:

(١) الاسم: ..... (٢) رقم التسجيل: .....

(٣) القسم: ..... (٤) الفصل الدراسي: .....

(٥) السنة الدراسية : .....  
.....

الجزء الثاني خاص بالقسم:

(١) النتيجة السابقة: .....  
.....

(٢) عدد مقررات البديل والرسوب (وأسماؤها) التي سوف يجلس الطالب فيها (يحددها الطالب مع المرشد الأكاديمي):

أ/ مع امتحانات الفصل: ..... السنة: ..... (لا تزيد عن أربعة ولا تزيد ساعاتها عن ١٠ ساعة معتمدة):

المقرر	م	عدد الساعات	المقرر	م	عدد الساعات
	٣			١	
	٤			٢	

ب/ مع امتحانات الفصل: ..... السنة: ..... (مقررات مؤجلة لا تزيد عن أربعة ولا تزيد ساعاتها عن ١٠ ساعات معتمدة):

المقرر	م	عدد الساعات	المقرر	م	عدد الساعات
	٣			١	
	٤			٢	

(٣) اسم المرشد الأكاديمي: ..... التوقيع: ..... التاريخ: .....

(٤) اعتماد رئيس القسم ..... التاريخ: .....

الجزء الثالث:- خاص بمسجل الكلية

أ/ هل استوفى الطالب شروط التسجيل؟: .....  
.....

ب/ هل وقع الطالب الذي لديه إنذار ثان على الإقرار؟ .....  
.....

توقيع المسجل ..... التاريخ: .....

الشكل (١-٥) لاستماره الطالب الأكاديمي

GPA	math2	Physics2	account	ogramming_fund	english3	islaic3	math3	descreate1	software1	Programming1	Statistics	hardware	software2	descl
2.36				1										
2.27				1										
2.28														
2.31														
2.29														
2.13														
2.35														
1.99														
2.02														
1.81	1													
1.95													1	
2.01	1												1	
1.97														
2.06														
2.15														
1.98														
1.73							1							
1.92								1						
2.03									1					
2.07										1				
2.1														
1.61														
1.86			1											
1.43														
1.86	1	1							1				1	1
2.07	1											1	1	
2.08	1													
1.93														
2.28	1													
1.88	1													
2.01														
2.1	1													
..														

(Apriori) نموذج لبيانات (٢-٥) الشكل

## ٤. تهيئة البيانات للفترة التعاونية

العمود الأول يمثل أرقام الطالب الجامعية والعمود الثاني يمثل متوسط المعدلات التراكمية للطلاب، أما بقية الخلايا في (Excel) تم وضع الأرقام المختلفة لتمثل عدد المرات للمواد التي جلس الطالب لتقديمها. الشكل رقم (٣-٥) يوضح نموذج لبيانات في (Excel) للفترة التعاونية.

GPA	arabic1	Mathematics1	Physics1	introduction	arabic2	Islamic2	math2	Physics2	account	ogramming_fund	english3	islaic3	math3	descreal
2.3										2				
2.29														
1.86														
1.99														
1.81									3	1	1			
2.04									3					
2.31														
2.69														
2.52														
2.32										1				
2.41														
2.16														3
2.14													1	
2.16									2	1				
2.15														
1.95									2		1			
2.14	2													
1.12	2	2	2				2	1		1	1		1	
1.88		2	1									2		
1.28														
1.53	1	1	1											
1.34	1	1	1											
2.16	1													
2.66							1					1		

