
خوارزم مقترن للتنقیب في الويب لتمييز أنماط المستخدمين والتنبؤ بمتطلباتهم

إعداد

أ.د. حمـى الدين إسماعيل موسى

أستاذ الحاسـب الآلي والنـظم المعلوماتـية
كلـيـة التـريـة النـوعـية - جـامـعـة المـنصـورـة

م.م. حـنـان الرـفـاعـي عـبـد القـادـر

مـدرـس مـسـاعـدـ الحـاسـبـ الآـلـيـ
كلـيـة التـريـة النـوعـية - جـامـعـة المـنصـورـة

أ.د. عـطا إـبرـاهـيم إـمامـ الـأـلـفـيـ

أستاذـ الحـاسـبـ الآـلـيـ والنـظمـ المـعـلـومـاتـيـةـ المـتـفـرـغـ
كلـيـة التـريـة النـوعـية - جـامـعـة المـنصـورـة

دـ. نـبـيل عـبـدـ الـأـخـسـنـ أـحـمـدـ مـوـسـىـ

مـدرـسـ الحـاسـبـ الآـلـيـ
كلـيـة التـريـة النـوعـية - جـامـعـة المـنصـورـة

مـجـلـة بـحـوثـ التـريـةـ النـوعـيةـ - جـامـعـةـ المـنصـورـةـ

عـدـدـ (٣٣)ـ - يـاـئـيرـ ٢٠١٤ـ

* بـحـثـ مـسـتـلـ مـنـ رـسـالـةـ دـكـتـورـاهـ

خوارزم مقترن للتنقيب في الويب لتمييز أنماط المستخدمين والتنبؤ بمتطلباتهم

إعداد

أ. د. محى الدين اسماعيل موسى^{**}

أ. د. عطا إبراهيم إمام الألفي^{*}

م. م. حناز الرفاعي عبد القادر^{****}

د. نبيل عبد الحسن أحمد موسى^{***}

مقدمة :

تعتبر شبكة المعلومات العالمية World Wide Web أكبر مستودعات الوثائق المعروفة، ومنذ بدايتها تتزايد كمية البيانات بمعدل كبير، ومع هذا النمو الهائل تزداد صعوبة وصول المستخدم لمعلومات التي يحتاج إليها، كما تزداد صعوبة تصنيف وفهرسة تلك المعلومات الأمر الذي يجعل استعراض كل النتائج مضيعة لوقت المستخدم (Anthony. S, 2005, 20). وترجع ضخامة حجم المعلومات الموجودة على الشبكة إلى الحرية في تأليف ونشر المحتوى وعدم وجود سلطة تحكم أو تسيطر على نشر المعلومات على الانترنت مما أدى إلى زيادة حجم المعلومات وتكرارها، وبسبب هذا فإنه على خلاف قواعد البيانات العلائقية فإن المعلومات على الويب ضعيفة البنية (Derar. H, 2009, 35).

وتلعب نظم تكامل المعلومات Information Integration Systems مثل محركات البحث دوراً هاماً في جعل هذا الكم الهائل من المعلومات قوي البنية وسهل الوصول إليه بسهولة وبشكل أكثر فائدة ورغم نجاح تلك الأنظمة في معالجة العديد من التحديات إلا أنها ما زالت تواجه العديد من القيود، خاصة عند استخراج واستكمال المحتوى من قواعد بيانات الويب التي تكتمن وراء واجهات البحث، ولمعالجة تلك القضايا لابد من توجيهه أنظار الباحثين إلى الاهتمام بتقنيات التنقيب في الويب Web Mining ك المجال هام للبحث والدراسة (Zhongming. M, 2007, 23).

ويعد التنقيب في الويب Web Mining أحد تطبيقات تعلم الآلة Machine Learning على بيانات مبنية على الويب من أجل التعلم واستخراج المعرفة. التنقيب في الويب يمكن تصنيفه إلى ثلاث تصنيفات مميزة وهي التنقيب في استخدام الويب Web Usage Mining، التنقيب في بنية الويب Web Structure Mining، والتنقيب في محتوى الويب Web Content Mining (G, 2007, 18).

* أستاذ الحاسوب الآلي والنظم المعلوماتية المتفرغ كلية التربية النوعية - جامعة المنصورة

** أستاذ الحاسوب الآلي والنظم المعلوماتية كلية التربية النوعية - جامعة المنصورة

*** مدرس الحاسوب الآلي كلية التربية النوعية - جامعة المنصورة

**** مدرس مساعد الحاسوب الآلي كلية التربية النوعية - جامعة المنصورة

خوارزم مقترح للتنقيب في الويب لتمييز أنماط المستخدمين والتنبؤ بمتطلباتهم

ويتعامل نظام التنقيب في الويب مع البيانات المدخلة من خلال ثلاث مراحل مختلفة حتى تصل إلى النتيجة النهائية، وتمثل تلك المراحل في مرحلة ما قبل المعالجة Pre-processing، مرحلة التنقيب في البيانات Data Mining، مرحلة بعد المعالجة Post Processing. عندما تكون البيانات مدخلة في نظام التنقيب في البيانات فإن مرحلة ما قبل المعالجة تصبح ضرورية لنقل البيانات الخام إلى صيغة مقبولة وتلك المرحلة ربما تشمل تقليل الحقول غير المرتبطة وتنقية البيانات من المعلومات المشوهة Noisy Information وهذه الخطوة ضرورية جداً حيث أن صفحات الويب تحتوي على نسبة عالية من المعلومات المشوهة (John.L, Michel V, 2007, 54-55).

مشكلة البحث:

يتميز هذا العصر بالتغييرات السريعة الناجمة عن التقدم العلمي والتكنولوجي وتقنية المعلومات، لذا تهتم المؤسسات التعليمية دائمًا بالحديث في مجال تكنولوجيا المعلومات والإنترنت حيث أنها تعتمد بصورة كبيرة حالياً على شبكة الإنترنت وخدماتها في التعامل مع المعلومات ونقلها من جهة إلى أخرى، خاصة بعد التطور الهائل في مجال التعليم الإلكتروني والإدارة الإلكترونية.

فعلى سبيل المثال وليس الحصر فجامعة المنصورة تعتمد في عملها على الإدارة الإلكترونية والتعليم الإلكتروني وهناك العديد من النظم الإلكترونية التي تستخدمنا مثل (نظام ابن الهيثم لإدارة الدراسات العليا، نظام المستقبل لإدارة المكتبات، نظام الحسابات الخاصة، نظام الموارنة العامة لجامعة المنصورة، نظام حفظ المستندات لجامعة المنصورة، نظام الأمين لإدارة المخازن والمعهد، نظام التصحيح الإلكتروني)، كذلك قامت بتحويل العديد من المقررات إلى مقررات تعليم إلكتروني.

