

التحديات التي تواجه خوارزميات محركات البحث في استرجاع المحتوى العربي على الشبكة العنكبوتية العالمية: دراسة مسحية تحليلية . 2

إعداد
مؤمن سيد النشرتي
مدرس مساعد، قسم المكتبات والوثائق والمعلومات
جامعة القاهرة، مصر

المستخلص

تُرصد هذه الورقة البحثية جانباً مهماً في إدارة ومعالجة المحتوى العربي على الانترنت، وهو قضية البحث والاسترجاع لهذا المحتوى، حيث تركز على التحديات التي تواجه خوارزميات محركات البحث الداعمة للغة العربية في استرجاع المحتوى العربي على الانترنت، وذلك في ضوء مجموعة من التساؤلات والتي تحاول الكشف عن:

- 1- التحديات التي تواجه طرق والآليات محركات البحث في الكشف والوصول إلى المحتوى العربي على الانترنت.
- 2- التحديات التي تواجه منهجيات تكشف المحتوى العربي داخل محركات البحث.
- 3- التحديات التي تواجه خوارزميات ونماذج الاسترجاع والترتيب للمحتوى العربي في نتائج محركات البحث.
- 4- التحديات التي تواجه المستفيدين في صياغة الاستفسارات عن المحتوى العربي على الانترنت.

وفي هذا تعتمد الدراسة على المنهج المسحي لحصر غالبية الخوارزميات والآليات التي تعتمد عليها محركات البحث في استرجاع المحتوى، ثم الاعتماد على النهج التحليلي لدراسة التحديات التي تواجه هذه الخوارزميات.

الاستشهاد المرجعي

النشرتي، مؤمن سيد. التحديات التي تواجه خوارزميات محركات البحث في استرجاع المحتوى العربي على الشبكة العنكبوتية العالمية: دراسة مسحية تحليلية . 2 . - ع 30 (ديسمبر 2012) . - تاريخ الاطلاع <أكتب هنا تاريخ الاطلاع على البحث> . - متاح في: <أكتب هنا تاريخ الاطلاع على البحث>

***The Challenges that Facing the Search Engine's Algorithms in Retrieving the Arabic Content on The World Wide Web:
Analytical study***

Abstract

This study explores an important side of managing and handling the arabic content on the web, search on arabic content and retrieve issues. this study focuses on the challenges that facing algorithms of search engines that supported arabic language in retrieve the arabic content.

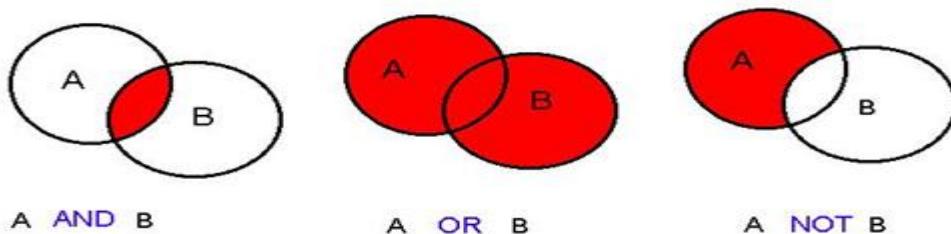
This study tries answering about a set of Queries that related to:

- 1- What's the challenges that facing the search engine's crawler?**
- 2- What's the challenges that facing the search engine's indexer?**
- 3- What's the challenges that facing the search engine's ranking?**

the study will depend on the analytical methodology to reach final results.

. The Boolean model النموذج البوليني

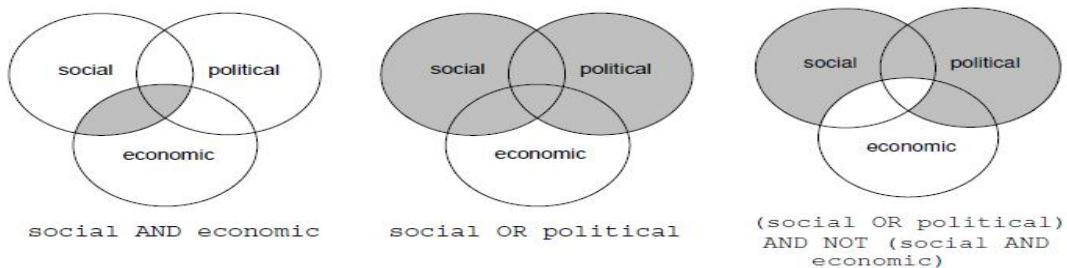
يأتي النموذج البوليني على رأس نماذج استرجاع وترتيب المحتوى في محركات البحث وأقدمها وأكثرها خصوصاً للدراسة، ويجب الإشارة إلى امكانية البحث البوليني التي توفرها معظم محركات البحث في وقتنا الراهن تعتمد على النموذج البوليني)، يعتمد النموذج البوليني في أساسه على مفهوم نظرية المجموعات¹ والجبر البوليني، ومنطقية عمله تعتمد على إقران محتوى الوثيقة بمجموعة من الكلمات المفتاحية لتمثيلها، وبالنسبة للاستفسار فيتم أيضاً رصد الكلمات المفتاحية به وتحديد سمة الاقتران بين الكلمات المفتاحية من خلال الروابط البولينية مثل (و، أو، لا²) كما هو موضح في الشكل رقم (12).



¹ تمثل نظرية المجموعات أحد فروع الرياضيات المعنوية بنمذجة الكيانات في صورة مجموعات وتحديد درجات الارتباط بين هذه الكيانات في ظل صورتها المجموعية.

² وتنسب هذه الروابط إلى عالم الرياضيات والمنطق البريطاني جورج بول Geogre Boole ، الذي يعد أول من استخدم مجموعة من الرموز الرياضية للتعبير عن بعض العمليات المنطقية ، وتمثل هذه الروابط في الكلمات الثلاث التالية AND , OR NOT .

يعلم النموذج البوليني على توفير نظام يتمتع بالسهولة في ان يدرك من قبل المستفيدين والمتعاملين مع محركات البحث علامة على ذلك فإن استفسارات المستفيدين تحدد وفقاً للروابط البولينية والتي تتسم بالدلاله المحكمة.



شكل رقم (12) يوضح كيفية عمل خوارزمية الرابط البوليني

ورغم ما يتمتع به من بساطة واحكام في منطقه الا ان الكثير من العيوب تعليه والتي تمثل تحديا في استرجاع وترتيب المحتوى داخل محركات البحث:

- اولها المعيار ذو الحكم الثنائي على درجة الصلة بين الاستفسار ومحلى الوثيقة (محلى الوثيقة وفقاً للنموذج البوليني إما أن يكون متصل relevant أو غير متصل non-relevant)، فالنموذج البوليني ينظر إلى الكلمات والمفردات الكشفية على كونها موجودة أو غائبة دون تحديد لدرجات الصلة، مما يحول دون استرجاع جيد وفعال لمحتوى الوثائق فالمصطلح الكشي لا يمثل وزن بين (0,1) كما يحدث في جميع الخوارزميات بل يحصل على أحد الإحتمالين إما (0) وإما (1).
- يتطلب المنطق البوليني استخدام نفس المصطلحات التي كشف بها محتوى الوثائق للتعبير عن استفسار المستفيد، وذلك لضمان نجاح عملية المضاهاة.
- يتطلب المنطق البوليني تدريباً للمستفيدين على صياغة الاستفسارات، لأنه يختلف عن اللغة الطبيعية في الاستخدام.
- نجد المعامل AND ، يحد من عملية البحث ، فالبحث عن A AND B AND C ، سوف يستبعد محتوى الوثائق التي لا تشتمل على المصطلحات الثلاثة مجتمعة، مع أنه يتحمل أن تكون وثيقة تشتمل على اثنين فقط ذات جدوى للمستفيد . وبالتالي نجد أن المعامل AND غالباً ما يؤدي إلى فشل عملية البحث.
- التعبيرات والروابط البولينية تتسم بأن لها دلالات محددة في كثير من الأحيان، فرغم ما تتسم بها من بساطة إلى أنها ليست بسيطة في التعبير عن الحاجات المعلوماتية ففي الواقع نجد أن معظم المستفيدين يجدون صعوبة في التعبير عن مطالبهم واحتاجاتهم في ظل استخدام التعبيرات المنطقية أو البولينية.

النموذج ذات الموجهات في الفراغ .Vector space model

يعد نموذج الموجهات أحد وأهم نماذج الترتيب في استرجاع المحتوى استخداماً وتوظيفاً، وقد كان لبيتر لون الفضل في تطوير منطقية الاعتماد على الموجهات، حيث كان أول من اقترح استخدام النهج الإحصائي في البحث عن المعلومات عام 1957 معتمدًا على معيار التماثل بين الاستفسارات والوثائق.

وفقاً للنموذج الإحصائي ينظر إلى محتوى الوثيقة على أنه حقيبة كلمات Bag of words بمعنى أن محتوى الوثيقة يشتمل على مصطلحات غير مرتبة وذات ترددية غير منتظمة داخل محتوى الوثيقة.

كانت الفكرة الرئيسية التي بنيت عليها نموذج الموجهات في الفراغ أن استخدام الوزن الثنائي (يتصل أو لا يتصل (1,0)) يحد جداً من عملية الاسترجاع والترتيب الطبيعي للنتائج، وبناءً عليه قدم هذا النموذج إطار عمل جديداً يعتمد على ما يعرف بالمطابقة الجزئية (أي أن درجة اتصال أو عدم اتصال الوثيقة بالاستفسار يحدد من خلال أوزان متفاوتة بين قيمتين أدنها يرمز له بالرقم 0 وأعلاها يرمز له بالرقم 1 ويتم ذلك من خلال مجموعة من المعادلات الخاصة بوزن المصطلح بحيث تستخدم هذه الأوزان في نهاية المطاف لحساب درجة التشابه والتماثل بين كل من الوثيقة المخزننة في النظام وبين استفسار المستفيد).

في نموذج فراغ الموجهات تحسب درجة صلة محتوى الوثيقة بالاستفسار من خلال تحديد درجة التشابه بينهما، حيث يمثل كلاً من محتوى الوثيقة والاستفسار في صورة موجهات في فراغ متعدد الأبعاد كما هو موضح في الشكل رقم (13).

$$\begin{aligned} \mathbf{d}_j &= (w_{1,j}, w_{2,j}, \dots, w_{t,j}) \\ \mathbf{q} &= (w_{1,q}, w_{2,q}, \dots, w_{t,q}) \end{aligned}$$

حيث ينطوي كل موجه على أوزان غير ثنائية للمصطلحات الكشفية في كلاً من محتوى الوثيقة والاستفسارات والتي يشار إليها بالرمز w_i .

وتحسب درجة الصلة للوثائق من خلال مقارنة انحراف الزوايا بين كل من موجه الوثيقة وموجه الاستفسار كما هو موضح من خلال المعادلة الآتية:

$$\cos \theta = \frac{\mathbf{d}_2 \cdot \mathbf{q}}{\|\mathbf{d}_2\| \|\mathbf{q}\|}$$

الأسس الرياضي الذي يعتمد عليه هذا النموذج:

يمكن ان توصف العلاقة بين محتوى الوثيقة D والمصطلح T من خلال المصفوفة tf-idf كمعيار كمي يشتمل على محورين اساسيين:

المحور الأول: هو تردد المصطلح TF ويشير إلى عدد مرات ظهور المصطلح t في محتوى الوثيقة d وتأتي المعادلة لحساب تردد المصطلح على هذا النحو:

$$tf_{i,j} = \frac{n_{i,j}}{\sum_k n_{k,j}}$$

- حيث تشير $tf_{i,j}$ إلى حساب تردد المصطلح.
- تشير $n_{i,j}$ إلى عدد مرات ظهور المصطلح t_i في محتوى الوثيقة d_j .
- وتشير $\sum_k n_{k,j}$ إلى مجموع عدد المصطلحات في إجمالي الوثيقة.

مثال اذا افترضنا ان وثيقة ما تتكون من 100 مصطلح، ويظهر مصطلح المكتبات 4 مرات في الوثيقة فإن المعادلة ستكون $0.04 = (4/100)$

المحور الثاني: هو تردد الوثيقة العكسي، والذي يعمل على حساب نسبة اجمالي عدد الوثائق المخزنة في النظام إلى عدد الوثائق التي تشتمل على المصطلح T وتظهر معادلته على هذا النحو:

$$idf_i = \log \frac{|D|}{|\{d : t_i \in d\}|}$$

- تشير idf_i إلى حساب تردد الوثيقة العكسي.
- بينما تشير \log إلى حساب لوغارتم ناتج القسمة.
- وتشير $|D|$ إلى اجمالي عدد الوثائق في النظام.
- وتشير $|\{d : t_i \in d\}|$ إلى عدد الوثائق التي يظهر فيها المصطلح t_i .