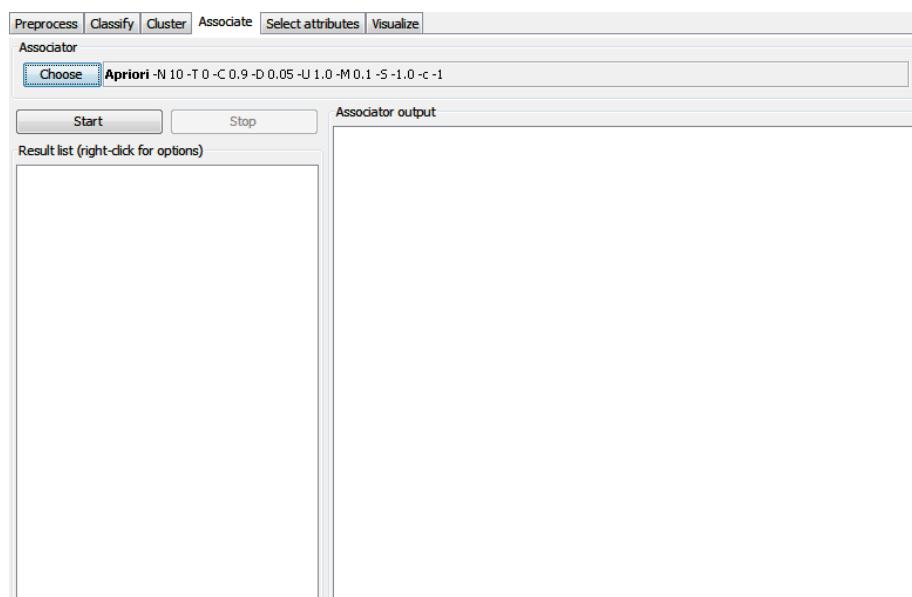
(K-NN) نموذج لبيانات (٣-٥) الشكل

٥. تذكير البيانات

وتم في هذه المرحلة إستخدام تقنية الفلتره التعاونية (collaborative filtering) بإستخدام خوارزمية (KNN) وأيضاً إستخدام قواعد الإرتباط بخوارزمية (Apriori).

## ٦. طريقة اختيار خوارزمية (Apriori)

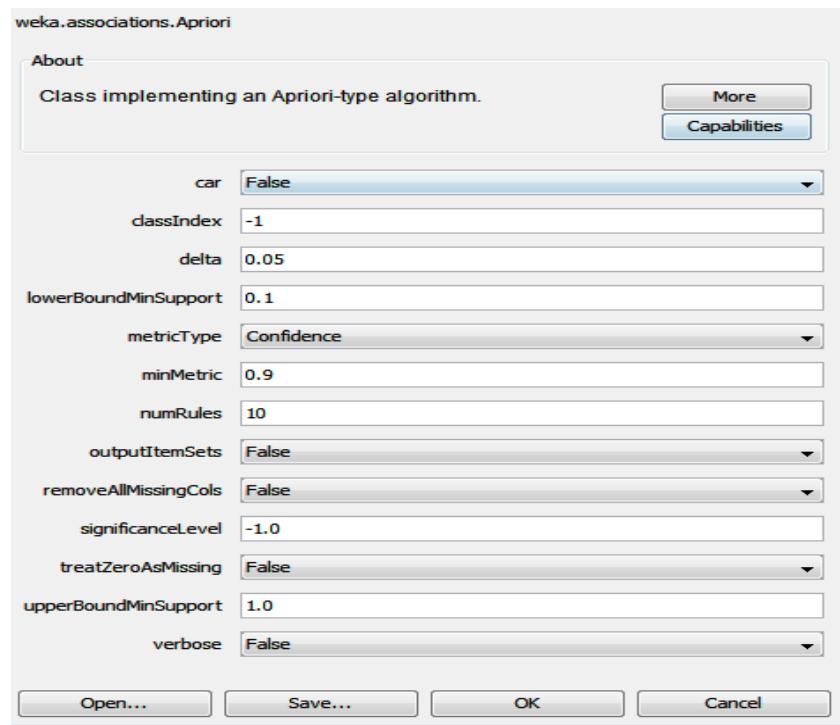
بعد أن يتم تحميل البيانات تقوم بتحديد الصفات(attributes) التي نريد إجراء عملية التجميع عليها ويمكن اختيار جزء منها أو اختيار جميعها وكذلك الحذف. ثم الرجوع لأعلى القوائم لإختيار (Associate) وبعدها اختيار start (لتبدأ خوارزمية Apriori) بالعمل وإظهار المخرجات والشكل (٣-٥) يوضح طريقة اختيار الخوارزمية.



(Apriori) خوارزمية اختيار طريقة (٤ . ٥) الشكل

**طريقة اختيار (support) و (confidence)**

في خوارزمية (Apriori) أجريت تجارب عديدة على البيانات وأعطت نتائج مختلفة وإختلاف النتائج يعتمد على تغيير (support) و (confidence) وتغيير الصفات، والمشكلة الأساسية في الخوارزمية هي إختيار (support) و (confidence) المناسب بسبب ذلك النتائج التي تم الحصول عليها منها ما هو منطقي ومنها ما هو غير منطقي والشكل (٤-٥) يوضح طريقة إختيار (support) و (confidence).



