

Data Mining

أروى عيسى الياسري

دكتوراة معلومات ومكتبات/العراق - بغداد
أستاذة جامعية في كلية المتصور الجامعية / قسم
الحاسبات ونظم المعلومات
البريد الإلكتروني :

Arwa_alyasri2005@yahoo.com
arwaissa@hotmail.com

عضو الهيئة الإدارية للجمعية العراقية
لتكنولوجيا المعلومات
عضو في الهيئة العامة للجمعية العراقية
 للمعلومات والمكتبات
عضو الهيئة الإدارية لمركز بغداد لدراسات
حقوق الإنسان

استخراج البيانات

Data Mining (DM)

اتجاه جديد في استرجاع المعلومات

النماذج المهمة والتي تمثل المعرفة يتم تقديرها استناداً إلى مقاييس محددة.

■ **تمثيل المعرفة :** Knowledge Representation 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.
ويمكن ان تتجزء مرحلتين في ان واحد وعلى سبيل المثال يمكن انجاز كل من مرحلة تقييم البيانات ومرحلة توحيد البيانات مع بعضها ويمكن ان تشتهر مرحلة اختيار البيانات مع مرحلة نقل البيانات.
يتضمن استخراج البيانات DM عدد من الأساليب الرئيسية التي يمكن من خلال استخدامها الوصول إلى الهدف من استخدام هذا الإتجاه وهي:

1- قاعدة الارتباط : Association Rule

قواعد الارتباط Associations Rule هي أحد الواجهات الوعادة من Data Mining كأداة من أدوات اكتشاف المعرفة KDD ولديها القدرة على تصفح كميات هائلة من البيانات، وهي تسمح بالتقاط كل القوانين الممكنة التي تشرح بعض الصفات الموجودة اعتماداً على وجود الصفات الأخرى [2].
ويعنى آخر هي قواعد ارتباطية معينة بين مجموعة من البيانات في قاعدة البيانات وتتضمن إيجاد large Item set من خلال المعادلة التالية:

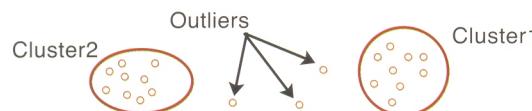
2 → X تتضمن إيجاد درجة الوثوقية لهذا الارتباط.

$$\text{Support} = \frac{\text{The Number of Transactionhat Contains X and Y}}{\text{The Total Number of Transaction}}$$

2- العنقدة : clustering

وهي عملية تقسيم البيانات إلى مجموعة من الأصناف اعتماداً على اشتراكها بالخصائص المشابهة وأن العنقدة هي تقسيم غير موجه للبيانات [3]. وهي عكس التصنيف الذي سيرد لاحقاً، كما أنها تساعد المستفيد على فهم التركيب الطبيعي للمجموعات من البيانات.

$\text{Unsupervised Classification} = \text{Clustering}$
هنا لا نعرف الأصناف ولا عددها.



شكل (1) يبين عملية العنقدة

مع وجود كميات هائلة من البيانات المخزنة في قواعد البيانات data bases ومستودعات البيانات الضخمة warehouses ازدادت الحاجة إلى تطوير أدوات تمتاز بالقدرة لتحليل البيانات واستخراج المعلومات والمعارف منها، ومن هنا ظهر ما يسمى باستخراج البيانات Data Mining كتقنية تهدف إلى استنتاج المعرفة من كميات هائلة من البيانات.

ومن هنا يمكن القول أن تقنية استخراج البيانات DM ما هي إلا اتجاه جديد في استرجاع البيانات Information Retrieval (IR) وخاصة تلك المنشورة على شبكة الإنترنت.

لقد ظهرت العديد من التعريفات لهذا المفهوم ذكر منها التقريب في مجموعة ضخمة من مجلدات البيانات فضلاً عن اكتشاف العلاقات بينها أو الاجابة على الأسئلة المتخصصة التي تكون واسعة جداً عند استخدام أدوات الاستعلام التقليدية(6) أو أنها عملية إستكشاف وتحليل كميات كبيرة من البيانات باستخدام أساليب آلية أو شبه إليه اعتماداً على اكتشاف نماذج وقواعد ذات مغزى (1).

يعد استخراج البيانات Data Mining مرحلة من مراحل اكتشاف المعرفة في قواعد البيانات Knowledge Discovery (KDD) التي تشير إلى استخراج المفاهيم الضمنية غير الاعتيادية والتي لم تكن معروفة سابقاً، وعملية اكتشاف المعرفة في قواعد البيانات Discovery in Database تتضمن عدد من المراحل تبدأ من جمع البيانات الخام إلى مرحلة الحصول على المعرفة الجديدة، (4) وفيما يأتي عرض لهذه المراحل:

■ **تنقية البيانات :** Data Cleaning وهي مرحلة عزل البيانات التي تحتوي على تشويش أو شوائب Noise من مجموعة البيانات.

■ **توحيد البيانات :** Data Integration هذه المرحلة غالباً ما تكون مكوناً من مصادر معالجة البيانات متغيرة العناصر وربما تكون مجتمعة في مصدر شائع.

■ **اختيار البيانات :** Data Selection في هذه المرحلة، يتم تحديد وإسترجاع البيانات الملائمة من مجموعة البيانات .