وتباعاً للمثال السابق، فإذا أفترضنا أن عدد الوثائق المخزنة في النظام تبلغ 1000000 وثيقة ويظهر مصطلح المكتبات في 1000 وثيقة من إجمالي عدد الوثائق وبالتالي يحسب $3=\log(1000000/1000)$.

ويحسب معدل التردد العام للوثيقة من خلال حاصل ضرب تردد المصطلح X تردد الوثيقة المعكوس المعادلة الآتية:

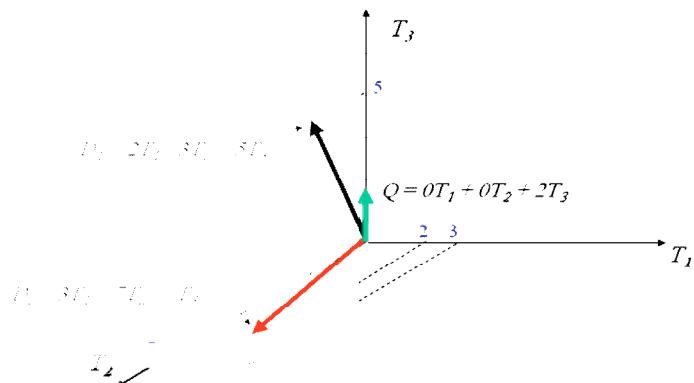
$$dt = TF(d, t) * IDF(t)$$

ومن خلال المثال السابق تكون المعادلة $3=0.04 \times 0.12$ اي ان رتبة الوثيقة يساوي 0.12، ولعل من الملاحظ ان اجمالي القيم ستائي منحصرة بين رقمي 1 و 0.

$$TF(d, t) = \begin{cases} 0 & \text{if } n(d, t) = 0 \\ 1 + \log(1 + \log(n(d, t))) & \text{otherwise} \end{cases}$$

وعليه يحسب جيب الزاوية الخاصة بالتشابه بين الوثيقة والاستفسار من خلال المعادلة الآتية:

$$sim(d_j, q) = \frac{\mathbf{d}_j \cdot \mathbf{q}}{\|\mathbf{d}_j\| \|\mathbf{q}\|} = \frac{\sum_{i=1}^N w_{i,j} * w_{i,q}}{\sqrt{\sum_{i=1}^N w_{i,j}^2} * \sqrt{\sum_{i=1}^N w_{i,q}^2}}$$



شكل رقم (13) توضح المنهجيات المختلفة لحساب جيب الزاوية بين الاستفسار والوثيقة.

ان عيوب هذا النموذج تمثل تحدياً كبيراً في استرجاع المحتوى في محرّكات البحث والتي تمثل في اعتماده وبشكل أساسي على المضاهاة المعجمية Lexical، بحيث يقوم باسترجاع محتوى الوثائق التي تستخدم الكلمات الكشفية التي وردت في استفسار المستفيد، واعتباره أكثر محتوى الوثائق صلة بالموضوع، وعليه يكتفي الاسترجاع وفقاً للمضاهاة اللغوية على مشكلتين أساسيتين:

- الترافق اللغوي Synonym: تتبع من امكانية استخدام نفس المفهوم ولكن بعبارة او كلمة اخرى فالسؤال مثلاً عن المساجد لا تظهر النتائج التي تشتمل على لفظة الجامع.
- التجانس اللغوي Polysemy: اما التجانس فينبع أن الكلمة الواحدة قد تحظى باكثر من معنى في سياقات مختلفة ومثلاً على ذلك قد يسترجع المحتوى عن موضوع القروض ومحتوى اخر يشتمل على اسم صلاح الدين ومحتوى اخر عن الدين الاسلامي نظراً لاستخدام لفظة الدين.

وعليه فإن استخدام المضاهاة اللغوية يؤدي إلى استرجاع محتوى قد لا يتصل باستفسار المستفيد، فضلاً على تعامله مع الكلمات في صورة فردية دون النظر إلى السياق³.

نموذج المنهج الإحتمالي :Probabilistic model

قدم المنهج الإحتمالي لأول مرة في مضمون استرجاع المعلومات عام 1960 على يد Maron and Kuhns في مقالتهما المعروفة باسم On Relevance, Probabilistic Indexing and Information Retrieval كأول عمل علمي يتطرق إلى استخدام المنهج الإحتمالي في استرجاع المعلومات، وعليه ظهر ما يعرف بالتكثيف الإحتمالي Probabilistic Indexing⁴. أما نموذج الاسترجاع الخاص بهذا المنهج فقد قدم في عام 1976 على يد كل من S. E. Robertson and K. Sparck Jones⁵ والذي عرف باسم نموذج الاسترجاع القائم على الفصل الثنائي The binary independence retrieval model (BIR)، وتمثل مفهوم هذا النموذج في أن مجموعة الوثائق المختزنة في نظام استرجاع المعلومات تنقسم إلى مجموعتين شائطتين مستقلتين عن بعضهما البعض، المجموعة الأولى تعرف بمجموعة الصلة والتي يتسنم محتواها بالصلة بالاستفسار، والمجموعة الأخرى تعرف بمجموعة اللاصلة والتي يتسنم محتواها بعدم الصلة بالاستفسار.

تتمثل جوهر هذا النموذج في سؤال منطقي وهو "ما هو احتمالية صلة وثيقة محددة باستفسار محدد؟!" من خلال هذا السؤال تبلورت رؤية هذا النموذج في قياس وتحديد الوثائق وفقاً لإحتمالية صلتها بالاستفسار.

إن الفكرة الأساسية لهذا النموذج تتمثل في فرضية أحتمال أن نظام استرجاع المعلومات يشتمل على وثائق تتصل باستفسار المستفيد تمام الصلة وهناك مجموعة أخرى بمنأى عن هذه الصلة، فوفقاً لهذا النموذج تسمى مجموعة الوثائق ذات الصلة بمجموعة الجواب المثالي *ideal answer set* ، وبتوفير توصيف كامل لهذه المجموعة من الوثائق (مجموعة الجواب المثالي) تتنبأ مشاكل استرجاع محتوى الوثائق، ورغم ذلك تظهر عقبة أخرى في صعوبة معرفة ماهية هذه الخصائص والسمات بشكل قاطع.

ما يمكن أن يستشف من معالجة الإستفسار يتمثل في الكلمات المفتاحية الواردة في محتوى الوثيقة والتي تحظى بدلالات لغوية أو اصطلاحية يمكن أن تستخدم في وسم هذه الخصائص والمميزات.

³ Dominich, S. (2008). The modern algebra of information retrieval . Berlin: Springer.

⁴ Maron, M. E., & Kuhns, J. (1960). On relevance, probabilistic indexing and information retrieval. *Journal of the Association for Computing Machinery*, 7(3), 216–244.

⁵ S. E. Robertson and K. Sparck Jones. Relevance weighting of search terms. *Journal of the American Society for Information Sciences*, 27(3):129-146, 1976.

رغم ذلك فإن هذه الخصائص والسمات لا تكن معروفة إلا في وقت الاستعلام أو الاستفسار. حيث يتمثل الجهد الأساسي في التخمين الأولي لما يمكن أن يكون خصائص وسمات للوثيقة مما يسمح بإنشاء وصف أولي احتمالي لمجموعة الجواب المثلية على الاستفسار من الوثائق.

ثم تأتي الخطوة الثانية متمثلة في تفاعل المستفيد مع النتائج بغرض تحسين الوصف الإحتمالي لمجموعة الإجابة المثلى، هذا التفاعل يمكن أن يجري على هذا النحو:

يقوم المستفيد بمراجعة متخصصة للوثائق المسترجعة، ثم تحديد أي منها ذو صلة بالاستفسار وأي منها لا يتصل بها، ثم يقوم النظام باستخدام هذه المعلومات لتنقح وصف الوصف الخاص بمجموعة الجواب المثلى، وبتكرار هذا الاجراء لعدة مرات يتوقع ان هذا الوصف سوف يتطور ويصبح اكثر صلة وقرابة إلى الوصف الحقيقي لمجموعة الإجابة المثلى.

تتخذ معادلة النموذج الاحتمالي هذا الشكل:

○ q للاشارة إلى استفسار المستفيد.

○ d_j للاشارة إلى الوثائق في نظام استرجاع المعلومات.

○ R للاشارة إلى مجموعة الإجابة المثلى.

○ $\sim R$ للاشارة إلى الوثائق التي لا صلة لها

○ $P(R|d_j)$ للاشارة إلى احتمالية ظهور مجموعة الإجابة المثلى من اجمالي وثائق النظام.

○ $P(\bar{R}|\vec{d}_j)$ للاشارة إلى احتمالية ظهور الوثائق ذات عدم الصلة ضمن اجمالي وثائق النظام.

○ sim للاشارة إلى حساب درجة التشابه والتمايز.

بحيث تتخذ المعادلة هذه الصورة لحساب احتمالية صلة الوثائق او عدم صلتها:

$$sim(d_j, q) = \frac{P(R|\vec{d}_j)}{P(\bar{R}|\vec{d}_j)}$$

ووفقا لقاعدة Bayes⁶ تتخذ المعادلة هذه الصورة:

$$sim(d_j, q) = \frac{P(\vec{d}_j|R) \times P(R)}{P(\vec{d}_j|\bar{R}) \times P(\bar{R})}$$

أن ما يعيّب هذا النوذج ويمثل تحديا في استرجاع المحتوى في محركات البحث يمكن في:

• الحاجة إلى التخمين للفصل الأولي لمحتوى الوثائق في مجموعتين مجموعه ذات صلة ومجموعة لا تتسم بالصلة.

⁶ تعد هذه النظرية أحد نظريات مجال الاحتمالات في علم الرياضيات والتي تعنى بقياس العلاقة بين احتمالين شرطيين والذي عادة ما يعلوهما التناقض فيما بينهم.

- إن هذه الطريقة لا تأخذ في الإعتبار وتيرة تردد المصطلحات الكشفية داخل الوثائق (مما يرجعنا إلى نظرية الحكم الثاني الخاصة بالنموذج البوليني).⁷

نماذج التكشيف الدلالي الكامن: Latent Semantic Indexing Model

إن نماذج الاسترجاع - السابق ذكرها - تعتمد وبشكل اساسي على الاسترجاع من خلال اختزال محتوى كلا من الاستفسار والوثيقة في مجموعة من المصطلحات الكشفية أو الكلمات المفتاحية.

ثم يعمد بعد ذلك إلى قياس درجة التشابه بين كلا منها، ثم الاسترجاع وفقاً لهذا الأساس، وتعرف هذه المنهجية بإسم الاسترجاع وفقاً للتشابه المعجمي lexical matching method أي من خلال الاعتماد على المضاهاة بين الأحرف المكونة للمصطلحات الكشفية الواردة في كلا من الوثيقة والاستفسار ، ووفقاً لهذه المنهجية السالفة يتسم أداء ومعدل الاسترجاع في محركات البحث بالفقر، وعدم الدقة، وهي الأسباب وراء تدني معدلات الاسترجاع والترتيب والمرجعية في ذلك تعود إلى سببين:

- وفي العادة تتواجد العديد من المصطلحات التي يمكن أن يستخدمها المستفيد في التعبير عن حاجته البحثية أو المفهوم مجرد لاستفساره، وهذه القضية تعرف بترادف المصطلحات فمن الممكن أن يقوم المستفيد بالتعبير عن مفهوم مجرد بلفظة الجوامع مثلًا في حين أن مستفيد آخر يعبر عنها بلفظة المساجد، في حين أن كلا من اللفظين يشيران إلى مفهوم واحد وهو دور العبادة لإقامة الصلاة عن المسلمين، ووفقاً للمنهجية المضاهاة المعجمية فإن بعض الوثائق ذات الصلة التي لم تكشف وفقاً للمصطلحات الكشفية لدى المستفيد قد لا تسترجع.