وتعتمد أنظمة الإدارة الإلكترونية وبرامج التعليم الإلكتروني في المقام الأول على استخدام شبكة الانترنت وتبادل كم هائل من المعلومات بينها، عن طريق موقعها الذي يقدم خدماته لجميع مستخدمي الموقع سواء من داخل الحرم الجامعي أو من خارجه فإنه تعتبرها ساعات ذروة نظراً لكثرة مستخدمي الموقع وكذلك ضخامة حجم البيانات المرتبطة بالموقع مما قد يتسبب في مجموعة من المشكلات مثل تعذر الدخول إلى الموقع أو الدخول ولكن لا يتم تفويت بعض متطلبات المستخدم كتحميل البرامج والأنظمة المستخدمة. الأمر الذي يتطلب مساعدة المستخدمين لتخفيف العبء عن الموقع عن طريق استخدام تقنيات جديدة مثل تقنيات التنقيب في الويب للمساعدة في حل تلك المشاكل. ومن ثم فالمؤسسات التعليمية تفتقد لنظم التنقيب في الويب لتمييز أنماط المستخدمين والتنبؤ بمتطلباتهم لتحسين أداء الواقع الإلكتروني، وبالتالي يمكن صياغة مشكلة البحث في التساؤل الرئيسي التالي:

كيف يمكن بناء نظام تنقيب في الويب لتمييز أنماط المستخدمين والتنبؤ بمتطلباتهم لتحسين أداء الواقع الإلكتروني؟

ويتفرع من هذا السؤال الرئيسي التساؤلات الفرعية التالية:

١. ما الخوارزميات المستخدمة للتنقيب في الويب؟

٢. كيف يمكن تمييز أنماط مستخدمي الواقع الإلكتروني إلى فئات متشابهة؟

٣. كيف يمكن التنبؤ بمتطلبات مستخدمي الواقع الالكتروني؟

٤. كيف يمكن تحسين أداء الواقع الالكتروني باستخدام تقنيات التنقيب في الويب؟

أهداف البحث:

١. التعرف على أهم الاتجاهات الحديثة في مجال التنقيب في الويب.

٢. تحديد أساس تصميم وبناء نظم التنقيب في الويب.

٣. التعرف على نوعية البيانات التي يمكن استنباط معرفة منها وتصنيفها طبقاً لاهتمامات مستخدمي موقع جامعة المنصورة.

٤. بناء خوارزم مقترن للتنقيب في الويب.

٥. توفير نظام تنقيب في الويب لمميز أنماط المستخدمين والتنبؤ بمتطلباتهم لتحسين أداء الواقع الالكتروني.

٦. التعرف على مدى الاستفادة من استخدام النظام المقترن في تحسين أداء الواقع الالكتروني.

أهمية البحث:

١. توجيه أنظار الباحثين إلى الاهتمام بتقنيات التنقيب في الويب كمجال هام للبحث والدراسة.

٢. تقديم تقنية جديدة مقترنة تعمل على تحسين عملية التنقيب في موقع الويب لتقليل التحميل الزائد على الواقع الالكتروني لتوفير وقت وجه المستخدم.

٣. توفير خوارزم تنقيب في الويب لمميز أنماط المستخدمين والتنبؤ بمتطلباتهم لتحسين أداء الواقع الالكتروني يمكن استخدامه في تطوير نظم مشابهة.

منهج البحث:

يتبع البحث منهجين هما:

١. المنهج الوصفي: ويرتبط مفهوم المنهج الوصفي بتوضيح واقع الأحداث ولا يتوقف عند وصف الواقع على تقرير حقيقة الحاضرة كما هي، بل يتناولها بالتحليل والتفسير لغرض الاستنتاج لتصحيح الواقع أو تحديده أو استكماله (محمد زياد حمدان، ١٩٩٩، ٦٦). وقد استخدم المنهج الوصفي لمعالجة الإطار النظري الخاص بالبحث من خلال وصف وتفسير وتحليل المفاهيم الخاصة بالتنقيب في الويب وكذلك تميز الأنماط من أجل تحسين أداء الواقع.

٢. المنهج التجريبي: لتصميم وإنتاج نظام تنقيب في الويب لمميز أنماط المستخدمين والتنبؤ بمتطلباتهم، وقياس فاعليته في تحسين أداء الواقع الالكتروني.

أدوات البحث:

١. خوارزم مقترن للعنقدة (Clustering).

٢. خوارزم مقترن للتصنيف (Classification) واستخلاص القواعد (Rules Extraction).

مصطلحات البحث:

١. التنقيب في الويب Web Mining:

يعرفه (Anthony Scime, 2005,20) على أنه الانتقال بشبكة المعلومات العالمية تجاه بنية أكثر فائدة حيث يستطيع المستخدمين إيجاد المعلومات التي يحتاجون إليها بسرعة وسهولة. وهو يتضمن استكشاف وتحليل البيانات، الوثائق والوسائط المتعددة من شبكة المعلومات العالمية. وتستخدم تلك التقنية محتويات الوثائق، بنية الروابط الفائقة واستخدام الإحصائيات لمساعدة المستخدمين في تلبية احتياجاتهم من المعلومات.

ويعرف البحث الحالي التنقيب في الويب بأنه "عملية اكتشاف وتحليل واستخراج المعلومات المفيدة من شبكة المعلومات العالمية من أجل تقديم خدمة أكثر سرعة وكفاءة".

٢. تمييز الأنماط Pattern Recognition

يعرفه (Richard . D, and et al., 2001, 35) بأنه عملية تصنيف البيانات إلى مجموعة من الفئات إما على أساس معرفة مسبقة أو على المعلومات الإحصائية المستخرجة من الأنماط، البيانات المصنفة عادة ما تكون مجموعات من القياسات أو الملاحظات.

٣. ملف دخول المستخدم Log file

يعرفه (Vel'asquez, J. D., Palade V., 2008) بأنه ملف يستخدم لتسجيل كافة بيانات المستخدم خلال إبحاره داخل الموقع وتستخدم تلك البيانات لاستخراج معرفة وأنماط تساعد على تلبية متطلبات المستخدمين.

٤. العنقود (التجميع Clustering)

يعرفه (Hannah, H., Thangavel, K., 2009, 3) بأنها تقنية لجمع مجموعة العناصر التي تمتلك صفات متشابهة في مجموعة واحدة. والعنقود هو مجموعة من العناصر المتشابهة فيما بينها، وغير مشابهة للعناصر المنتسبة إلى عناقيد أخرى.