■ **نقل البيانات :** Data Transformation وهي عملية نقل البيانات التي تم اختيارها إلى شكل ملائم لإجراءات البحث والاسترجاع.

■ **استخراج البيانات :** Data Mining في هذه المرحلة سيتم تطبيق أسلوب ذكي لاستخراج نماذج مفيدة قدر الإمكان.

■ **تقييم النموذج :** Pattern Evaluation بعد استخراج

Data Mining

ال المعلومات وباستخدام خوارزمية Classification - rule learning تم الحصول على أصناف محددة سيتم إتباعها في المستقبل عندما تصل المكتبة مصادر معلومات في هذا الموضوع.

وما زال موضوع تطبيق استخراج البيانات DM في مجال علم المعلومات وتحديداً إسترجاع المعلومات أرضاً بحاجة إلى المزيد من البحث وإجراء التجارب لغرض الحصول على العديد من الموضوعات والأفكار الجديدة التي من شأنها الإرتقاء بمستوى خدمات المعلومات.

المصادر

- 1- Adriaan & P. and D. Zanting. Data Mining . Addison-Wesley Harlow, England, 1996.
- 2- Al-Hamami ,Alaa H., abass F Kader ,Hussein K.Al-khefaji,"Desgin and Implementation of Genererate of large Dense, or sparce Database to test Association rules Miners" (selected reachers papers), Scientific journal of Fedration of Arab Scin- tific Research Council, 2002 .
- 3- Botta, Marco "Clustering Techniques ",Dipartimento di Informatica Universitàdi Torino, www.di.unito.it/~botta/didattica/ clustering.html,2003.
- 4- Fayyad, U., G. Piatetsky-Shapiro,P. Smyth, & R. Uthurusamy, Advance in Knowledge Discovery & Data Mining. Cambridge, MA (The AAAI Press/The MIT Press), 1996.
- 5- Joshi, Karuna Pande . Analysis of Data Mining Algorithms .available at : http://www.
- 6- Michael, J., A. Berry and Gordan S. Linoff, Mastering Data Mining. John Wiley & Sons, Inc, 2000.
- 7- الياسري، أروى عيسى، هديل شوكت العبيدي. تجربة تصميم مكنز آلي بإستخدام أساليب إستخراج البيانات Data Mining بحث غير منشور أقي في مؤتمر بلدية دبي الدولي الثالث للتوثيق والأرشفة الإلكترونية أيلول 2005.
- 8- الياسري، أروى عيسى، هديل شوكت العبيدي. التصنيف الآلي لمصادر المكتبة بإستخدام تقنيات التصنيف Data Mining في إستخراج البيانات Mining بحث غير منشور.

3- التصنيف Classification

يستخدم التصنيف بشكل واسع في حل الكثير من المشكلات خاصة تلك التي تتعلق بالأعمال Business من خلال تحليل مجموعة من البيانات ووضعها على شكل أصناف أو أقسام يمكن استخدامها فيما بعد لتصنيف البيانات المستقبلية.(5) وهنا يمكن الفرق بين التصنيف والعنقادة. وهناك عدد من الطرق التي يمكن استخدامها في تصنیف البيانات باستخدام الخوارزمیات مثل الخوارزمیات الإحصائیة Statistical Alg. و خوارزمیات الشبکات Ge- نیural Network Alg. و خوارزمیات الوراثة- Nearest neighbor و طریقة الجار الأقرب netic Alg. .method

4- التحليل التسلسلي Sequential analysis

في هذه الطريقة يتم البحث لاكتشاف نماذج تحدث بالتسلاسل إذ تكون المدخلات عبارة عن بيانات تشكل مجموعة متسلسلة وكل سلسلة من البيانات هي قائمة منظمة من العمليات أو المصطلحات وعندما تكون العملية عبارة عنمجموعات من المصطلحات لابد أن يحسب معها الوقت المصاحب لكل عملية . (5) ولكن مشكلة هذا النموذج تكمن في إيجاد كل النماذج المتسلسلة مع أقل دعم يخصصه المستفيد عندما يكون الدعم لهذا النموذج هو نسبة تسلسل البيانات التي يتضمنها النموذج.

نماذج تطبيقية في استخدام استخراج البيانات (DM) في علم المعلومات.

نظراً للمزايا التي يمتلكها هذا الاتجاه تم تنفيذ بعض من أساليبه على سبيل التجارب التطبيقية في موضوعات علم المعلومات ومنها تجربة بناء مكنز آلي باستخدام اسلوب clustering قاعدة الارتباط Association Rule والعنقادة (7) إذ وبواسطة الأسلوب الأول تم تحليل مستخلصات large بحوث علمية وتحديد مجموعة المصطلح الكبير Item set وبواسطة الأسلوب الثاني تم تجميع المصطلحات في عناقيد ومنها تم الوصول إلى المصطلحات العريضة والمصطلحات الضيقة والمصطلحات المترابطة وبالنتيجة تم الحصول على مكنز آلي بإستخدام إساليب إستخراج البيانات DM أما التجربة الثانية فكانت تدور حول استخدام أسلوب و خوارزمیات التصنيف المستخدمة في إستخراج البيانات DM لغرض إيجاد طريقة جديدة في التصنيف الآلي لمصادر المعلومات في المكتبات(8). في هذه التجربة تم تحليل مجموعة من البحوث في موضوع تكنولوجيا