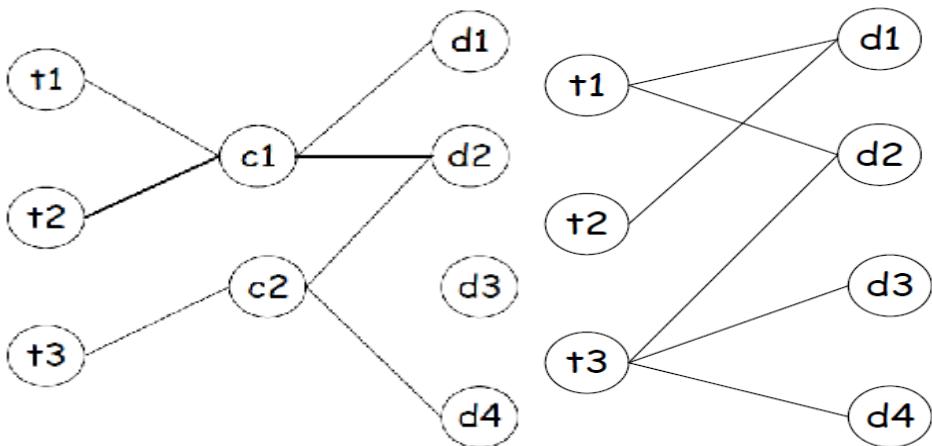
- قد تسترجع العديد من الوثائق التي لا تتصل بالاستفسار داخل مجموعة الوثائق المسترجعة، والمرجعية في ذلك تعود إلى أن العديد من البنى اللغوية للكلمات تحمل في طياتها الكثير من البنى الدلالية أو ما يعرف بالتجانس اللغوي، وعليه فإن المصطلحات الكشفية في استفسار المستفيد سوف تضاهي وفقاً للمضاهاة المعجمية مجموعة من الوثائق تشتمل على نفس المصطلحات الكشفية ولكن لا تتصل بموضوع الاستفسار مثل البحث عن لفظة الدين فقد ينطوي الأمر على أن تسترجع وثائق موضوعها الديانات، وأخرى موضوعها القروض والاقتراض، وأخرى تحتوي لفظة الدين كاسم شخص كأسم صلاح الدين أو عماد الدين.

فالأفكار التي ترد في نصوص الوثائق أقرب أن توصف من خلال المفهوم بدلاً من أن توصف من خلال الالفاظ، ومن ثم فإن تحقيق الاسترجاع وفقاً للمفهوم أو المعنى يعد أقرب صلة باستفسار المستفيد، وعليه فإن عملية مضاهاة الوثائق

⁷ A probabilistic model of information retrieval: development and comparative experiments. K. Sparck Jones. Information Processing and Management 36 (2000) 779±808

بالاستفسار المقدم يجب أن تعتمد على المضاهاة وفقاً للمفهوم بدلاً من أن تعتمد على المضاهاة وفقاً للفظ مما يسمح باسترخاع الوثائق التي لم تكشف وفقاً لمصطلحات الكشفية للاستفسار.

عرفت هذه المنهجية باسم التكشيف الدلالي الكامن Latent semantic indexing وقد قدم هذا النموذج كمنهجية آلية لمعالجة بعض أوجه القصور المتأصلة في تقنيات التي تعتمد على المضاهاة المعجمية والاسترجاع وفقاً للكلمات المفتاحية في الوثيقة، يعتمد النموذج الدلالي الكامن على تحليل درجة العلاقة الدلالية بين محتوى الوثائق من خلال معدلات احصائية، فوفقاً لهذه المنهجية فإن محرك البحث يقوم باسترخاع محتوى الوثائق ذات الصلة بمفهوم الاستفسار وليس وفقاً لتشابه الكلمات المفتاحية حتى ولو لم تشمل هذه الوثائق على مصطلحات الاستفسار كما هو موضح في الشكل رقم (14):



شكل رقم (أ).

شكل رقم (ب).

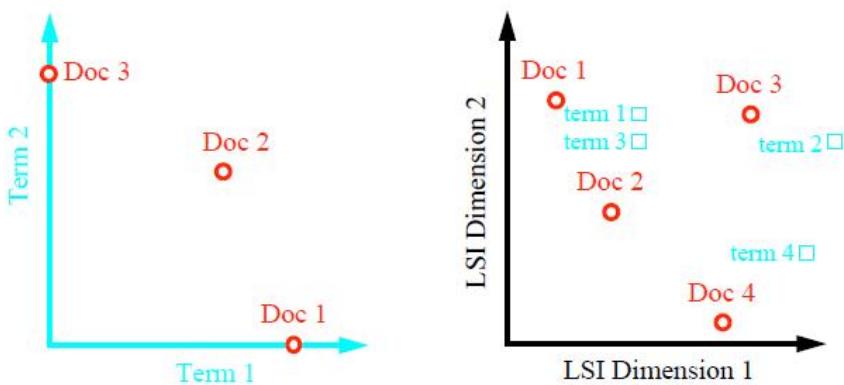
شكل رقم (14) يوضح هذا الشكل منهجية عمل نموذج التكشيف الدلالي الكامن.

يوضح هذا الشكل منهجية عمل التكشيف وفقاً للمضاهاة المعجمية والتكشيف وفقاً للمفهوم، حيث في الشكل رقم (أ) يتضح أن كل لفظ يقابل مجموعة من الوثائق أما في الشكل (ب) فإن الوثائق ترتبط بالمفاهيم التي تدل عليها مجموعة من الألفاظ المختلفة

قدم النموذج التكشيف الدلالي الكامن في عام 1990 ضمن ورقة بحثية لمجموعة من الباحثين في معهد Bell Communications Research (“Bellcore”)⁸

بعد نموذج التكشيف الدلالي الكامن نموذج حسابي يعتمد على تقنية الجبر الخطى بهدف تجميع البيانات (المفاهيم) المتشابه معاً ويتم تحقيق ذلك من خلال الآتي:

- تحديد المفاهيم الأساسية المشتركة الموجودة داخل مجموعة من الوثائق.
- تنظيم هذه المفاهيم داخل فراغ متعدد الأبعاد .
- التحليل الجري لهذه المصفوفة.



الشكل رقم (15) مقارنة بين نموذج الاسترجاع فراغ الموجهات وبين نموذج الاسترجاع الدلالي الكامن.

في اغلب نماذج الاسترجاع يتم رصد محتوى الوثائق وفقاً للمصطلحات المعبرة عنها، أما في النموذج الدلالي فالوثائق ترصد وفقاً للمفاهيم ثم تحصر الالفاظ التي تحدد موضوع الوثائق من داخلها كما هو موضح في الشكل رقم (15).

إن عيوب هذا النموذج والتي تعتبر تحدياً في استرجاع وترتيب المحتوى في محركات البحث: هو قدرته المحدودة في التعامل مع الاعداد الضخمة من الوثائق كما هو الحال في بالنسبة إلى حجم مصادر الشبكة العنکبوتية.⁹

نموذج الاسترجاع (الروابط الفائقة الناجمة عن البحث الموضوعي HITS) (hyperlink-induced topic search).

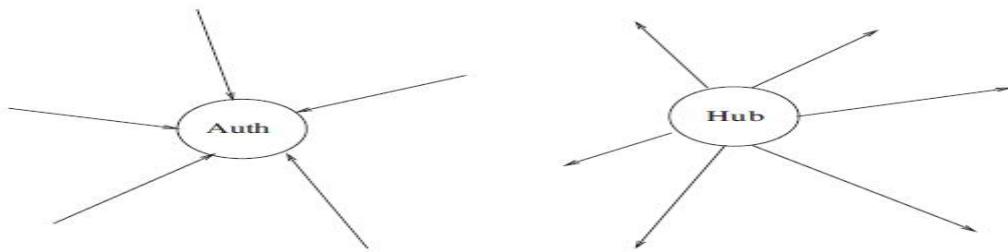
طورت هذه الخوارزمية عام 1997 على يد Jon Kleinberg في نفس الوقت الذي طورت فيه خوارزمية الترتيب الطبقي، تعتمد هذه الخوارزمية على اكتشاف وترتيب محتوى الوثيقة ذات الصلة بموضوع محدد – وتعد هذه الخوارزمية

⁸ Deerwester, S., Dumais, S.T., Furnas, G.W., Landauer, T.K., Harshman, R. (September, 1990). Indexing by latent semantic analysis. *Journal of the American Society for Information Science*, 41(6): 391-407

⁹ Deerwester, S., Dumais, S.T., Furnas, G.W., Landauer, T.K., Harshman, R. (September, 1990). Indexing by latent semantic analysis. *Journal of the American Society for Information Science*, 41(6): 391-407

الآن جزءاً أساسياً في خوارزميات محرك البحث Ask (www.ask.com) - بمعنى أن هذه الخوارزمية تعتمد على أن يوجه المستفيد أولاً الاستفسار لإداة البحث ثم تسترجع النتائج من الكشاف أو قاعدة البيانات لتبدء مرحلة الترتيب للنتائج وفقاً لعناصر اساسيين هما:

- الموضع الارتكازية Nodes Hubs: وهي الموضع التي تشتمل على محتوى يصدر منه الرابط في اشارة منها لموقع الاستنادية.
- الموضع الاستنادية او ذات الموثقية Nodes Authorities: ويقصد بها الموضع التي يرد اليها الرابط من قبل الموضع المحوري كما هو موضح في الشكل رقم (16).



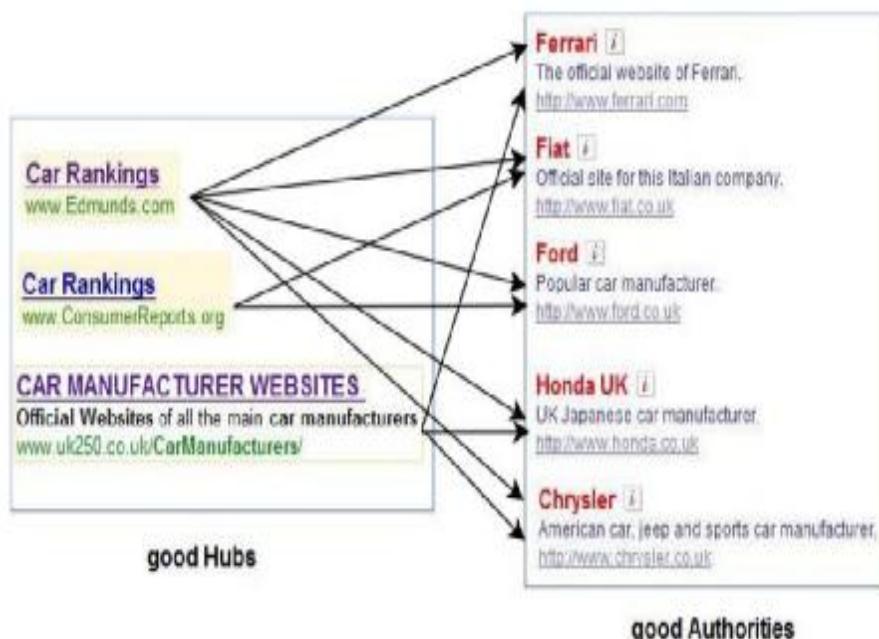
شكل رقم (16) يوضح بنية الموضع الارتكازية والموضع الاستنادية

فلو افترضنا أن الصفحة **A** تشتمل على محتوى ذات موثقية authority للاستفسار المقدم لمحرك البحث عن "أشهر صناع المركبات" في ظل أنها تشتمل على محتوى قيم عن الموضوع المراد الاستفسار عنه، حيث تعد الصفحات الرسمية لمنتجي السيارات بمثابة صفحات استنادية ذات موثوقية لهذه العملية البحثية كموقع تويوتا ومرسيدس وفيات وغيرها كما تعد موضع وصفحات وكلاء المبيعات لهذه السيارات بمثابة صفحات استنادية أيضاً للموضوع المشار إليه، على الجانب الآخر كيف يتم تحديد هذه الموضع الموثقية للاستفسار في ظل عدم اشتمالها على كلمة مركبات وفي ظل عدم اشتمال محرك البحث على مكنز أو خريطة انتropolوجية لحصر المترادفات والمفردات.