الشكل (٥.٥) شاشة اختيار (confidence) و (support)

وبعد الاطلاع على النتائج قمنا بتحديد القواعد التي يظهر فيها المعدل التراكمي (GPA) مع المواد التي جلس لامتحانها مما يساعد في تحديد أي مواد يمكن الجمع بينها وأي المواد التي اذا تم الجمع بينها يؤثر ذلك بشكل سلبي على نتيجة الطالب، ويمكن معرفة ذلك من خلال المعدل التراكمي لأنّه يوضح نتيجة المواد التي جلس لامتحانها.

الشكل (٥-٥) يوضح ملخص النتائج المتحصل عليها بعد تطبيق خوارزمية (Aproiri) موضحا عدد المجموعات المتكررة (Frequent item sets) التي تم تنقيبها وعدد القواعد المكتشفة ومتوسط كل من (confidence and support) لكل قاعدة مع ثبات (Support) وتغيير (confidence).

Confidence	Support	n.Rules	Large item set	n.item sets
<b>0.1</b>	<b>0.001</b>	<b>14</b>	<b>4</b>	<b>4</b>
<b>0. 2</b>	<b>0.001</b>	<b>2</b>	<b>2</b>	<b>2</b>
<b>0. 3</b>	<b>0.001</b>	<b>1</b>	<b>2</b>	<b>2</b>

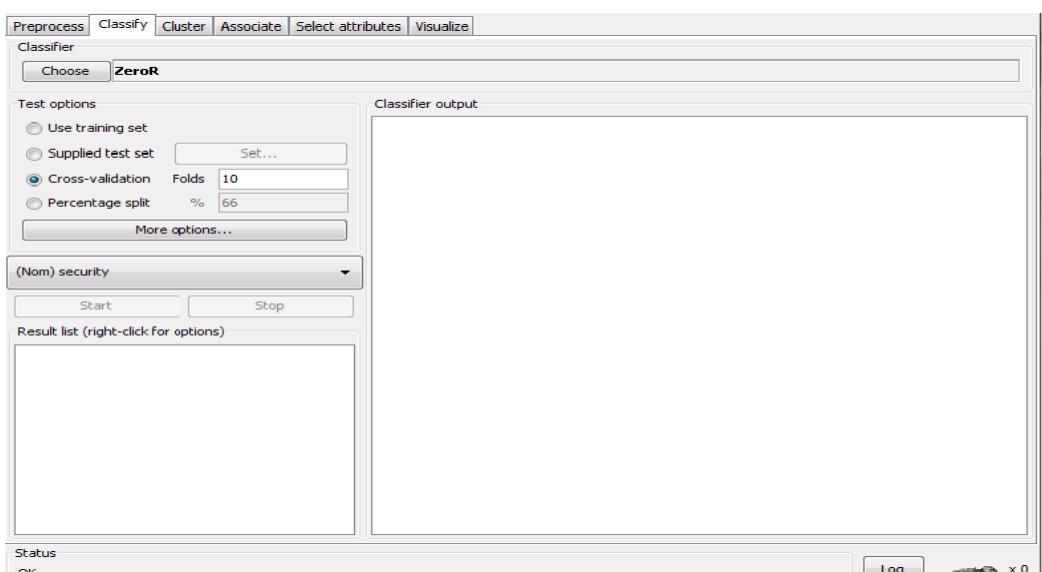
الشكل (٥-٥) يوضح النتائج المتحصل عليها

ومن النتائج لاحظنا كلما زادت نسبة (item set) قل عدد (Confidence) وكلما قل (item set) كانت العلاقات بينهم أكثر منطقية، التغيير في كلاً من قيم (confidence) و (support) بزيادة أو نقصان يؤدي إلى ظهور قواعد مختلفة ذات درجات مختلفة من المنطقية.

كما ظهرت كمية كبيرة من النتائج البديهية والنتائج الغير منطقية عند تحديد جميع الصفات لإيجاد العلاقات بينهم مما جعلنا نقوم بتحديد صفات معينة واجراء العمليات عليها لاكتشاف علاقات أكثر منطقية بين المواد.