٥. التصنيف

يعرفه (Kamber,M . and Han, J.(2006) عملية ربط عنصري بيانات بأحد الفئات المعرفة مسبقا وقد تشير إلى العملية التي يتم بها التعرف على الأفكار والأشياء متباعدة ومفهومة. خوارزميات التصنيف الأكثر شيوعا هي شجرة القرارات والشبكات العصبية. وهناك أيضاً أساليب أخرى لاستخراج أنماط الاستخدام من سجلات ويب.

دراسات سابقة:

١ - دراسة (David. S, Antonio. M, 2005) بعنوان "تقنيات التنقيب في الويب من أجل الاستكشاف الآوتوماتيكي للمعرفة الطبية" استهدفت هذه الدراسة توضيح أهمية شبكة المعلومات العالمية كأداة حيوية للباحثين ومهندسي المعلومات والشركات الطبية والممارسين من أجل استخراج المعرفة. فتقترح هذه الدراسة طريقة آوتوماتيكية ومستقلة من أجل استخراج التصنيفات من

المصطلحات على الويب وتقدم وثائق الويب المسترجعة بترتيب ذو مغزى. كما قدمت هذه الدراسة طريقة جديدة لاكتشاف المرادفات والـ lexicalization والناتج التي تم التوصل إليها كانت مفيدة جداً لتسهيل عملية الوصول إلى مصادر الويب في أي مجال طبي أو عروض Ontological .

٢- دراسة (Srivastava. J , et al, 2005) بعنوان "التنقيب في الويب - المفاهيم والتطبيقات واتجاهات البحث". استهدفت الدراسة توضيح أهمية استخراج معلومات ذات قيمة من الويب وأن تقنيات التنقيب في البيانات لاستخراج المعرفة من المحتوى ، والبنية والاستخدام هو تجميع لمجموعة من التكنولوجيات لتحقيق تلك الإمكانيّة. وأن الاهتمام بمجال التنقيب في الويب قد نمى بسرعة في مجالات البحث والمجالات الاجتماعية الأخرى. فتقدّم هذه الدراسة ملحة مختصرة عن الانجازات في هذا المجال سواء من حيث التقنيات والتطبيقات وبحسب التوجهات الرئيسيّة للبحث في بحوث المستقبل. وتوصّلت هذه الدراسة إلى أهمية تحليل البيانات واستخراج جميع أنواع المعرفة المفيدة منه. وتوصّلت الدراسة أيضاً إلى وصف مساهمات العملية الأساسية للحاسوب التي ساهمت في نمو هذا المجال وتطوره.

٣- دراسة (Lan.Y, Bing. L, 2006) بعنوان "تقنية صفحة الويب للتنقيب في الويب خلال وزن الحقول".

استهدفت هذه الدراسة إيضاح أنّة على خلاف البيانات التقليدية أو النصية فإن صفحات الويب تحتوي على كمية كبيرة من المعلومات والتي لا تعتبر جزء من المحتويات الرئيسية لتلك الصفحات مثل أشرطة الإبحار، الإعلانات ، ومعلومات حقوق النشر، هذه المعلومات غير زي علاقة وتسمى ضوضاء صفحة الويب^{noise} Web page noise مثل العقدة Clustering والتصنّيف Classification. تقترح هذه الدراسة تقنية جديدة لوزن الحقول Feature Weight للتعامل مع ضوضاء صفحة الويب من أجل تحسين التنقيب في الويب. هذه الطريقة تنشئ ما يسمى شجرة التركيب المضغوطة Compressed Structure Tree وتقوم باستخدام المعلومات البنية على القياس لتقييم أهمية كل عقدة node في شجرة التركيب المضغوطة. وبناء على الشجرة وأهمية قيم عقدها فإن تلك التقنية تخصص وزن لكل حقل في كل محتوى. الأوزان الناتجة تستخدم في التنقيب في الويب ويتم تقييم التقنية المقترنة عن طريق مهمتين للتنقيب في الويب هما: عقدة صفحة الويب Web Page Clustering - تصنّيف صفحة الويب Classification . وتوصّلت النتائج إلى أن طريقة القياس المستخدمة في الدراسة استطاعت أن تحسن نتائج التنقيب بشكل ملحوظ.

٤- دراسة (David. J, et al 2007) بعنوان (التنقيب المرئي للويب) تتضمن تحليل بيانات استعمال موقع الويب تحديين هامين: أولاً حجم البيانات الناشئ عن نمو الويب، وثانياً، التعقيد الهيكلي لموقع الويب استهدفت الدراسة تطبيق تقنيات التنقيب في البيانات والمعلومات المرئية إلى مجال الويب لكي يستفيد من قوة كل من فهم الرؤية البشرية واستعمال الحاسوبات نعّين هذا التنقيب في الويب البصري رداً على التحديين حيث تطبق تقنيات التنقيب في البيانات إلى مجموعات

خوارزم مقترن للتنقيب في الويب لتمييز أنماط المستخدمين والتتبُّع بمتطلباتهم

بيانات الويب الضخمة وتستهدف الدراسة تلخيص التقنيات المستخدمة، وتستخدم أساليب تصوّر المعلومات على النتائج. الهدف هو ربط نتائج التنقيب في تسجيلات استخدام الويب وبنية الويب المستخرجة عن طريق تركيب النتائج بشكل بصري. وقترح الدراسة مجموعة من تخطيطات المعلومات المرئية الجديدة وتحليل أدواتهم والتحكم في بنية نموذج التطبيق.

٥- دراسة (Cheng. Y, et al, 2009)عنوان "تقنيات التنقيب في الويب لتسويق الكتب على الانترنت"

استهدفت الدراسة توضيح للعملاء المحتملين للكتب على الانترنت عن طريق تنقيب محتوى الويب. فهذه الدراسة أولاً تقوم بعمل قائمة من العلماء الذين يرتبط مجال بحثهم في تكنولوجيا المعلومات، ثم بعد ذلك يتم استخدام محرك البحث لحساب عدد صفحات الويب المرتبطة بخبرة العلماء. هذه البيانات يتم معالجتها قليلاً بواسطة ثلاث خطوات رئيسية قبل استخدامها وهي:

١. ترشيح أو فرز البيانات الغير طبيعية.
٢. تطبيق البيانات Normalizing Data
٣. توليد البيانات الثانية.

تم استخدام تحليل الارتباط والتحليل العنقودي الهرمي وذلك لتوليد عينة العلماء وخبرتهم من أجل اختبار دقة استخدام التنقيب في الويب للتتبُّع بالعلماء المهتمين بقوائم الكتب. وتوصلت النتائج إلى أن معدل الدقة لقوائم الكتب الموصى بها هام من الناحية الإحصائية.