يتم تحديد الموضع الموثقية من خلال تتبع الروابط من نقاط ارتكازية محددة تكون بمثابة دليل موثوق به لمحرك البحث ثم يتم تتبع الروابط التي يشير فيها لموضع آخر، فلو افترضنا أن الصفحة **A** بمثابة صفحة ذات موثقية authority للاستفسار المقدم لمحرك البحث عن "أشهر صناع المركبات" في ظل أنها تشتمل على معلومات قيمة عن الموضوع المراد الاستفسار عنه، حيث تعد الصفحات الرسمية لمنتجي السيارات بمثابة صفحات استنادية ذات موثوقية لهذه العملية البحثية كموقع تويوتا ومرسيدس وفيات وغيرها كما تعدد مواقع وصفحات وكلاء المبيعات لهذه السيارات بمثابة صفحات استنادية أيضاً للموضوع المشار إليه، على الجانب الآخر كيف يتم تحديد هذه الموضع الموثقية للاستفسار في ظل عدم اشتمالها على كلمة مركبات وفي ظل عدم اشتمال محرك البحث على مكنز أو خريطة انتropolوجية لحصر المترادفات والمفردات؟ يتم تحديدها

من خلال تتبع الروابط من نقاط ارتكازية محددة تكون بمثابة دليل موثوق به لمحرك البحث كما هو موضح في الشكل رقم

:17



شكل رقم (17) يوضح المثال السابق

وتتمثل العلاقة بينهما في علاقة تبادلية تعزز بعضهم البعض، بمعنى أن الموقع الارتكازية ذات الجودة العالية تشير إلى الموقع الاستنادية الجيدة والعكس أيضاً. وعليه تعمل هذه الخوارزمية على تحديد درجة خاصة لإرتكازية الوثيقة ودرجة أخرى لاستنادية نفس الوثيقة.

وعلى هذا فإن كل محتوى يحظى بدرجتين واحدة للموقع التي تشير إليها - وهي في هذه الحالة نقطة ارتكازية - و أخرى للموقع التي تشير إلى هذه الصفحة، ويحدد على أساسهما رتبة الموقع في قائمة النتائج:

وعليه تحسب درجة الموثوقية والنقطة الارتكازية للوثيقة p على النحو الآتي:

$$\sum_{i=1}^n auth(i)$$

$$\sum_{i=1}^n hub(i)$$

لحساب قيمة النقاط الارتكازية للصفحة

لحساب قيمة موثوقية الصفحة

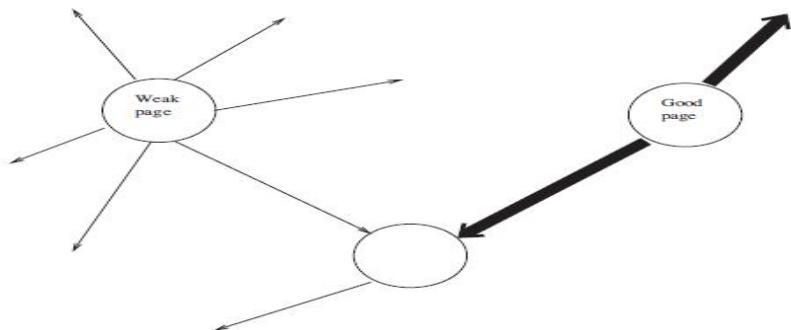
حيث تشير n إلى مجموع عدد المواقع التي ترتبط بالصفحة p ، أما A فتشير إلى الصفحة المرتبطة بـ p بشكل مباشر¹⁰.

نموذج الاسترجاع (ترتيب الطبقي للصفحات). (PageRank).

طور هذا النموذج على يد كلا من Lawrence Page و Sergey Brin عام 1997، وقد عرف هذا النموذج بـ "بانها المنهجية التي تعني بحساب رتبة محتوى كل صفحة على العنکبوتية اعتماداً على نمذجة العنکبوتية في مخطط بياني قائم على الروابط والمواقع". ولقياس جدوى هذه الخوارزمية قاما كلا من Brin و Page بتصميم محرك البحث الشهير Google.

أن الجانب الذي التفتت إليه هذه الخوارزمية هو النظر إلى الكيف دون الكم، بمعنى الاخذ في الاعتبار جودة الروابط بدلاً من النظر إلى عدد الروابط ، فتستند هذه الخوارزمية على مبادئ اساسين هما:

- تمثل الروابط مؤشرات جيدة لتحديد أهمية محتوى الوثيقة التي تشير إليها.
- الروابط الصادرة من وثائق تحظى باهمية في موضوعها تعد مؤشراً جيداً لجودة الوثيقة التي تشير إليها، عن الوثيقة التي يشار إليها من قبل وثائق أقل في الامانة والجودة كما هو موضح في الشكل رقم (18).



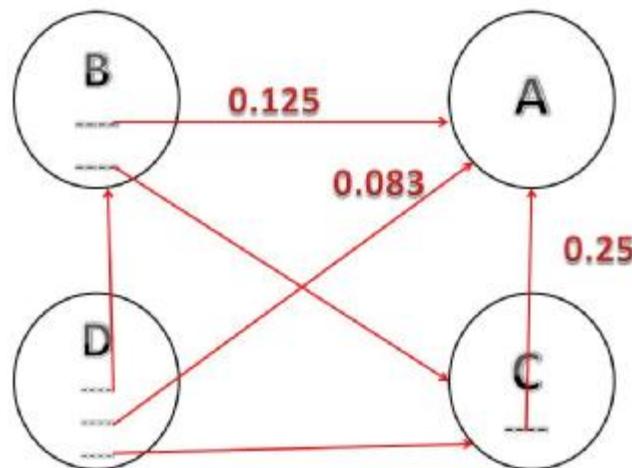
شكل رقم (18) يوضح منهجية PageRank ويوضح دلالة ان الرابط الفائق يكتسب قوة من قوة الصفحة ومحتواها الخوارزمية:

بداية يجدر الإشارة إلى أن خوارزمية الترتيب الطيفي (the pagerank) صدرت في أكثر من صيغة وأكثر من معادلة متالية، وسيعرض الدراسة في هذا المقام إلى الصيغة البسيطة من هذه المعادلات.

¹⁰ Levene, M. (2010). An introduction to search engines and web navigation (2nd ed.). Hoboken: Wiley.

تعتمد خوارزمية الترتيب الطبقي على نظرية احصائية تعرف بنظرية التوزيع الاحتمالي والتي تعمل على احتمالية تحديد قيمة لمتغير ما (صفحة عنكبوتية او الرابط الفائق) تم اختياره عشوائيا، هذه القيمة في هذا المقام هي الاهمية والتي يمكن ان تتراوح ما بين قيمتين اساسيتين هما (0 & 1).

ولنفترض ان لدينا بنية بياناتية لشبكة عنكبوتية تتكون من 4 نقاط (NODES) (أربع صفحات) A,B,C and D وأن أهمية هذه الصفحات تتوزع بالتساوي بينهم – أي تقسيم رقم 1 الذي يشير إلى وجود اهمية للبنية البياناتية للشبكة بالتساوي – فيكون نصيب كل صفحة هو 0.25، ولنفترض أن بين هذه الصفحات مجموعة من الروابط والتي سيتم الاعتماد عليها لحساب رتبة الصفحة A، هذه الروابط تتمثل في الشكل رقم (19).



شكل رقم (19) يوضح كيفية حساب رتبة الصفحة من خلال الرابط

حيث تشير كلا من الروابط الموجودة في الصفحات B,C,D إلى الصفحة A كما هو موضح في الشكل، مع الأخذ في الاعتبار أن الصفحة A تحسب رتبتها من خلال قيمة الرابط الذي يشير إليها فإذا كانت الصفحة B تحظى بقيمة مقدارها 0,25 موزعة هذه القيمة على رابطين فإن قيمة الصفحة B بالنسبة إلى الصفحة A هي: $0.25/2=0.125$ وتحسب قيمة رتبة A من خلال المعادلة الآتية:

$$PR(A) = \frac{PR(B)}{2} + \frac{PR(C)}{1} + \frac{PR(D)}{3}.$$

$$PR(A) = \frac{0.25}{2} + \frac{0.25}{1} + \frac{0.25}{3} = 0.458$$

ومن ثم تكون رتبة الوثيقة A في موضوع تخصصها 0.458 على صعيد الشبكة العنكبوتية.

التحديات التي تواجه خوارزميات page rank & HITS في ترتيب النتائج المسترجعة.

ورغم ذلك تمثل التحدي الذي واجه محركات البحث في تطبيق هذه الخوارزمية في:

1. هذه الخوارزمية في الأساس تعتمد على نمذجة وثائق العنكبوتية وروابطها في صورة تعرف بالمخطط البياني للعنكبوتية والذي ينطوي على انه قد يتخذ اكثرا من صورة وهيئة وشكل مما قد ينطوي على تبديل الاذوار في النقاط الارتكازية والمواقع ذات الموثوقية.

2. تعتمد هذه الخوارزمية على فرضية أساسية مفادها ان الصفحات المرتبطة ببعضها عبر الروابط الفائقة تنتمي إلى نفس الموضوع او بدرجة شبيهة منه، مع الاخذ بالاعتبار ان بيئة العنكبوتية لا تنسى بالاستقرار الكامل في ما تحمله وما تطرحه الموقع من محتوى وموضوعات، فضلا عن التعديلات المرتدة التي قد تتأثر بالموضوع الأساسي إلى موضوعات أخرى مما ينطوي ايضا على زيادة في عدد الروابط الفائقة او قد تتوارد بعض الروابط التي تشير إلى موقع تتناول موضوعات أخرى وهو ما يعرف بقضية توليد الموضوعات topic generalized ومن ثم فان فرضية دلالة الربط وفقا لتشابه المواقع ذات الموضوع الواحد تتضاءل.

3. ان الاعتماد على تحليل الروابط الفائقة ينطوي على ما يعرف بظاهرة الانحراف الموضوعي topic drift في ظل ما توفره الروابط من قدرة على الابحار¹¹.

ويعد التحدي الاكبر الذي يواجه الترتيب وفقا للروابط الفائقة هو خادعات الروابط والتي ستتناول في قسم التحديات الخارجية لمحركات البحث في استرجاع المحتوى على العنكبوتية.

التحديات الخارجية لمحركات البحث في استرجاع المحتوى من على العنكبوتية:

4/1- خادعات المحتوى لمحركات البحث:

يمكن القول أن بعض التحديات والمشكلات التي تواجهها محركات البحث في استرجاع المحتوى ارتبط ظهورها بوجود الشبكة العنكبوتية والبعض الآخر كان بمثابة تغيرات مستحدثة لمشكلات حظيت من قبل بالدراسة والاهتمام العلمي في ادبيات مجال استرجاع المعلومات أي قبل ظهور محركات البحث.

¹¹ Langville, A. N., & Meyer, C. D. (2006). Google's PageRank and beyond: the science of search engine rankings. Princeton, N.J.: Princeton University Press.

اتسم نمط سلوك المستفيدين من محركات البحث إلى اللجوء والاعتماد بصورة قصوى على النتائج الأولى داخل الصفحات الأولى من نتائج محركات البحث وقصر التصفح عليها دون النظر إلى باقي النتائج في الصفحات الأخرى فقط أوضحت Silverstein ان 85% من عمليات البحث يقتصر تصفح نتائجها على الصفحة الأولى فقط ولعل المرجعية في ذلك إلى قناعة ذاتية من جانب المستفيدين في أن النتائج ذات الصلة باستفسارة لابد ان تظهر اولاً، وانه كلما توغل في النتائج الأخرى ابتعدت به عن مجال استفساره¹².

وعليه ادرك مدبرون الواقع والقائمين على إدارة صفحات العنكبوتية تبعية منطقية مفادها في أن تضمين الموقع داخل النتائج العشر الأولى يؤدي إلى ما يعرف بإرتفاع معدل المرور إلى محتوى الموقع traffic to web site¹³ ، وعلى النقيض فإن استثناء أو استبعاد الموقع من الشاشة الأولى أو النتائج الأولى للبحث يسمح لعدد محدود من المستفيدين من رؤية محتوى الموقع أو تصفحه.

ويعد هذا الامر هو بؤرة اهتمام الواقع ذات التوجه التجاري – والتي تعتمد في دخلها على ارتفاع معدلات المرور إليها – حيث تعمل على ان تظهر في أول عشر نتائج للاستفسار، مما يساعد على تعزيز من سمعة الموقع والتي بدورها يساعد على جعل المزيد من الواقع تشير إليه وبالتالي تساعد على توليد مستوى أعلى في النتائج ومن ثم الحصول على القدر الاوفر من تضمين الاعلانات والدعائية داخلها.