## ٦.٥ كيفية عمل خوارزمية (k-NN)

بعد أن يتم تحميل البيانات لعمل خوارزمية (K-NN) تقوم بتحديد الصفات (attributes) التي نريد إجراء عملية التجميع عليها، اختيار (choose) في (classify) (التحديد الخوارزمية بالضغط على (lazy) وبعدها (IBK) وهي خوارزمية الفلترة التعاونية أو الجار الأقرب وأخيراً اختيار العناصر المراد اختبارها أسلف (more options) ثم اختيار (start) لتبدأ الخوارزمية بالعمل وإظهار المخرجات كما في الشكل (٦-٥).

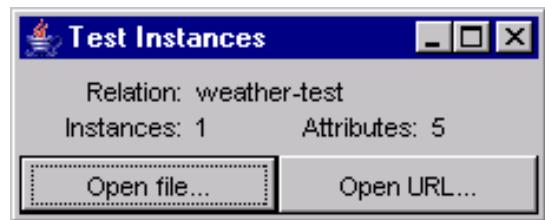


الشكل (٦-٥) شاشة (classify)

تحديد خيارات الاختبار (test options)

١. استخدام مجموعة التدريب (Use training set): يعني استخدام مجموعة التدريب (الملف الذي قمت بتحميله في (Preprocess) للإختبار.

٢. التزود بمجموعة اختبار (Supplied test set): يعني أنه يمكنك تحديد ملف مع بيانات الإختبار. للقيام بذلك تحديد الخيار والنقر على تعين. وتشير نافذة صغيرة تسمى حالات الإختبار التي تسمح لك لتحميل ملف اختبار ثم يظهر لك إسم العلاقة وعدد من الصفات والحالات. أنقر على الملف المفتوح (open file) وتحمّل ملف اختبار. يمكنك الحصول على ما يلي:



٣. عبر التحقق من الصحة (Cross-validation): هو أسلوب تتبّع للتحقق من صحة نموذج لتقدير كيف يمكن للنتائج أن تحمل الإحصائيات والتعميم إلى مجموعة بيانات مستقلة.
٤. نسبة الانقسام (Percentage split): يعني أنه سيتم تقدير نتائج التصنيف على مجموعة الإختبار التي هي جزء من البيانات الأصلية. الإنقسام الإفتراضي (كما هو موضح في منطقة النص بجانب الخيار) هو ٦٦٪، وهو ما يعني أن ٦٦٪ من البيانات تذهب للتدريب و ٣٤٪ للإختبار.

# **الباب السادس**

**مناقشة النتائج والتوصيات**

## ٦.١ مقدمة

في هذا الباب سوف نناقش نتائج كلاً من خوارزمية (Apriori) و (k-nn)

## ٦.٢ نتائج خوارزمية (Apriori)

```
31. BS 126=1 CS 215=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
32. BS 126=1 MAT 222=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
33. GPA=1.37 BS 126=1 CS 215=1 MAT 222=1 1 ==> CS 225=1 1    conf:(1)
34. GPA=1.37 BS 126=1 CS 215=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
35. GPA=1.37 BS 126=1 MAT 222=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
36. GPA=1.37 CS 215=1 MAT 222=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
37. GPA=2.48 CS 215=1 MAT 222=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
38. BS 126=1 CS 215=1 MAT 222=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
39. GPA=1.37 BS 126=1 CS 215=1 MAT 222=1 EN 223=1 1 ==> CS 225=1 1    conf:(1)
40. CS 215=1 MAT 222=1 4 ==> CS 225=1 3    conf:(0.75)
41. CS 215=1 EN 223=1 3 ==> CS 225=1 2    conf:(0.67)
42. MAT 222=1 EN 223=1 3 ==> CS 225=1 2    conf:(0.67)
43. MAT 222=1 6 ==> CS 225=1 3    conf:(0.5)
44. GPA=1.37 2 ==> CS 225=1 1    conf:(0.5)
45. GPA=2.01 2 ==> CS 225=1 1    conf:(0.5)
46. GPA=2.44 2 ==> CS 225=1 1    conf:(0.5)
47. GPA=2.48 2 ==> CS 225=1 1    conf:(0.5)
48. GPA=2.07 CS 215=1 2 ==> CS 225=1 1    conf:(0.5)
49. GPA=2.48 EN 223=1 2 ==> CS 225=1 1    conf:(0.5)
50. GPA=1.98 3 ==> CS 225=1 1    conf:(0.33)
51. CSS 221=1 3 ==> CS 225=1 1    conf:(0.33)
52. CS 215=1 14 ==> CS 225=1 4    conf:(0.29)
53. EN 223=1 20 ==> CS 225=1 5    conf:(0.25)
54. GPA=2.07 4 ==> CS 225=1 1    conf:(0.25)
55. GPA=2.23 4 ==> CS 225=1 1    conf:(0.25)
56. GPA=0 5 ==> CS 225=1 1    conf:(0.2)
57. GPA=2.14 5 ==> CS 225=1 1    conf:(0.2)
58. ENG 212=1 5 ==> CS 225=1 1    conf:(0.2)
59. BS 126=1 8 ==> CS 225=1 1    conf:(0.13)
```