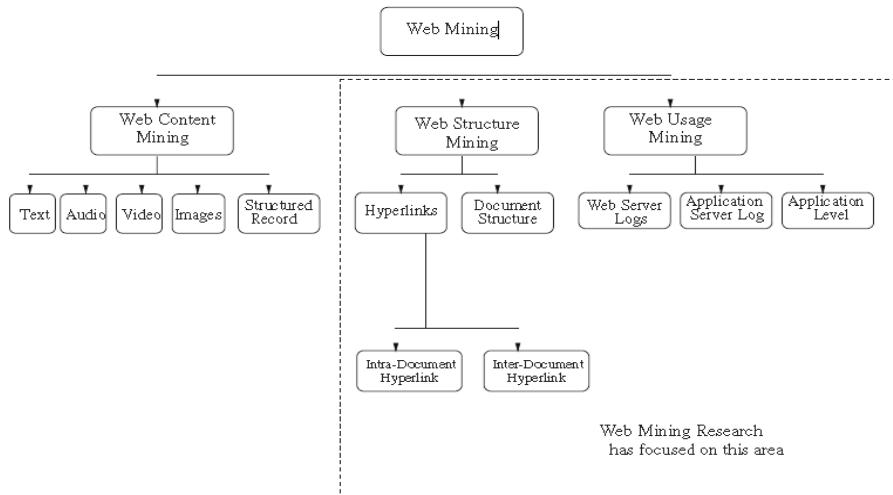
٦- دراسة (Tuncay. S, Necmi. D, Zafer. C, 2010)عنوان "التنقيب في الويب وبائيات التعلم الافتراضية"

استهدفت هذه الدراسة توضيح أن البيانات التعليمية تنقسم إلى شكلين أساسين هما (بيئات التعلم التقليدية، بيئات التعلم الافتراضية). ويوجد مشاكل في تلك البيانات تشمل مشكلة التقييم وتحليل السلوك. ففي التعليم التقليدي تحليل السلوك يتم بسهولة من خلال أساليب الملاحظة بينما في التعليم الافتراضي فإن تحليل اتجاهات الطلاب وسلوكياتهم مشكلة هامة. تطبيقات التنقيب في الويب تستخدم في إعطاء معلومات ذات معنى من خلال سلوكيات غير ذات مغزى. التجول داخل بيئات الويب هي الوسيلة للتغلب على تلك المشاكل. وأشارت هذه الدراسة أن تطبيقات التنقيب في الويب في بيئات التعلم الافتراضية شكلت توافق مع طريقة البحث الوصيفية ونتيجة لذلك تم إدخال التنقيب في الويب في بيئات التعلم.

الإطار النظري:

تصنيف التنقيب في الويب

ويمكن تقسيم التنقيب في الويب إلى ثلاثة فئات متميزة، وفقاً لأنواع البيانات التي يمكن التنقيب فيها. ويمكن أيضاً ملاحظة موجزة عن الفئات الثلاث في الشكل التالي (Rathod, D. (2012):



شكل (١) تصنیف التنقیب في الويب

التنقیب في محتوى الويب (WCM)

هو عملية استخراج معلومات مفيدة من محتويات مستندات ويب، ويمكن أن تتألف من النصوص والصور والصوت والفيديو، أو سجلات منظمة مثل القوائم والجداول. ويمكن معاملة التنقیب في محتوى الويب كامتداد لمحرك البحث الأساسي (Search Engine). معظم محركات البحث تعتمد على الكلمة المفتاحية. في حين أن التنقیب في محتوى الويب يمتد إلى تكنولوجيا استرجاع المعلومات التقليدية (IR) من خلال بناء المفاهيم الهرمية، واستخراج ملفات تعريف المستخدمين وتحليل الروابط بين صفحات الويب Taherizadeh, S., Moghadam N. 2009).

التنقیب في بنية الويب (WSM)

هو العملية التي من خلالها نكتشف نموذج لبنية روابط صفحات الويب. وتوليد المعلومات مثل التشابه وال العلاقات فيما بينها من خلال الاستفادة من الارتباط الشعبي. فيتم فهرسة الروابط، وتوليد المعلومات مثل التشابه Similarity وال العلاقات فيما بينها. يهدف التنقیب في الويب إلى ملخص هيكلی لنوع وصفحات الويب (Jain,R. Purohit, G. N., 2011, 0975 – 8887).

التنقیب في استخدام الويب (WUM)

التنقیب في استخدام شبكة الويب هو عملية تطبيق تقنيات التنقیب في البيانات لاكتشاف أنماط السلوك على أساس البيانات المبنية على شبكة الإنترن特، مختلف التطبيقات (Kohavi, R. and Parekh, R, 2003

مراحل التنقيب في استخدام الويب

يوفر التنقيب في استخدام الويب مدخلاً لجمع وتجهيز البيانات على شبكة الإنترنت، ويبني نموذج يمثل سلوك المستخدمين ومتطلباتهم. ويكون التنقيب في استخدام الويب من المراحل الأساسية التالية (Gutschmidt, A., et al, 2008) :

١- جمع البيانات .Data collection

٢- معالجة البيانات .Data preprocessing

٣- اكتشاف الأنماط .Pattern discovery

٤- تحليل الأنماط .Pattern analysis

١- جمع البيانات .Data collection

جمع البيانات مهمة ضرورية في أي تطبيق لاستخراج البيانات وخلق مجموعة بيانات ذات هدف مناسب. قد تشمل عملية ما قبل معالجة البيانات الأصلية، ودمج البيانات من مصادر متعددة، وتحويل البيانات إلى شكل مناسب للاستخدام في عمليات تنقيب بيانات محددة. يتم جمع البيانات من خوادم الويب Web Servers، من العمالء المتصلين بالخادم، أو من مصادر وسیطة مثل خوادم بروكسي proxy servers (Dunham,H., 2003)

٢- معالجة البيانات Data preprocessing

تهدف معالجة سجل دخول الويب (Log File) إلى إعادة تهيئة تسجيلات الدخول الأصلية لتحديد جميع جلسات (Sessions) الوصول إلى شبكة الإنترنت. خادم الويب عادة يسجل أنشطة دخول كافة المستخدمين للموقع وسجلات خادم الويب logs. هناك العديد من أنواع سجلات الويب ويوجد العديد من المهام التي يتبعن القيام بها على سجلات خادم الويب قبل تنفيذ خوارزميات التنقيب على الويب. وتشمل تلك المهام، تنقية البيانات data cleaning، تعريف المستخدمين، تمييز المستخدمين User differentiations session identification، تحديد الجلسات session identification Ling Zheng, et al, 2010, VI-19-VI-21.). سجلات الدخول الأصلية يتم تنقيتها، إعادة تهيئتها، ومن ثم تجميعها في مجموعات ذات معنى قبل أن يتم استخدامها من قبل التنقيب في استخدام الويب (SubMasthan, T., et al.. 2012, 307-312).