وبالتالي يعمل أغلب موفرى المحتوى على العنكبوتية – خاصة الواقع التجارية – على جعل محتوى صفحات مواقعهم تحظى بترتيب طبقي عالى في نتائج محركات البحث داخل محركات البحث العامة والاكثر استخداما . ويتم تحقيق ذلك عن طريق منهجية واضحة و مباشرة وهي تحسين جودة صفحات الموقع سواء كان في المحتوى أو الشكل ولكن تكتفى هذه الطريقة الكثير من المال والوقت والجهد والموارد الأخرى، وعوضا عن كل ذلك يلجأ بعض موفرى المحتوى إلى طرق أخرى مختصرة تتمثل في التلاعب في نتائج محركات البحث من خلال استخدام اساليب غير اخلاقية عند بناء محتوى الواقع او تصميم الصفحات، فيما تعرف هذه المحاولة بتضليل خوارزمية الترتيب الطبقي لنتائج محركات البحث بخداع محركات البحث search engine spam

¹² Craig Silverstein ,Hannes Marais ,Monika Henzinger,Michael Moricz. Analysis of a very large web search engine query log.

ACM SIGIR Forum, 1999 - portal.acm.org

* ظاهرة المرور إلى الموقع Web traffic تعرف بانها حجم البيانات التي ترسل وتستقبل من قبل زائر الموقع والتي تقدر وفقا للمعادلة بحساب عدد الزائرين وعدد الصفحات التي تم تصفحها من خلالهم ويعد هذا المقياس مؤشر مهم للفائمين على ادارة الواقع في تحديد جوئي صفحاتهم.

المفهوم والتعريف:

يعود تاريخ الكلمة في الانتاج الفكري إلى عام 1996 حينما صر Eric Convey هذا المصطلح في مقالته¹⁴، موضحاً أن سمة مشكلة تظهر في نتائج محركات البحث، وأن مرجعية هذه المشكلة تعود إلى أن مدورو المواقع الذين يلجأون إلى إضافة مئات المصطلحات في بنية محتوى وثائقهم للحصول على رتبة أعلى وقد أطلق على هذه العملية مسمى Spamdexing في اشارة منه إلى خداع كشافات محركات البحث.

ويمكن أن يعرف خداع محركات البحث بـ "المنهجية أو أسلوب الذي يعتمد إلى استخدام بعض الاليات المصممة عمدًا لرفع ترتيب المواقع أو الصفحات في نتائج محركات البحث"¹⁵.

إن الهدف الأساسي لمحركات البحث هو توفير نتائج عالية الدقة والجودة عبر التحديد الكامل والدقيق لكافة الوثائق التي تتصل موضوعياً باستفسار البحث.¹⁶ والعمل على ترتيب النتائج التي تتسم بالأهمية عن مثيلاتها وفقاً لدرجات الصلة الموضوعية.

مفهوم الصلة الموضوعية يشير إلى التشابه النصي بين الاستفسار المقدم والوثيقة المسترجعة. أما عن مفهوم الأهمية فهو يشير إلى قوة الوثيقة وعاليتها ودرجة تمنعها برواج وفقاً لمجالها كما يستدل أيضاً على أهميتها من واقع الروابط الفائقة (على سبيل المثال الوثيقة التي تشتمل على الكثير من الروابط الداخلية تحظى بالأهمية عن مثيلاتها).

و عملياً تقوم محركات البحث بالدمج بين معيار الصلة الموضوعية ومعيار الأهمية كمؤشر لترتيب النتائج المتعلقة بالاستفسار في صورة خوارزمية خاصة بمحرك البحث. ولتحقيق هذه الأهداف يلجأ مخادعوا محركات البحث spammers إلى دراسة خوارزميات الترتيب الطيفي لمحرك البحث بغية لايجاد سبل الافادة منها وبشكل أكثر دقة يعمل المخادعون إلى تحديد المؤشرات والعوامل والمقاييس المستخدمة في نظم الاسترجاع والترتيب الطيفي لمحركات البحث بصورة أقرب مما يقومون به قراصنة الحاسوب في التعامل مع فرائسهم من الشبكات والنظم والحواسيب مما يجعل خداع محركات البحث أحد أهم التحديات التي تواجه محركات البحث فنتائج محركات البحث تتأثر بشكل كبير وخطير مما قد يستتبع أن يفقد محرك البحث مصداقية نتائجه لدى المستفيدين وبالتالي عدم ثقة المستفيد في هذا المحرك مرة أخرى.

أوجه الضرر التي قد تلحقه الخادعات بمحركات البحث فتتمثل في :

- تصعيب مهمة المستفيدين في إرضاء حاجتهم المعلوماتية information needs.
- ارساء خلفية سيئة تجاه محرك البحث ونتائجها وعدم مصداقتها.

¹⁴ Eric Convey. Porn sneaks way back on Web. *The Boston Herald*, May 22, 1996

¹⁵ Gyongyi, Z., & Garcia-Molina, H. (n.d.). Web Spam Taxonomy. Web Spam Taxonomy. Retrieved July 21, 2011, from air-web.cse.lehigh.edu/2005/gyongyi.pdf

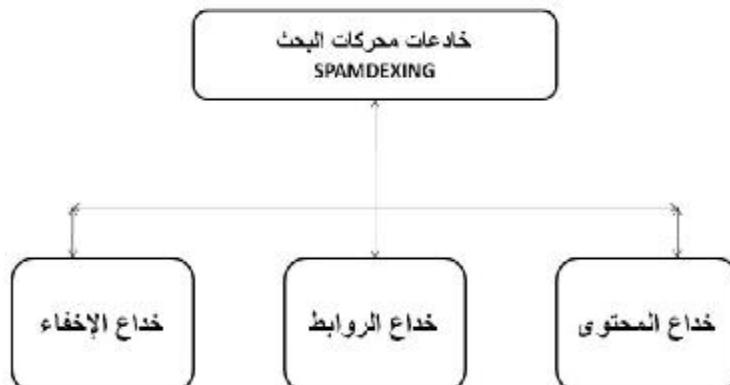
¹⁶ Gyongyi, Z., & Garcia-Molina, H. (n.d.). Web Spam Taxonomy. Web Spam Taxonomy. Retrieved July 21, 2011, from air-web.cse.lehigh.edu/2005/gyongyi.pdf

- تلویث كشاف محركات البحث بموقع زائفه.
- حرق النطاق الترددی للزواحف او ما يعرف ب Bandwidth.
- تشويه نتائج محركات البحث.
- قدرة الخادعات على توليد العديد من شبیهاتها.
- وقد يمتد الضرر إلى اصحاب الموقع، فقد يدفع مدراء الموقع إلى التخلی عن جهودهم في توفير صفحات ومحفوی ذو جودة مرتفعة، اخذین على عاتقهم مهمة انشاء محتوى يستطيع ان يتعامل مع محركات البحث مما يستتبع ان يجعل محتوى الشبکة العنکبوتیة موجه إلى محركات البحث بدلا من ان يوجه إلى مستقیدي الشبکة العنکبوتیة الامر الذي يشكل کارثة في نهاية المطاف على الشبکة العنکبوتیة¹⁷.

فئات خادعات محركات البحث:

يمكن ان تصنف خادعات محركات البحث من خلال تقنياتها وأهدافها إلى:

- خداع محتوى الموقع.
- خداع روابط الصفحات.
- الخداع معتمد على اخفاء او تضمين الصفحات.



خداع المحتوى:

تعتمد هذه الفئة على تغيير محتوى صفحات العنکبوتیة للحصول على رتبة أعلى في نتائج محركات البحث وتعد اشهر تقنيات الخداع المعتمد على المحتوى هي تكرار الكلمات المفتاحية داخل صفحات العنکبوتیة، واستخدام الكلمات غير المتصلة بسياق او موضوع الصفحة او اضافة قاموس كامل من المصطلحات في نهاية الصفحة سعيا به لأن يكشف في

¹⁷ Detecting Spam Web Pages. Marc Najork. Microsoft Research, Silicon Valley

محركات البحث ومن ثم تسكينها وفقاً للمصطلحات والكلمات الواردة في القاموس داخل قاعدة بيانات محرك البحث ومن ثم استرجاع الصفحة في كافة عمليات البحث في ظل الاعتماد على المماثلة أو المشابهة في الاسترجاع.

دور المصطلحات والألفاظ في خداع المحتوى:

يجدر في البداية إلى اشارة ان كافة اشكال المحتوى في صفحات ومواقع العنكبوتية يتم تمثيلها وفقاً للفظ والمصطلح فالصوره والملفات الفيديو والملفات ثلاثية الابعاد وغيرها يتم تковيدتها وفقاً للغة النص التشعبي الفائق HTML تكون في صورة نصية أي في صورة الفاظ ومصطلحات طبيعية او برمجية ولا يقتصر الامر على هذا فحسب بل ان تكشف الوثائق (مهما كان محتواها نصي او صوري او ملف فيديو) داخل محركات البحث يتم وفقاً للنص.

إن محركات البحث تلجأ في تقييم درجة الصلة الوثائق بالاستفسار إلى تحديد المصطلحات الواردة في الاستفسار داخل صفحات الموقع، او مايعرف بالمضاهاة، غالباً ما يكون ظهور هذه المصطلحات في أماكن محددة داخل محتوى الوثيقة ، تعرف هذه الاماكن وفقاً لخوارزميات محركات البحث باسم الحقول Fields وتعد أشهر الحقول داخل الوثيقة هي حقل جسم الوثيقة والعنوان ووصفات البيانات والمحدد الفريد للموقع وتعد هذه الحقول بمثابة مفاتيح محتوى الوثيقة ومحدداتها، وبالتالي تلجأ محركات البحث إلى تحديد درجة الصلة بين الاستفسار والوثيقة من خلال محتوى هذه الحقول، ومن ثم تعدد هذه الحقول ايضاً بمثابة الصيد الثمين لخداعات محركات البحث بل تمثل النقاط الحيوية للتلاعب.

خوارزميات خداع محتوى الواقع:

إن اغلب خوارزميات محركات البحث المستخدمة في ترتيب النتائج تعتمد وبشكل اساسي على استخدام انماط مختلفة من المعادلات والحسابات المختلفة ولكن تعد خوارزمية tf-idf القاسم المشترك بين اغلب هذه الخوارزميات وتحسب العلاقة بين الوثيقة والاستفسار من خلال المعادلة الآتية والتي سبق الاشارة اليها:

$$tf-idf(p, q) = \sum_{t \in p, t \in q} tf(t) \cdot idf(t)$$

وفي هذا يعتمد الخادعون spammers على هذه المعادلة لتحقيق هدفين اساسيين اولهما: جعل صفحاتهم تتصل بعدد كبير من الاستفسارات وذلك من خلال جعل صفحاتهم لا تحصل على الرقم صفر كناتج لهذه المعادلة ويتم تحقيق ذلك من خلال تضمين مجموعة كبيرة وضخمة من المصطلحات بنية الوثيقة.

اما الهدف الثاني فهو فيتمثل في جعل الوثيقة تكثر صلة باستفسار محدد وبالتالي تحظى برتبة عالية في نتائج محركات البحث من خلال ان تحصل على درجة عالية في المعادلة السابقة تقاد تصل إلى رقم 1 ويتم تحقيق ذلك من خلال تكرار مصطلحات محددة في بنية الوثيقة او في الحقول التي سبق الاشارة اليها.