(الشكل ٦.١) نتائج خوارزمية (Apriori)

الشكل (٦.١) يوضح جميع نتائج خوارزمية (Apriori) وقد قمنا باختيار بعض القواعد لمناقشتها ومن القواعد المعتمدة.

١. GPA=1.37 BS 126=1 CS 215=1 MAT 222=1 1 ==> CS 225=1 1 conf:(1)

2. GPA=1.37 BS 126=1 CS 215=1 EN 223=1 1 ==> CS 225=1 1 conf:(1)

3. GPA=1.37 BS 126=1 CS 215=1 MAT 222=1 EN 223=1 1 ==> CS 225=1 1

## ٦.٢ مناقشة نتائج خوارزمية Apriori

١. الطلاب الذين يرسبون في مادة المحاسبة ومادة الإحصاء سوف يرسبون أيضاً في مادة الهياكل المتقطعة ومعدلهم سوف يكون أقل من 1.40.

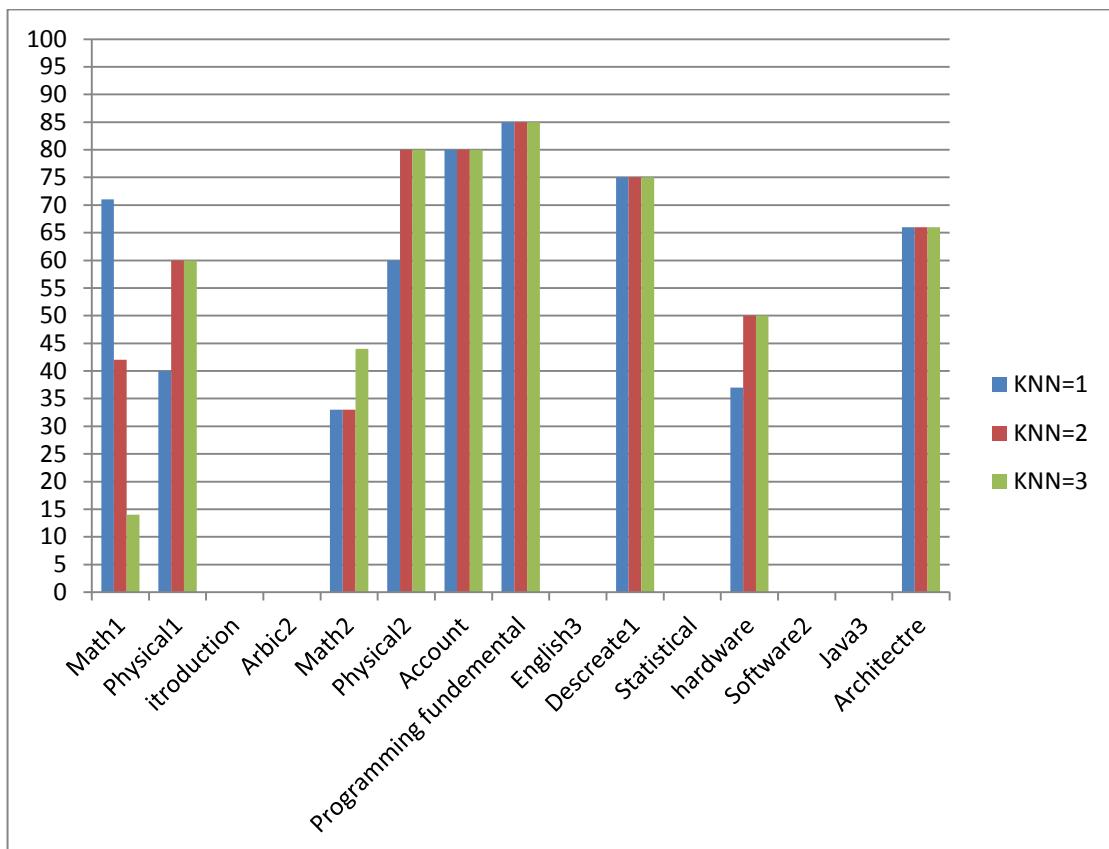
٢. الطلاب الذين يرسبون في مادة الإحصاء ومادة المكونات المادية سوف يرسبون أيضاً في مادة الهياكل المتقطعة ومعدلهم سوف يكون أقل من 1.40.