٢.١ مكونات ملف الدخول Log File:

يتكون ملف دخول المستخدم من مجموعة من العناصر مثل رقم العنوان Ip adress ، وهو رقم الجهاز الذي يتم الدخول على الموقع من خلاله، اسم العميل Client name وهو اسم المستخدم في حالة وجود حماية بكلمة سر، الوقت والتاريخ Time stamp وهو وقت وتاريخ الزيارة كما يتم رؤيتها من خادم الويب، access request ويشمل اسم الرابط الذي تم طلبه والبرتوكول المستخدم، رابط المرجع Refferr Url ويشير إلى الرابط المصدر الذي تم الدخول من خلاله ، وكيل المستخدم User Agent ويشمل الوكيل أو المستعرض المستخدم في التصفح ول يكن الانترنت

V.)Vel'asquez, J. D., Palade (Mozilla Internet explorer أو موزيلا) 2008

٣- اكتشاف الأنماط **Pattern discovery**

في تلك المرحلة يتم اكتشاف الأنماط التي تكون مطلوبة من أجل تخصيص الويب والتي تستجيب لسلوك واهتمامات المستخدمين، يتم اكتشاف المعرفة عن طريق تطبيق العديد من التقنيات مثل العنقده (التجمیع) Clustering ، التصنیف Classification، قواعد الارتباط (Kiruthika, M.(2011)(sequential Association Rules) واكتشاف النمط المتسلسل pattern discovery.

٣.١ العنقدة أو التجمیع **Clustering**

يمكن أن تتم العنقدة في مجال التنقیب في استخدام الويب على المستخدمين user clusters، عنقدة الصفحة page clusters وعنقدة الجلسات sessions clusters من ملف الدخول. عنقدة المستخدمين تهدف إلى إنشاء مجموعات من المستخدمين يمتلكون اهتمامات مشتركة بناء على سلوكهم على الموقع. وعلى الجانب الآخر عنقدة الصفحات تكتشف مجموعات من الصفحات تمتلك محتويات متشابهة من أجل تحسين محركات البحث search engines في الويب. بالإضافة إلى ذلك يمكن أن تطبق العنقدة على الجلسات sessions حيث كل منها يمكن أن يعرض موضوع واحد هام خلال الموقع (Suresh, K.,et al.,(2011).

٣.٢ التصنیف **Classification**

يكون الاهتمام في مجال الويب بتطوير الملف الشخصي Profile للمستخدمين المنتسب لفئة معينة. وهذا يتطلب تحديد واستخراج السمات features التي تصف خصائص الفئة المعطاة بأفضل ما يمكن. يمكن القيام بالتصنیف عن طريق باستخدام العديد من التقنيات مثل شجرة القرارات Support Vector classifier ، K-nearest neighbor classifier ، decision tree .Machine الخ (Usama Fayyad, et al,(2009).

٤- تحلیل الأنماط **Pattern analysis**

تحليل الأنماط هو آخر مرحلة من مراحل التنقیب في الويب والهدف وراء تلك المرحلة هو فرز القواعد rules أو الأنماط patterns الغير هامة من مجموعة الأنماط التي تم الحصول عليها في مرحلة اكتشاف الأنماط.

الإطار التطبيقي:

أولاً تصميم وبناء الخوارزم المقترن:

١- ماهية الخوارزم المقترن:

يعتمد النظام المقترن على خوارزمين هما:

- خوارزم مقترح للعنقoda clustering algorithm: وذلك لتجزئة مصفوفة جلسات العمل sessions التي تم إنشاؤها في مرحلة المعالجة وتحويلها إلى مكونات متراقبة (عناقيد clusters) ولتحديد المكونات المتراقبة وتخصيصها لعنقود (cluster).
- خوارزم مقترح للتصنيف Classification: وذلك لتصنيف الصفحات إلى أحد المجموعات Clusters التي تم تحديدها مسبقا.

-٢ مراحل الخوارزم المقترح:

يمر الخوارزم المقترح بمجموعة من الخطوات، يتم توضيحها كما يلي:

1. مرحلة جمع البيانات Data Collection : في هذه المرحلة، بيانات المستخدم تم تسجيلاها في ملف الدخول log file يستخدم في متابعة سلوك المستخدم خلال الإبحار في الموقع وبيانات جلسات العمل Sessions ويكون من الجدول التالي:
 - جدول مصفوفة الصفحات Page_array table : يتبع سلوك المستخدم خلال الإبحار في تسجيلات دخول الموقع (رقم المستخدم user_id - رقم الجلسة session_id - الرابط المطلوبة Urls - والوقت المستغرق timestamp).

جدول (١) جدول دخول الصفحات

جدول : pagearray				
session_id	user_id	pagearray	date	
hyjy5m5rbx	eng_s	p1,p2,p3,p4,p7,p8,p10	8/21/2012 7:22:07 PM	
hjuj1pekip45	dr_hamdy	p1,p3,p4,p5,p6,p7,p10	7/25/2012 11:59:03 AM	
bh45lktel13z	i_risho	p2,p3,p4,p6,p7,p9	7/16/2012 12:09:50 AM	
se453s2z34nq	dr_hamdy	p1,p3,p4,p5,p6,p8,p10	7/15/2012 11:09:01 PM	
kyvxgagf51z2	dr_hamdy	p1,p5,p7,p8,p10	7/15/2012 7:33:03 PM	
ueebtp24faje	i_risho	p2,p3,p6,p9	7/15/2012 6:11:12 AM	
sl45lc4xwemm	i_risho	p2,p3,p5,p6	7/14/2012 6:01:19 PM	
rdgra55lt45vey	i_risho	p2,p3,p5,p8	7/13/2012 2:21:18 PM	
eor45hof4s445	dr_hamdy	p3,p5,p7,p8,p10	7/12/2012 8:01:12 AM	
umhea5ua555	i_risho	p3,p5,p7,p10	6/20/2012 9:05:40 PM	

2. معالجة البيانات Data Preprocessing: تشمل هذه المرحلة تنقية البيانات cleaning، تحديد الجلسة session identification بناء مصفوفة علاقة التشابه بين Sessions Similarity.