تقنيات خداع المحتوى:

- خداع حقل جسم الوثيقة :document body
في هذا الحقل يتم تكرار المصطلحات الخادعة في المضمنة في جسد الوثيقة.
- خداع حقل العنوان :title
مؤخراً، تعمل خوارزميات محركات البحث على اعطاء أعلى وزن للمصطلحات التي ترد في عنوان الوثيقة وبالتالي يعمل الخادعون على تضمين المصطلحات الخادعة في عنوان الوثيقة.
- خداع حقول واصفات البيانات :meta tags
تظهر حقول واصفات البيانات في رأس الوثيقة التي تم تكويدها بلغة النص الفائق التشعبي شكل رقم 2 والتي تعد بمثابة هدف اساسي ورئيسي للخداعات ونظرًا لذلك استغنت محركات البحث في الوقت الراهن عن اعطاء وزن مرتفع للكلمات التي تظهر في حقول واصفات البيانات بل ووصلت إلى أنها تتجاهلها تماماً
`<meta name="keywords" content="money, bank, finale">`
- خداع حقل العنوان الموحد للموقع URL:
يعد محدد الموقع بمثابة محدد فريد لدرجة صلة الوثيقة بالاستفسار ورغم ذلك تخلت محركات البحث في الاعتماد عليه نظراً لمتداد يد الخادعات لتشملها، حيث يعمل الخادعون على إنشاء محدد موقع طويل يشتمل على مصطلحات خادعة وبالتالي حينما يتم تكشيفه تدرج هذه المصطلحات في كشافات محرك البحث ومن ثم ظهور نتائج لا تتصل باستفسار المستفيد.
- تكرار الكلمات المفتاحية :Repeated keywords
حيث يتم في هذه التقنية تكرار الكلمات المفتاحية عدة مرات في الوثيقة، وتعد هذه التقنية فعالة جداً في ظل الاعتماد على البحث على خوارزمية تعطي وزن أكبر للوثيقة باحتساب عدد مرات ظهور الكلمات المفتاحية وفي ظل الشتمال الوثيقة على نفس الكلمات مفتاحية التي وردت في استفسار المستفيد.
- إخفاء المحتوى :Content Hiding
تعتمد هذه التقنية على إخفاء بعض الكلمات المفتاحية بحيث لا ت تعرض حينما يقوم المتصفح بعرض الصفحة، ويتم ذلك من خلال عملية تمويه الكلمات والمصطلحات حيث يتم جعل لون هذه الكلمات بنفس لون خلفية الوثيقة، أو من خلال كتابتها بصورة ضئيلة ومتناهية في الصغر.

إغراق محتوى الوثائق بالمصطلحات الاستفسارية:

حيث تعتمد هذه التقنية على اغراق محتوى الوثيقة بالمصطلحات الخادعة والكلمات المفتاحية التي لا علاقه لها بالموضوع ويتم ذلك من خلال انشاء ما يعرف بقاموس المصطلحات الخادعة داخل الوثيقة بحيث يشتمل هذا القاموس على مصطلحات مختلفة تضاهي اي كلمات مفتاحية قد ترد في اي استفسار يوجه إلى محرك البحث مما يستتبع ان تظهر الوثيقة كنتيجة للعديد من الاستفسارات، ويتم اخفاء القاموس في نهاية الوثيقة داخل كود النص الفائق للوثيقة.

○ الخداع المعتمد على واصفات الكيانات:

سبق وقد اشرنا ان محركات البحث في تكشفها للصور وملفات الفيديو وغيرها من ملفات الوسائط المتعددة - والتي عرفت باسم الكيانات Objects للتمييز بينها وبين نص الوثيقة- تعتمد النصوص الملحة بالكيان كالنص الموجود في اسفل الصورة كتعليق عليها وتوضيح لها وهو ما يعرف في لغة النص الفائق التشعبي بحقل بديل النص Alt text وعادة لا يرى المستخدم هذا الحقل إلا عندما يقف عليه بالفأرة، وتلجأ محركات البحث لهذا النص في تكشف محتوى الصورة، مما جعل الخادعون يعملون على اضافة مصطلحات خادعة داخل بينة هذا الحقل بحيث تكشف المصطلحات الخادعة مع المصطلحات الاساسية مما يوفر فرصة في ظهور الوثيقة عند البحث عن صورة لموضوع معين.

○ ناسخات المواقع:

تعمل هذه التقنية على استنساخ او كشط المحتوى الكامل للموقع بهدف انشاء مثل هذا الموقع لجمع عائدات مادية والتلاعب في رتب نتائج محركات البحث.

خداع الروابط:

تعتمد الكثير من محركات البحث على خوارزميات تحليل الروابط بين الوثائق وذلك في ظل ما تتمتع به بنية الشبكة العنكبوتية من روابط بين وثائقها، مما جعل محركات البحث تعتمد على الروابط كمؤشر في تحديد اهمية الوثيقة ودرجة الصلة بينها وبين الموضوعات المستفسر عنها من قبل المستفيد.

تقوم تقنيات خداع الروابط على تغيير بنية الروابط لصفحات الموقع لمحاجمة محركات البحث المعتمدة على استخدام خوارزميات الروابط للترتيب الطيفي لنتائجها مثل خوارزمية رتبة الصفحة pagerank ونموذج HITS والتي سبق الاشارة اليها وتعتبر اشهر تقنيات الخداع المعتمد على الروابط هي بناء ما يعرف بمزرعة الموقع وتبادل الروابط وهو ما سنعرض له الان.

○ مزارع الروابط :Link farm

تعتمد هذه التقنية على اضافة عدد من الروابط التي تشير إلى موقع معروفة وتتمتع بشعبية على امل أن تكون الصفحة مصدراً للصفحات الموثوقة بها، ويتم تجميع هذه الروابط من خلال نسخ الموقع المرتبطة في الاكملة الموضوعية Directory

- والتي حظيت بفهرسة دقيقة وموثوقة - ثم تسكينها في الصفحة الخادعة وبالتالي حينما تقوم محركات البحث بترتيب هذه الصفحة نجد انها تحظى برتبة عالية في كونها مصدرا للروابط او المواقع ذات الموثوقية.

○ خداع معتمد على اخفاء او تضمين الروابط :Create a honey pot

تعتمد هذه التقنية على الروابط التي تشير إلى صفحة ما، فمن الممكن ان تشتمل بعض الصفحات على معلومات مفيدة تجعل المستفيد يستخدمها، ولكن تشتمل هذه الصفحات على روابط خفية لصفحة الخادعة من خلال هذه الروابط تحظى هذه الصفحة برتبة عالية في نتائج محركات البحث.

○ تبادل الروابط :Link exchange

تعتمد هذه التقنية على اتفاق بين اصحاب المواقع او مدرييها والتي تتمثل في اضافة الرابط الخاص بك في صفحاتهم على ان تضيف رابطهم في صفحتك، بغض النظر عما اذا كان رابطهم يتصل بموضوع صفحتك او لا مما يسمح بظهور هذه الصفحة في نتائج محركات البحث.

○ شراء الروابط :Link purchase

وتعتمد هذه التقنية على ان تقوم بعض المواقع بأن تدفع مبالغ لبعض المواقع لتضمين روابط صفحاتهم ضمن صفحات الموقع الآخر.

○ شراء النطاقات المنتهية :Expired domains

وتعتمد هذه التقنية على ان يقوم المخادعون بشراء نطاقات منتهية او قد غيرت ووضع محتوى غير مفيد، في ظل تمنع هذا النطاق برتبة جيدة داخل نتائج محركات البحث.

○ تقنية صفحات الابواب الخلفية :Doorway pages

تعتمد هذه التقنية على انشاء صفحة خادعة من اجل خداع كشاف محركات البحث تظهر في نتائج محرك البحث وعندما يقوم المستفيد بالنقر عليها يتم اعادة توجيهه إلى صفحة اخرى مما يسمح بارتفاع رتبتها داخل محرك البحث في ظل تكرار الزيارات لها من قبل المستفيدين، إن فكرة هذه التقنية تعتمد على كود يعرف باسم Meta refresh والذي يعمل على اعادة تنشيط الصفحة خلال فترة زمنية وفقا لمحدد اخر وتوضح في المثال الآتي:

<meta http-equiv="refresh" content="5;url=http://example.com/" >

يعد هذا الكود من اكواد الميتا الخاص بعمل تنشيط للصفحة خلال فترة زمنية معينة وعلى ان يحدد URL الخاص بالموقع كما هو مبين في الاعلى ، ما يقوم به الخادعون Spammers ان يلصقوا URL الخاص بهم مما يؤدي إلى انه اثناء

تحميل الصفحة الرئيسية يتم عمل تنشيط لها خلال خمس دقائق وتوجيه الصفحة للURL الآخر مما يوفر فرصة لوثيقة الخادعة ان تحظى برتبة عالية نتائج محركات البحث في ظل ارتفاع معدلات الزيارة لها.
ولا تعد هذه الطريقة هي الطريقة الوحيدة لعمل ابواب الخلفية بل يمكن انشاؤها من خلال ما يعرف بنصوص الجافا . JavaScript

○ الروابط المنفجرة Link bombing spam

حيث ان الروابط في البنية العنكبوتية بمثابة روابط حرة يمكن ان تطعم بالكثير من العبارات والكلمات المفاحضة، ومن ثم يكون تحظى الصفحة المشار اليها برتبة عالية في نتائج محركات البحث.

○ خادعات التعليقات والمدونات Comment or blog spam

تعتمد هذه التقنية على ان يقوم الخادعون بالإضافة روابط خادعة لبعض الموقع والمدونات التي تحظى بسمعة طيبة في ترتيب نتائج محركات البحث.

خادعات اخفاء الصفحات:

من الطبيعي ان يقوم الخادعون Spammers بإخفاء الأدلة او ما يثبت انشطتهم الخادعة، ويتم ذلك من خلال استخدام العديد من التقنيات لتخفي عن المستفيدين الذين يقومون بزيارة الموقع او الصفحات الخادعة، او اخفائها عن محرري شركات محركات البحث الذين يسعون إلى تحديد حالات الخداع.

○ الحجب Cloaking

تعتمد هذه التقنية على أن تقوم بعض خدمات الموقع الخادعة Sam web searver بتحديد زواحف محركات البحث وذلك من خلال عنوانها IP الخاصة بالزائف، ومن ثم تقوم هذه الخادعات بتوفير محتوى خاص للزائف غير الذي تقدمه للمستفيدين ومن ثم الحصول على الظهور في بعض النتائج غير المتصلة.

○ الخداع المعتمد على الطبقات Layer based spam

تعتمد هذه التقنية على الخداع من خلال ما يعرف بطبقات (Cascading Style Sheets) CSS لتنسيق طراز الصفحة، حيث تعد تقنية CSS أحد التقنيات الخاصة بتنسيق الصفحات من خلال طبقات، يقوم المخدعون بتزويد الموقع بطبقة غير مرئية للمستخدم حين العرض حيث تشتمل على المحتوى الخادع لمحركات البحث.

○ الخداع الاستفساري Query spam

حيث تعمد هذه التقنية على توجيهه اسئلته لوحدة الاستفسار الموجودة داخل بنية الزائف بهدف تلویث ملف الاستفسار لديه.

يمكن القول بأن هناك ثلاثة عوامل رئيسية خارجية تقف كعقبة في طريق محركات البحث في القضاء على الخادعات.

1- التطور السريع لاساليب وخوارزميات خداع محركات البحث لملحقة تطور خوارزميات التكشيف في محركات البحث.

فقد عملت الخادعات spams على تضليل محركات البحث منذ الولادة الأولى لظهور الثانية، فبداية عمدت الخادعات إلى تقنية حشو الكلمات المفتاحية keyword stuffing داخل كشافات محركات البحث في ظل اعتماد محركات البحث على منهجيات وخوارزميات نظم المعلومات التقليدية في التكشيف. مثل تقنية TF-IDF.

وقد كان هذا الأمر دافعا للباحثين والعلميين في حقل محركات البحث على توفير خوارزميات تكشف أخرى لمحركات البحث بمنأى عن خادعات البحث، فظهرت خوارزمية الترتيب الظبي المعتمد على الروابط link based ranking algorithm في ظل تضليل فاعلية الخوارزميات السابقة، ولكن سرعان ما أوجد الخادعون أسلوبا جديدا للتعامل مع هذه الخوارزمية الجديدة عرف هذا الأسلوب باسم link bombing or link farms الأمر الذي جعل الباحثين إلى تصوير هذا الوضع بالحرب بين الخادعين ومحركات البحث.

2- التنوع الواسع في تقنيات خادعات محركات البحث:

يعمل منشوا خادعات محركات البحث على إنشاء العديد من خوارزميات وتقنيات الخداع المختلفة مما يجعل الأمر صعبا على محركات البحث في ايجاد منهجة او خوارزمية موحدة للكشف عن خوارزميات الخداع وبعد احد اهم الأمثلة في هذا المقام اسلوب الخداع المعتمد على نمطية الحجب cloaking behavior (أحد التقنيات الخاصة بخداع محركات البحث يعتمد على ان يرسل إلى زائف محرك البحث محتوى مختلف عن المحتوى الذي يراه المستفيدين من خلال اخفاء بعض النصوص في صفحات التكويذ الخاصة بالموقع). بالإضافة إلى هذا يصعب على محركات البحث التعرف المسبق على طبيعة ونوع الخداع المحتمل ان يتعرض له بحيث يمكن ان يشبه هذا الأمر بمعركة مع خصم غير مرئي.