٣. الطلاب الذين يرسبون في المواد الإحصاء والهياكل المتقطعة ١ و المكونات المادية سوف يرسبون أيضاً في مادة الهياكل المتقطعة ٢ ومعدلهم سوف يكون أقل من ١.٤٠.

## ٢.٦ التوصيات

١. إذا رسب الطالب في مادتي المحاسبة والإحصاء لا ينصح بالجلوس لهذه المواد معاً بل يجب أن يمتحن واحدة فقط حتى لا يرسب المادتين ويرسب في مادة ثلاثة.
٢. إذا رسب الطالب في مادتي الإحصاء والمكونات المادية لا ينصح بالجلوس لهذه المواد معاً بل يجب أن يمتحن واحدة فقط حتى لا يرسب المادتين ويرسب في مادة ثلاثة.
٣. إذا رسب الطالب في المواد الإحصاء والهياكل المتقطعة ١ والمكونات المادية لا ينصح بالجلوس لهذه المواد بل ينصح بأن يعيد السنة الدراسية حتى لا يأخذ إنذار بسبب المعدل.

## ٦.٣ مخطط يوضح نسب خوارزمية (KNN)



الشكل(٢.٦) مخطط نسب خوارزمية(KNN)

الشكل(٢.٦) يوضح مخطط نسب خوارزمية(KNN) للطلاب الراسبين في المواد عندما تكون  $k=1$ ،  $knn=1,2,3$  هذا يعني أن الخوارزمية تقارن بمتوسط معدل تراكمي واحد فقط للطلاب الراسبين بعد تقديمهم للمواد مع بقية متوسطات المعدلات التراكمية التي هي مجاوره أو مقاربه له، أما  $k=1,2,3,000$  هذا يعني أنه يقارن بمتوسط معدلين أو ثلاثة أو أكثر من ذلك علي حسب  $K$ .

## ٣.٦ مناقشة نتائج المخطط

- ١- في  $k=1$  هذا يعني أن متوسط معدل الطلاب في مادة الرياضيات ١ عندما  $k=1$  النسبة ٧١٪ وعندما  $k=2$  نسبة متوسط معدل الطلاب ٤٢٪ وعندما  $k=3$  نسبة متوسط معدل الطلاب ١٤٪ وهكذا في بقية المخطط.
- ٢- في بعض المواد تظهر نسب  $(1,2,3)=0$  وهذا يعني أنه لا توجد علاقة بين متوسطات معدلات الطلاب الراسبين.
- ٣- يلاحظ بعض المواد لديها نسب  $(1,2,3)$  ثابتة، وهذا يدل على أن الطلاب الراسبين في هذه المواد معدلاتهم متقاربة.

## ٦.٣.٢ التوصيات

- ١- للحصول على أفضل النتائج يجب استخدام أكبر قدر من البيانات وعمل ملف كامل لكل طالب.
- ٢- حوسبة البيانات التي سستخدم لهذا النظام.
- ٣- دمج كل من خوارزميتي (K-NN) و(Apriori) في نظام خليط للحصول على نتائج أفضل.

## **الخاتمة**

بعد تحليل النتائج ومناقشاتها والاطلاع على الحالات الأكademية للطلاب قيد الدراسة ظهرت أهمية نظم التوصية لتجنب إعطاء توصيات غير ملائمة لحالة الطالب بسبب قرارات تخص خطتهم الدراسية والاستفادة من الحالات لطلاب اتبعوا الإرشاد الجيد.