- البيانات Data Cleaning، تحديد الجلسة session identification: وتم عملية تنقية ملف الدخول log file حيث يتم تحديد مصفوفة صفحات الجلسات sessions فخلال الإبحار المستخدم يقوم النظام بتسجيل الطلبات requests ويبنى مصفوفة من الصفحات

والجلسة sessions_pages session). هذه المصفوفة تتكون من كل الصفحات التي تم الوصول إليها بواسطة المستخدم خلال الجلسة session ويتم تخزين تلك المصفوفة في جدول يسمى array_page فيتم تحويل البيانات في ملف الدخول إلى شكل ثنائي (٠،١) حيث أن الموقع يتكون من ١٠ صفحات (p1-p10) والتعامل مع sessions من s1-s10 حيث يتم إعطاء الصفحة التي تم الدخول عليها القيمة (١) والصفحة التي لم يتم الدخول عليها القيمة (٠) كما هو موضح بالجدول (٢) والعمود الأخير (Count) يدل على عدد الصفحات التي تم الدخول عليها.

جدول (٢) مصفوفة الصفحات وجلسات العمل

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Count
s1	1	1	1	1	0	0	1	1	0	1	7
s2	1	0	1	1	1	1	1	0	0	1	7
s3	0	1	1	1	0	1	1	0	1	0	6
s4	1	0	1	1	1	1	0	1	0	1	7
s5	1	0	0	0	1	0	1	1	0	1	5
s6	0	1	1	0	0	1	0	0	1	0	4
s7	0	1	1	0	1	1	0	0	0	0	4
s8	0	1	1	0	1	0	0	1	0	0	4
s9	0	0	1	0	1	0	1	1	0	1	5
s10	0	0	1	0	1	0	1	0	0	1	4

بـ: بناء مصفوفة علاقة التشابه بين الجلسات Sessions Similarity: بعد تحديد مصفوفة session_page، تستخدم لبناء مصفوفة sessions معرفة عدد المواقع. وكل (s1,s2) تقيس التشابه بين s1 و s2 وبعضها عن طريق المعاشرة التالية:

$$Sim = \begin{cases} 1 & P_m(s_i) = P_m(s_j) = 1 \\ & \text{Otherwise} \end{cases}$$

Where:

$$m=1,\dots,n$$

$$i=1,\dots,n$$

$$j=j+i \text{ and } j>0$$

$$\text{Simllarty}(S_i, S_j) = \frac{\sum_{m=1}^{n1} Sim(P_m)}{\text{Max}(\sum_{m=1}^{n1} P_m(S_i), \sum_{m=1}^{n1} P_m(S_j))}$$

Where:

$S_i, S_j \rightarrow$ Sessions

$P_m \rightarrow$ Pages

ليكون الناتج كما هو موضح بالجدول التالي:

جدول (٢) مصفوفة علاقـة التشابه بين الجلسات

	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8	S_9	S_{10}
S_1	1	0.71	0.57	0.71	0.571	0.29	0.286	0.43	0.57	0.429
S_2	0.71	1	0.57	0.86	0.571	0.29	0.429	0.29	0.57	0.571
S_3	0.57	0.57	1	0.43	0.167	0.67	0.5	0.33	0.33	0.333
S_4	0.71	0.86	0.43	1	0.571	0.29	0.429	0.43	0.57	0.429
S_5	0.57	0.57	0.17	0.57	1	0	0.2	0.4	0.8	0.6
S_6	0.29	0.29	0.67	0.29	0	1	0.75	0.5	0.2	0.25
S_7	0.29	0.43	0.5	0.43	0.2	0.75	1	0.75	0.4	0.5
S_8	0.43	0.29	0.33	0.43	0.4	0.5	0.75	1	0.6	0.5
S_9	0.57	0.57	0.33	0.57	0.8	0.2	0.4	0.6	1	0.8
S_{10}	0.43	0.57	0.33	0.43	0.6	0.25	0.5	0.5	0.8	1

٣. اكتشاف الأنماط Pattern Discovery : لاكتشاف الأنماط يتم استخدام خوارزم العنقدة clustering algorithm وذلك لتجزئة مصفوفة الجلسات sessions التي تم إنشاؤها في مرحلة المعالجة وتحويلها إلى مكونات متراقبة (عنقود clusters) وتحديد المكونات المتراقبة وتخسيصها لعنقود cluster باستخدام threshold وذلك لتنقية الروابط الضعيفة بين sessions حيث تم تنقية وفرز الروابط بين sessions عند threshold = 0.6 كما

هو بالجدول التالي:

جدول (٤) الجلسات ذات الارتباط المرتفع

<i>S10</i>	<i>S1</i>	<i>S2</i>	<i>S3</i>	<i>S4</i>	<i>S5</i>	<i>S6</i>	<i>S7</i>	<i>S8</i>	<i>S9</i>	<i>S10</i>
0	1	0.71	0	0.71	0	0	0	0	0	0
0	0.71	1	0	0.86	0	0	0	0	0	0
0	0	0	1	0	0	0.67	0	0	0	0
0	0.71	0.86	0	1	0	0	0	0	0	0
0	0	0	0	0	1	0	0	0	0.8	0
0	0	0	0.67	0	0	1	0	0	0	0
0	0	0	0	0	0	0.75	1	0.75	0	0
0	0	0	0	0	0	0	0.75	1	0	0
0.8	0	0	0	0	0.8	0	0	0	1	0.8
1	0	0	0	0	0	0	0	0	0.8	1

ومن خلال الجدول السابق يمكن استخلاص ثلاث مجموعات Clusters حيث تشمل المجموعة الأولى (*s1,s2,s4*) ، المجموعة الثانية (*s3,s6,s7,s8*) ، المجموعة الثالثة (*s5,s9,s10*). كما هو موضح بالجدول التالي:

جدول (٥) المجموعات التي تم اكتشافها

Cluster1	<i>S1</i>	<i>S2</i>	<i>S4</i>	
Cluster2	<i>S3</i>	<i>S6</i>	<i>S7</i>	<i>S8</i>
Cluster3	<i>S5</i>	<i>S9</i>	<i>S10</i>	

٤. استخراج القواعد Rules Extraction وتنستخدم عن طريق استخدام خوارزم لتصنيف الصفحات بناء على المجموعات Clusters التي تم الحصول عليها. فمن خلال إضافة كل مجموعة Cluster كهدف للجسسة session الذي ينتمي إليها كما هو مبين بالجدول التالي فعلى سبيل المثال ينتمي *s1* إلى Cluster1 و *s3* إلى Cluster2 مع تكرار الخطوات السابقة.