3- استمرارية النمو الهائل للشبكة العنبوتية:

حيث تعد استمرارية نمو الهائل للشبكة العنبوتية سببا تتضاعل فرضية الاعتماد على البشر في ملحقة والتحقق من صفحات المواقع بدلا من الآلة (الزواحف)، على الرغم مما يكفله طبيعة العمل البشري من القدرة المنطقية في الحكم على المحتوى مما يجعل فرصة خداع محركات البحث تتضاعل امام الخادعين، ولكن اغلب ما تتخذه محركات البحث من اجراءات تأخذ الطابع الآلي وبالتالي يجدر على محركات البحث في ظل عدم اعتمادها على القدرة البشرية واستبدالها بالطاقة الآلية في الحكم على المحتوى ان تعمل على اختبار خوارزمياتها الخاصة بمكافحة الخادعات على نطاق واسع ومتنوع من البيانات المتاحة على الويب، وفي هذا المقام يجب توضيح نقطة هامة ان غالبية الخوارزميات التي تتخذها

محركات البحث في مكافحة الخادعات تعمل بشكل جيد على العينات من الواقع والصفحات ولكن الأمر يختلف جذرياً في التعامل مع المحتوى المتدايق من العنكبوبية¹⁸.

العنكبوبية غير المرئية كتحد لخوارزميات محركات البحث في استرجاع المحتوى:

يمكن النظر إلى العنكبوبية العالمية وفقاً لمنظور البحث والاسترجاع على أنها تنقسم إلى قسمين:

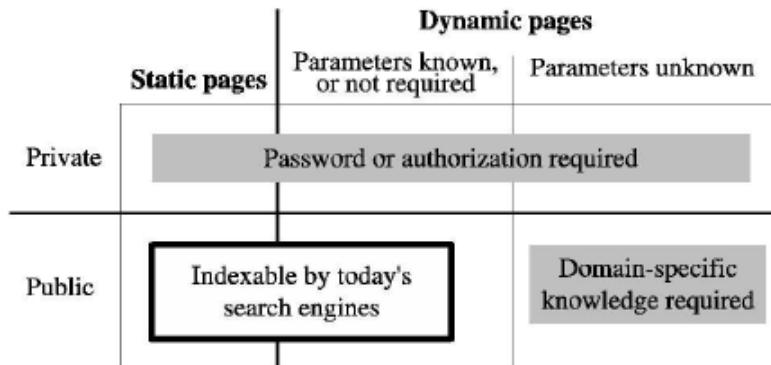
القسم الأول: العنكبوبية السطحية Surface web أو العنكبوبية القابلة للتكتشيف Publicaly Indexable web أو العنكبوبية المفتوحة Open web: وهي تلك الصفحات والمواقع التي تخضع للتجميع والتكتشيف والاسترجاع من قبل محركات البحث من خلال تتبع الروابط.

القسم الثاني: العنكبوبية غير المرئية Invisible web: وتعرف أيضاً بالعنكبوبية العميقa the deep web ، أو العنكبوبية المظلمة Darknet او ما تحت العنكبوبية Undernet: وتشتمل على مصادر المعلومات التي لا يمكن لمحركات البحث ان تخضعها للتجميع او التكتشيف او التسخين في فهارسها. كما هو موضح في الشكل رقم (20).

إن محركات البحث التقليدية تعتمد في إنشاء فهارسها وكشفاتها على تصفح وتتبع محتوى الواقع بغية اكتشاف الصفحة وتتبع ما بها من روابط للتجميع صفحات أخرى، وعليه يسقط من حسبانها البيانات والمصادر ذات الطبيعة المستقلة عن الروابط الفائقة هذه المصادر تشكل ما يعرف بالعنكبوبية الخفية، كما أن عجز محركات البحث لا يتمثل في عدم قدرته على التعامل مع العنكبوبية الخفية وحسب بل يمتد ليتضخم أن تغطية محركات البحث لما هو متاح على العنكبوبية المرئية لا يتجاوز من 20% - 50% ويعود ذلك إلى عدة أسباب:

- اعتماد محركات البحث على تقنيات تتسم بالحدودية في قدراتها حيث لا يمكن لزواحف محركات البحث مواكبة ومتابعة وتيرة الديناميكية التي تتخذها العنكبوبية في ظل التزام هذه الزواحف بداول زمنية قد تتفاقم التغيرات في الواقع خلال تكرار الزيارة لها من قبل الزاحف.
- ارتفاع التكاليف التي تتطلبها تشغيل محرك البحث بصورة شاملة فمن المعروف أن تحديد مصادر المعلومات والحفظ على حداثة كشافات محرك البحث بصورة دورية يعد أمراً مكلفاً للغاية.
- محاولة محركات البحث تجنب الخادعات ذات التأثير الضار لفهارسها وكشفاتها، ومن خلال تطويرها لمنهجيات صارمة تكفل تجنب مع هذه الخادعات، تحمل هذه المنهجيات عيوباً تستقضي استبعاد محتوى آخر.
- اختلاف محركات البحث فيما بينها من حيث خوارزميات التجميع والتكتشيف والاسترجاع لكل منهم، وقد أدى ذلك لما يعرف بالتدخل والتكرار في نتائج محركات البحث.

¹⁸Wu, B. (n.d.). FINDING AND FIGHTING SEARCH ENGINE SPAM. CiteSeerX. Retrieved July 21, 2011, from <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.91.6961>



شكل رقم (20) رسم توضيحي يوضح فئات الوثائق من خلال انواع العنکبوتية

تعرف العنکبوتية غير المرئية "بأنها ذلك الجانب من العنکبوتية الذي يشتمل على محتوى لا يمكن لمحركات البحث التعامل معه بالتجميع أو التتبع أو الاكتشاف نظراً للقيود والمحدودية التي تتمتع بها تقنياتها من زواحف وبرامج تصفح أو نظراً لسياسات التوجيهية لمحركات البحث في الاختيار المتعذر لمصادر ذات سمات وطبيعة محددة"¹⁹.

ويمكن تحديد خصائص العنکبوتية غير المرئية على النحو الآتي:

- يقدر حجم العنکبوتية غير المرئية من 400 - 500 مرة من العنکبوتية المرئية.
- تشتمل العنکبوتية على ما يقرب من 70 الف تيرابايت من المعلومات مقارنة بـ 9 الاف تيرابايت متاحة على العنکبوتية القابلة للتكتشيف.
- تشتمل العنکبوتية غير المرئية على ما يقرب من 550 بليون وثيقة منفردة مقارنة بـ 1 بليون وثيقة متاحة على نظيرتها.
- يشتمل العنکبوتية غير المرئية على أكثر المصادر تتمتع بمصداقية وموثوقية عما هو متاح على العنکبوتية السطحية.
- تشتمل غير المرئية على اغلب المصادر التي يمكن ان تتحقق نسبة مرتفعة من تلبية الحاجات المعلوماتية.
- 95% من معلومات العنکبوتية غير المرئية متاح مجاناً²⁰.

إن التحديات التي تواجهها محركات البحث في التعامل مع محتوى العنکبوتية غير المرئية تكمن في تعاملها مع هذه المفردات:

1. مستودعات قواعد البيانات :information stored in databases

¹⁹ Sherman, C., & Price, G. (2001). *The Invisible Web: uncovering information sources search engines can't see*. Medford, N.J.: CyberAge Books.

²⁰ MICHAEL K. BERGMAN. The Deep Web: Surfacing Hidden Value.available:
<http://brightplanet.com/images/uploads/12550176481-deepwebwhitepaper.pdf>

فهناك الآلاف او ربما الملايين من قواعد البيانات التي تشتمل على معلومات عالية الجودة والموثوقية والمصداقية، ما يتمثل في تحد لمحركات البحث يمكن في ان كل قاعدة بيانات تعتبر نظاما فريدا من حيث تصميم هيكل البيانات ومن حيث قدرات البحث والاسترجاع، ومن ثم فزوائف محركات البحث يمكن لها ان تصل إلى واجهات الاستخدام ولكن لاتمكن من الانتقال إلى المرحلة التالية وهي مستودعات قواعد البيانات نظرا لاختلاف بنيتها عما هو مبرمج عليه الزائف في التعامل معه.

2. صيغ التمثيل النصي : Formats of text

حيث ان غالبية محركات البحث صممت لإنقاط وتكشف النصوص التي صيغت وفقاً لصيغة اللغة النص الفائق دون النظر إلى صيغ التمثيل النصي الأخرى كـ pdf و Epub و dej vu و vug وغيرها نظراً لاحتاجها لمعالجة حاسبية معينة مما يوفر فجوة في التعامل مع بعض هذه الصيغ.

3. الوثائق المنقطعة : Disconnected

وهي الصفحات المتاحة على العنکبوتية والتي لا يشار إليها عبر الروابط الفائقة من قبل صفحات أخرى وهي تمثل غالبية العنکبوتية غير المرئية، ما يمثل تحدياً لمحركات البحث في هذا الصدد ان زواحف محركات البحث تعتمد في زحفها على تتبع الروابط الفائقة للإنقاط الصفحات ومن ثم اغفال الوثائق والصفحات التي لم يشر إليها من جانب الصفحات الأخرى.

4. المحتوى غير النصي : Untextual content

فالكثير من محركات البحث صممت زواحفها للتعامل مع المحتوى النصي او التركيز بشكل كامل على طبيعة هذا المحتوى دون النظر إلى البيانات الأخرى ومن ثم اغفال قدر ليس بالصغير من المحتوى الممثل في صور أخرى، ومع ذلك قد نجد الكثير من محركات البحث تضمن امكانية البحث من خلال البيانات الأخرى كالبحث عن الصور والصوت والفيديو ولكن يجب الاشارة إلى ان محركات البحث لم تقم بتجميع هذه البيانات بصورة مستقلة بل ان هذه البيانات مدرجة في وثائق نصية ووتكتسب قابلية البحث من خلال عمليات الفرز التي تتم داخل كشافات محركات البحث كما ان هذه البيانات تكشف من واقع التعليقات نصية سابقة او لاحقة او من خلال ما يعرف بـ "البدائل text alternative (ALT)" والذي ينشئ من قبل مصمم الوثيقة.

5. المحتوى ذات الطبيعة الانية : Real-time content

حيث تشتمل العنکبوتية على محتوى يتسم بانها ديناميكية الوقت في وجودها وفي تعطل محتواها، كداول الطيران واسعار الاسهم وغيرها، الامر الذي لا يوفر لمحركات البحث فرصة في التقاطه نظراً للتداول الزمنية لانطلاق الزواحف وتكرار الزيارة.

6. تقييد زواحف محركات البحث من خلال بروتوكول استبعاد الروبوتات : Robots Exclusion Protocol

وهو عبارة عن مجموعة من القواعد التي تمكن مدیروا المواقع من تحديد الاجزاء المفتوحة من الخوادم ليتعامل معها الزاحف واي منها مغلق خارج نطاق التعامل. ويتم ذلك من خلال ان يقوم مدیروا المواقع بانشاء قائمة من الملفات او الادلة التي لا يجب لها ان تجمع او تكشف ثم حفظها في الخادم تحت مسمى robots.txt.

7. اقصاء الزواحف:

يتم ذلك من خلال ان يقوم مدیروا المواقع بتضمين عبارة NoIndex في حقول الميتاداتا في راس الوثيقة.

8. كلمات السر:

وتعد التقنية الاكثر قوة في تجنب تكشيف المحتوى للوثائق حيث تعتمد على حاجز تقني لابعد الزاحف عن التجميع.

سلوك وانماط تفاعل المستفيدين مع محركات البحث:

يمثل المستفيد المحور الثاني بعد محور النظام في منظومة محركات البحث User-oriented وهو ذلك المنحى من دراسات محركات البحث الذي يهتم بدراسة طبيعة المستفيد البحثية، ونمط سلوكه البحثي، ومقومات لغته، والمتغيرات العلمية والتقاريفية والاجتماعية التي تؤثر في صياغة استفساره.