وأثبتت النتائج أن من الصعب التخلص من المرشد الأكاديمي ولكن يمكن مساعدة المرشدين الجدد ببعض الأمور التي تتعلق بمساعدة الطالب الأكاديمي المتعثر أكاديميا حتى يستطيع تحسين أدائه ومواصلة مشواره الدراسي.

# المراجع

# المراجع

[1] ويكيبيديا (أبريل 2015). *تنقيب في البيانات*. Retrieved from [https://ar.wikipedia.org/wiki/%D9%81%D9%8A%D9%86%D9%8A%D8%A8\\_%D9%81%D9%8A\\_%D7%A9%D9%82%D9%8A%D8%A8](https://ar.wikipedia.org/wiki/%D9%84%D9%8A%D9%86%D9%8A%D8%A8_%D9%81%D9%8A_%D7%A9%D9%82%D9%8A%D8%A8)

البيانات\_في\_تنقيب

[2] همام حايك (٢٠١٥). *التنقيب في البيانات واستخراج المعرفة*. Retrieved 129, 2015, from نسيج:

<http://blog.naseej.com/2014/03/27/التنقيب-عن-البيانات/>

[3] تطوير اليات جديدة للتنقيب في . (2009). آصف شميس. رakan رزوق، د. فادي خلوف، أ: 15، مجلة جامعة دمشق للعلوم الهندسية. المعطيات لادارة علاقات الزبائن في بيئة مصرافية

[4] *Apriori algorithm*. (2015, September 18). Retrieved 12 9, 2015, from Wikipedia: [https://en.wikipedia.org/wiki/Apriori\\_algorithm](https://en.wikipedia.org/wiki/Apriori_algorithm)

[5] Michael D. Ekstrand, John T. Riedl, Joseph A. Konstan. (2011). *Collaborative Filtering Recommender Systems*. Human–Computer Interaction.

[6] *Collaborative filtering*. (2013, November 29). Retrieved 8 14, 2015, from Wikipedia: [https://en.wikipedia.org/wiki/Collaborative\\_filtering](https://en.wikipedia.org/wiki/Collaborative_filtering)

[7] *What is R?* (n.d.). Retrieved 9 21, 2015, from r: <https://www.r-project.org/about.html>

[8] *Data Mining using R*. (n.d.). Retrieved 9 22, 2015, from Rattle: <http://rattle.togaware.com/RattleBrochure.pdf>

[9] *RapidMiner* . (2014, October 8 ). Retrieved jly 23, 2015, from Wikipedia: <https://en.wikipedia.org/wiki/RapidMiner>

[10] *What is Apache Mahout?* (n.d.). Retrieved 9 21, 2015, from mahout: <http://mahout.apache.org>

[11] *PSPP*. (2015, June 20). Retrieved June 12, 2015, from Wikipedia: <https://en.wikipedia.org/wiki/PSPP>

[12] *What is R?* (n.d.). Retrieved 9 21, 2015, from r: <https://www.r-project.org/about.html>

- [13] Abernethy, M. (2010, May 11 ). *Data mining with WEKA*. Retrieved May 8, 2015, from developerworks:  
<http://www.ibm.com/developerworks/library/os-weka2/>
- [14] ويكيبيديا (أبريل 2015). Retrieved 9 6, 2015, from [14] تتفقib في البيانات: البيانات في تتفقib/  
<https://ar.wikipedia.org/wiki/%D9%82%D9%8A%D9%82%D9%8A%D9%86%D9%8A%D9%84%D9%8A%D9%85%D9%8A%D9%82%D9%8A%D9%86>
- [15] Aleksandra Kla, Boban Vesin,Mirjana Ivanovi,Zoran Budimac. (2010, November 2). E-Learning personalization based on hybrid recommendation strategy and. *Computers & Education* , 15.
- [16] Sunita B. Aher, L.M.R.J. Lobo. (2013, April 25 ). Combination of machine learning algorithms for recommendation of. *Knowledge-Based Systems* , 14.
- [17] Sanjog Ray, Anuj Sharma. *A Collaborative Filtering Based Approach for. Madhya Pradesh*.
- [18] Ying Zhang, Samia Oussen,Tony Clark, Hyeonsook Kim. *USE DATA MINING TO I*. London.
- [19] جامعة السودان للعلوم والتكنولوجيا: الخرطوم بليل الارشاد الاكاديمي. (2012). ا. م, العلمية.