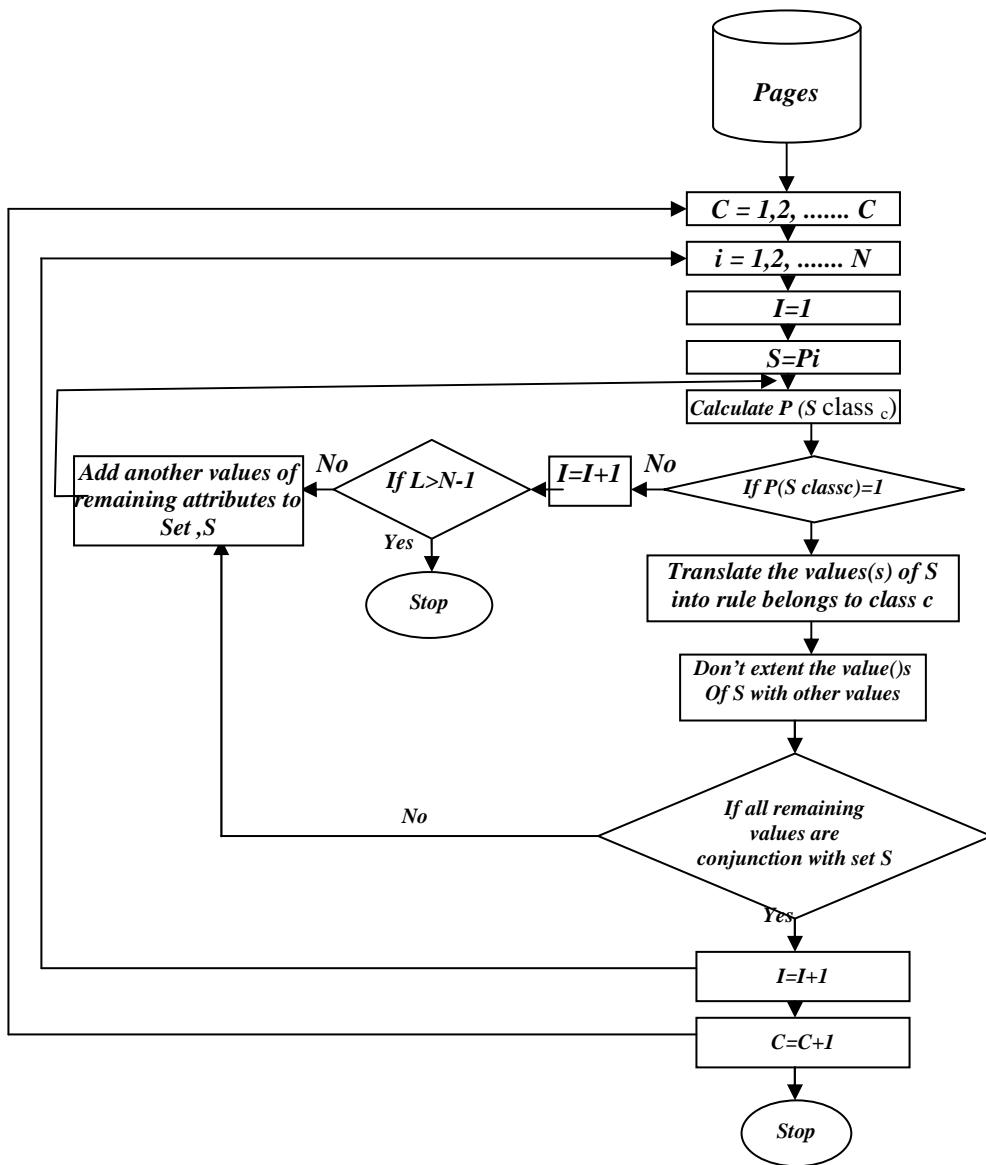
جدول (٦) الجلسات بعد إضافة المجموعات كهدف لاستخلاص القواعد

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Cluster1	Cluster2	Cluster3
S1	1	1	1	1	0	0	1	1	0	1	1	0	0
S2	1	0	1	1	1	1	1	0	0	1	1	0	0
S3	0	1	1	1	0	1	1	0	1	0	0	1	0
S4	1	0	1	1	1	1	0	1	0	1	1	0	0
S5	1	0	0	0	1	0	1	1	0	1	0	0	1
S6	0	1	1	0	0	1	0	0	1	0	0	1	0
S7	0	1	1	0	1	1	0	0	0	0	0	1	0
S8	0	1	0	0	1	0	0	1	0	0	0	1	0
S9	0	0	1	0	1	0	1	1	0	1	0	0	1
S10	0	0	1	0	1	0	0	0	0	1	0	0	1

ومن خلال تطبيق خوارزم التصنيف شكل (٢) يتم استخراج بعض القواعد التي تساعد المستخدم الجديد في تلبية متطلباته بتخصيص صفحات مرتبطة بالصفحات إلى يقوم بتصفحها وذلك لتوفير الوقت وتقليل عمليات البحث حيث يتم إضافة المجموعات clusters التي تم اكتشافها في المرحلة السابقة وهي (٣) مجموعات كهدف إلى الجدول السابق بحيث تتم قياس احتمالية وجود الصفحات كل على حدة ومجتمعة في مجموعة معينة من المجموعات (ارتباط الصفحة بالمجموعة)، فمثلا نرى أن الصفحة P1 تم الدخول عليها (٤) مرات منهم ثلاث مرات تنتمي إلى المجموعة الأولى cluster1 ومرة واحدة تنتمي إلى المجموعة الثالثة cluster3 وبالتالي يكون نسبة ظهورها في المجموعة الأولى ٧٥٪ ونسبة ظهورها في المجموعة الثالثة ٢٥٪ وبالتالي نحتاج إلى إضافة صفحة أخرى إلى الصفحة P1 لمعرفة احتمال ظهور الصفحتين في أحد المجموعات فنقوم بتجربة P1,P2 لنجد أنها تظهر معا مره واحدة في المجموعة الأولى cluster1 وبالتالي يكون احتمالية ظهورهما معا بنسبة ١٠٠٪ وبالتالي يمكن استخلاص القاعدة التالية:

If p1=1 and p2=1 then cluster1

ولقياس ارتباط P1, P3 معا نجد أنهم ظهرا (٣) مرات في المجموعة الأولى



شكل (٢) خوارزم التصنيف

نتائج البحث

يهدف تخصيص الويب إلى إمداد المستخدم بالبيانات التي يحتاجها بدون أن يطلبها بشكل مباشر. في هذا السياق اتضح أن تقنيات التنقيب في بيانات الويب من التقنيات المفيدة في هذا المجال لاستكشاف المعلومات المخبأة في البيانات المرتبطة بالويب وتحديداً تقنية التنقيب استخدام الويب والتي تستكشف المعلومات من بيانات دخول المستخدم للموقع باستخدام تقنيات التنقيب في البيانات. وتستخدم المعرفة المستخلصة من البيانات التاريخية للمستخدمين في تطوير نظام التخصيص أو النظام المقترن. ويقوم النظام المقترن باستخلاص البيانات من ملف دخول المستخدم file log ليتم استخدامها في اكتشاف أنماط المستخدمين عن طريق تطبيق تقنيات العنقدة أو التجميع (Clustering) حيث تم تقسيم جلسات العمل Sessions على ثلاث مجموعات متزابطة وفقاً لعلاقة التشابه فيما بينها حيث شملت المجموعة الأولى (S1,S2,S4) والمجموعة الثانية (S3,S6, S7,S8) والمجموعة الثالثة (S5, S9, S10). وكذلك استخراج القواعد classification rules) عن طريق استخدام تقنيات التصنيف وذلك من أجل إعطاء المستخدم مجموعه من التوصيات recommendations حيث تم حساب الارتباط بين الصفحات التي يقوم المستخدم الجديد بالدخول عليها والمجموعات الموجودة بالفعل من خلال عملية العنقدة التي تساعده في الحصول على الصفحات الأكثر أهمية والأكثر تشابهاً توفيرًا لوقت وجهد المستخدم وتخفيض الحمل الزائد على الموقع.

المراجع:

أولاً المراجع العربية:

1. محمد زياد حمدان (١٩٩٩) البحث العلمي كنظام، سوريا، دار التربية الحديثة، ص ٦ .

ثانياً المراجع الأجنبية:

1. Anthony. S (2005): Web Mining Application and Techniques, United State of American, Idea Group Inc, ISBN 1-59140-9 (e-book), P.20, Available Online at <http://books.google.com.eg/books>, Accessed On 11 May 2010
2. Derar.H (2009): Effectiveness of Template Detection on Noise Reduction and Websites Summarization, M.S, Department of Computer Science, University of Calgary, Alberta.
3. Zhongming. M (2007): Web Mining for Knowledge Discovery, Ph.d, Department of Bussiness Administration, University of Utah.
4. Fatih. G (2007): Effective Use of Term Relationships in Web Content Mining , Ph.d, Arizona State University, P.18.
5. John.L, Michel . V (2007): NonLinear Dimensionality Reduction, NewYork, USA, PP.45-55.

6. Richard . D, Peter. H, David. S (2001) :Pattern classification ,2nd ed, Wiley, New York, PP.35.
7. Vel'asquez, J. D., Palade V. (2008): "Adaptive Websites: A Knowledge Extraction From Web Data Approach," IOS Press, Amsterdam, NL.
8. Hannah, H., Thangavel, K.(2009): Rough set based User profiling for Web Personalization, International Journal of Recent Trends in Engineering, Vol. (2), No. (1).
9. Kamber,M . and Han, J.(2006) : Data mining Concepts and Techniques. All rights reserved by Elsevier Inc. 13:978-1-55860-901-3.
10. Yuefeng. L, Ning. Z (2004): Web Mining Model and Its Applications for Information Gathering, Journal of Knowledge-Based Systems, Vol (17), PP. 207–217.
11. David. S, Antonio. M (2009): Web Mining Techniques for Automatic Discovery of Medical Knowledge, Department of Computer Science and Mathematics Universitat Rovira, Available Online at <http://www.ScienceDirect.com>, Accessed On 27 march
12. Srivastava, J, et al (2005): Web Mining – Concepts, Applications and Research Directions, Journal of Computer Science, Vol (180), PP. 275–307.
13. Lan. Y, Bing. L (2006) : Web Page Cleaning for Web Mining through Feature Weighting, Available Online at <http://www.ScienceDirect.com>, Accessed On 27 march 2010.
14. David J, et al (2007) : Visual Web Mining , Machine Learning Journal, Vol (42), PP.31–60.
15. Cheng. Y, et al (2009) : Applications of Web Mining for Marketing of Online Bookstores, Journal of Expert Systems with Applications, Vol(39), PP. 11249–11256.
16. Tuncay. S, Necmi. D, Zafer. C (2010): Virtual Education Environments and Web Mining, Journal of Procedia Social and Behavioral Sciences, Vol (2),PP. 5120–5124.
17. Rathod, D. (2012): A Review On Web Mining, International Journal of Engineering Research and Technology (IJERT), ISSN: 2278-0181, Vol. (1) Issue (2), April.
18. Taherizadeh, S., Moghadam N. (2009): Integrating Web Content Mining into Web Usage Mining for Finding Patterns and Predicting Users' Behaviors,

- International Journal of Information Science and Management, Vol. (7), No. (1).
19. Jain,R. Purohit, G. N.(2011): Page Ranking Algorithms for Web Mining, International Journal of Computer Applications, Vol(13)- No.(5), pp.0975 – 8887.
20. Kohavi. R and Parekh. R (2003): Ten supplementary analyses to improve e-commerce web sites. In Proceeding of the Fifth WEBKDD workshop.
21. Gutschmidt, A., Cap, C. H., Nerding, F.W. , (2008): Paving the Path to Automatic User Task Identification. Workshop on Common Sense Knowledge and Goal-Oriented Interfaces, International Conference on Intelligent User Interfaces.
22. Dunham,H. (2003): "data mining introductory and advanced topic", pearson education INC.- Eirinaki,M. and Vazirgiannis,M.(2003)" Web mining for web personalization", http://www.soe.ucsc.edu/eirinaki/papers/Ev03_TOIT.pdf, may 2008.
23. Ling Zheng, Hui Gui and Feng Li,(2010) “ Optimized Data Preprocessing Technology For Web Log Mining”, IEEE International Conference On Computer Design and Applications(ICCDA), pp. VI-19-VI-21.
24. SubMasthan, T., Ravindra, Y., Satish, U., Sandeep, S., Srikanth, K. (2012): An Effective Framework For Identifying Personalized Web Recommender System By Applying Web Usage Mining, International Journal of Engineering Research and Applications (IJERA), Vol. (2), Issue (3), pp. 307-312.
25. Vel'asquez, J. D., Palade V. (2008): "Adaptive Websites: A Knowledge Extraction From Web Data Approach," IOS Press, Amsterdam, NL.
26. Kiruthika, M.(2011): Pattern Discovery Using Association Rules, International Journal of Advanced Computer Science and Applications (IJACSA), Vol. (2), No. (12).
27. Suresh, K., Madana, R., Rama, A. (2011): Improved FCM algorithm for Clustering on Web Usage Mining, IJCSI International Journal of Computer Science, ISSN (Online): 1694-081, Vol. (8), No(1), www.IJCSI.org.
28. Usama Fayyad, et al(2009): From Data Mining to Knowledge Discovery in Databases, Morgan Kaufmann, USA.