الاستفسارات واسترجاع المحتوى على العنکبوتیة:

ذهب Broder إلى ان العنکبوتیة قد حملت معها انماطاً جديدة لحالات المستفيدين في التعامل مع المعلومات سواء كان على صعيد البحث او الاسترجاع، وقد امتدت هذه الانماط لتشكل فئات جديدة من الاستفسارات المعلوماتية لدى المستفيدين، ففي سياق العنکبوتیة، لا تقتصر الحاجة the need من وراء الاستفسار على ان تكون ذو طبيعة معلوماتية فحسب بل تمتد لتشمل 3 اقسام اخرى الحاجة:

- الحاجة الملاحية Navigational need .
- الحاجة المعلوماتية Informational need .
- الحاجة الاجرائية Transactional need .

1- الحاجة الملاحية:

يعد نمطاً حديثاً من الاستفسارات فالغرض منه هو الوصول إلى موقع أو مصدر معلومات معين لدى المستفيد وأن الحاجة من وراء هذا الاستفسار تتمثل في أن المستفيد ربما قد زار أو تعرض لهذا الموقع من قبل أو على فرضية أن مثل هذا الموقع يمكن ان يكون موجوداً على العنکبوتیة. إن هذا النمط من الحاجات أو البحث كان يشار إليه سالفاً بالبحث عن

"المفردة المعروفة" بمعنى ان المستفيد يكون على دراية وعلم بأن هذه المفردة (سواء كانت هذه المفردة وثيقة او ملف صوتي او موقع .. الخ) موجودة على العنکبوتية.

2- الحاجة المعلوماتية:

بعد هذا النمط تقليديا إلى حد ما فالغرض منه لا يختلف كثيرا عن الغرض من الحاجات المعلوماتية من نظم الاسترجاع التقليدية وهو ايجاد المعلومات التي يفترض ان تكون متاحة على العنکبوتية في صورة ثابتة ولكن سمة امتياز امتازت به العنکبوتية تمثل في قدرتها على المزج بين البيانات المتاحة من خلال المصادر المختلفة في صورة اقرب لتحقيق التكاملية بين مصادر العنکبوتية فمثلا من خلال البحث عن مدينة الرياض في بعض محركات البحث تكفل خوارزميات هذه المحركات القدرة على توفير مصادر المعلومات التي تتناول الرياض ثم تستطرد لسترجع اسماء فنادق الرياض والمعالم الاثرية بها... الخ .

3- الحاجة الاجرائية:

والغرض من طبيعة هذه الحاجة هو الوصول إلى موقع تتعالا فيها سمة التفاعل سواء كان بين المستفيدين بعضهم البعض (كالشبكات الاجتماعية) او تفاعل المستفيدين مع الالة (كتحميل الملفات والتزيل الهابط وكالمعاملات التجارية مع البنوك).

اما عن فئات الاستفسارات فتشمل الاقسام الآتية:

1. الاستفسارات البولينية Boolean Queries: وهي تلك الاستفسارات التي تعتمد على الروابط المنطقية (- and - or - not) في صياغته.
2. الاستفسارات باللغات الطبيعية Natural Language Queries: وهي تلك الاستفسارات التي تصاغ في صورة سؤال او جملة خبرية.
3. الاستفسار المكنزي Thesaurus Queries: وهو النمط الذي يعتمد على ان يقوم المستفيد باختيار مصطلح من قائمة بالمصطلحات معدة سلفا من جانب نظام الاسترجاع او محرك البحث.
4. الاستفسار المبهم Fuzzy Queries: والذي يعكس انماط الاسئلة التي تشتمل على اخطاء املائية او مشتقفات من الجذور اللغوية.
5. الاستفسار بالتجاور Term Searches: وهو نمط الاستفسارات الذي يعتمد على صياغة السؤال في جملة واحدة دون تفتيتها.

استفسارات المستفيدين كتحدى يواجه محركات البحث في استرجاع المحتوى:

حمل ظهور العنكبوتية العالمية في بدايتها مؤشرات شتى كان أولى هذه المؤشرات نهاية حقبة ما يعرف بالبحث من خلال وسيط المعلومات، فقد كفلت العنكبوتية وللمرة الاولى للمستخدم القدرة على ان يقوم بالبحث بنفسه دون الحاجة إلى وسيط للبحث تتفاوت من خلاله عملية البحث او تتبسيط وفقا لعوامل متغيرة.

ويرى Ricardo baeza ان التحديات التي تواجه محركات البحث في تفاعل المستفيدين معها تكمن في محوريين اساسيين:

• التعبير عن الاستفسار وصياغته:

ان التعبير عن الحاجات المعرفية لدى البشر في صورة استفسارات لا يعد امر سهلا في كثير من الاحيان ، حتى وإن كان هذا التعبير باللغة الطبيعية، فالاستفسار في افضل صورة ما هو الا انعكاس لاحتياجات المعلومات وبالتالي قد يفتقر هذا الانعكاس إلى الدقة او الوضوح فضلا عن العوامل الاجتماعية والثقافية والعلمية التي تلعب دورا في التعبير عن الحاجة المعرفية.

• تفسير الاجابات والنتائج:

حتى ان المستفيد قادرا على التعبير بشكل مثالي عن حاجته من خلال استفساره، فمن الممكن للاجابة ان تتضمن على الاف او ملايين الوثائق التي تتفاوت معاها بعض القضايا التي تتعلق بمطابقة حاجة المستفيد أم لا، او كيفية ترتيبها في نسق منطقي واسباب هذا الترتيب، وكيف يمكن ان تستخدم هذه الوثائق بفاعلية من جانب المستفيد.

ويتمكن اجمال التحديات التي تتعلق بتفاعل المستفيدين مع محركات البحث على النحو الاتي:

1- حجم الاستفسارات:

إن حجم استفسارات المقدمة إلى العنكبوتية في نمو مستمر فقد بلغت نحو 10 مليار استفسار عام 2008 موجه إلى 5 محركات بحث (Google, Yahoo!, MSN, AOL, Ask Jeeves). كما أن عدد الاستفسارات الموجهة لمحرك البحث جوجل اكبر من 200 مليون استفسار يوميا عام 2003، لتصل هذه النسبة في عام 2010 إلى 3,5 مليار استفسار يوميا بمعدل يصل إلى 40,000 استفسار في الثانية، وبالتالي تعد هذه المؤشرات بمثابة تحدي كبير يواجه محركات البحث.

2- صياغة الاستفسار:

عادة ما يميل المستفيدين إلى تقديم استفسارات أعم بكثير من الحاجة الفعلية إلى المحتوى، والمرجعية وراء ذلك تكمن في ظن المستفيد بأن محرك البحث يمكن أن يعمل على مستوى أعرض وليس على مستوى التخصيص، هذا من ناحية ومن ناحية أخرى كشفت الدراسات المقارنة – القائمة على تحليل ملفات النظام لمحركات البحث – أن سلوك المستفيدين في البحث على المعلومات ينطوي على أن معدلات الاستفسارات المقدمة لمحرك البحث تتسم بالقصر فمعظم المستفيدين يدخلون

ما بين مصطلحين إلى ثلاثة مصطلحات في الاستفسار الواحد، ويدخل ما بين استفسارين إلى ثلاثة استفسارات في عملية البحث الواحدة.²¹

3-نط الاستفسار :

إن 50% من إجمالي الاستفسارات المقدمه لأحد محركات البحث كانت تبدأ بعبارات استفهامية مثل "Where do I find" . ..؟ كيف أجد" وأن 25% من المستفيدين يبدؤن بحثهم بعبارات طلبية مثل "احضر لي معلومات عن information" ، في حين أن معظم محركات البحث تعتمد في المقام الأول على الكلمات المفتاحية مما يسفر في الحالات السابقة عن الكثير من النتائج غير المرضي عنها من قبل المستفيد.

4-معدلات توزيع مفردات ومصطلحات البحث:

أوضحت إحدى الدراسات البحثية أن معدل توزيع تردد مصطلحات الاستفسار يتسم بالانحراف من إجمالي عمليات البحث فقد كشفت هذه الدراسة أن بعض المصطلحات تستخدمن بشكل متكرر في مقابل الكثير من المصطلحات التي تستخدم مرة واحدة فقط ففي احدى الدراسات تم الكشف عن ان 63 مصطلح حظي بتردد ظهور بلغ أكثر من 100 مرة، في حين كون هذه المصطلحات تمثل أقل من 1% من إجمالي المصطلحات. مما يظهر طبيعة أن البحث على العنکبوتیة يمكن وصفه بأنه بحث بمصطلحات تتسم بنسبة منخفضة في تردد الظهور مقابل مصطلحات تتسم بتردد عالي في الظهور.

5-إعادة صياغة الاستفسار:

أن معظم الباحثين على محركات البحث يلجاون إلى صياغة حاجتهم البحثية في صورة استفسار واحد فقط دون اللجوء إلى إعادة صياغته مرة اخرى بمعدل بلغ اثنين من 3 باحثين وبصورة عامة بلغت نسبة المستفيدين الذين يعتمدون على تعديل استفسارتهم في البحث على العنکبوتیة نحو 44% بينما بلغت نسبة من يقوم بتوجيه اكثرب من 3 استفسارات في عملية البحث الواحدة نحو 25%.

6-الاعتماد على الروابط البولينية والبحث المتقدم:

بلغت درجة الاعتماد على الروابط البولينية في عمليات البحث على درجة تكاد تصل إلى الندرة في عملية البحث داخل محركات البحث فشخص واحد من اجمالي 18 شخص يلجأ إلى الاعتماد على الروابط البولينية فضلا عن شخصان من اصل 3 اشخاص يستخدم هذه الروابط بصورة خاطئة.²²

²¹ Jansen, B. J., & Spink, A. (2003). An analysis of web information seeking and use: Documents retrieved versus documents viewed. In Proceedings of the 4th International Conference on Internet Computing, pp. 65-69. Las Vegas, Nevada. 23-26 June.

نتائج والتوصيات:

أولاً: النتائج:

تمثل نتائج الدراسة في حصر التحديات التي تواجه محركات البحث بعد التعرض لها بالحصر والتحليل فيما سبق ويمكن اجمال التحديات على هذا النحو:

أولاً: التحديات الداخلية النابعة من خوارزميات محرك البحث والتي تعوقه في استرجاع المحتوى:

1. الزواحف:

- لا يستطيع الزاحف تحميل وتجميع كافة الصفحات المتاحة على العنکبوتیة، وفي ظل ذلك يجدر على الزاحف ان يحدد الصفحات التي يجب زيارتها وذلك وفقا لأهميتها.
- صعوبة تحديد الحد الادنى من التحميل والتجميع للمحتوى.
- صعوبة الكشف عن وجود مكررات على العنکبوتیة على صعيد المحتوى.
- صعوبة تحديد المجموعات البذرية للمحتوى اي ما هي الصفحات التي يجب ان تزار اولا.

2. التكشيف:

- عمليات التأكيد Tokenization والتي تعتمد على أن يقوم محرك البحث بتفتيت المحتوى الكامل إلى كلمات مستقلة وهو لا يتناسب مع طبيعة بعض المحتويات الخاصة بالوثائق ففرضًا إذا تم تفتيت معاذلة حسابية فوفقا لهذا المبدأ لا يمكن لمحركات البحث ان تسترجع المعادلات الحسابية أو الرياضية.
- ما تقوم به محركات البحث من أستبعد لبعض الكلمات في المحتوى والتي قد تحمل دلالة ضئيلة ولكنها في ذات الوقت تلعب دورا محوريا.
- منهجة التكشيف في محركات البحث التي تقضي باستخراج الجذور الصرفية للمصطلحات الواردة في المحتوى ودون أن تأخذ في اعتبارها أن اللغة العربية تتسم جذورها الصرفية بالتعقيد وعدم المرونة.
- مفاضلة محركات البحث بين صغر حجم الكشاف وبين القدرة على إجابة الاستفسارات المعقدة من محتوى الوثائق.
- بناء الكشافات الفرعية ضمن الكشاف المقلوب مما يسمح بوجود تداخل وتكرار في نتائج المحتوى.

3. الترتيب للمحتوى المسترجع:

²² Jansen, B. J., & Spink, A. (2005). How are we searching the World Wide Web? A comparison of nine large search engine transaction logs. *Information Processing and Management*, 42(1), 248-263.

- الاعتماد على المقياس الثاني في الاسترجاع والذي يعتمد على أن ترجيح المحتوى المسترجع بين كفتين فقد أما متصل باستفسار المستفيد وأما غير متصل.
- الاعتماد على التكشيف المعجمي وما يحمل من مشكلات تتعلق بالترادف اللغوي أو التجانس اللغوي.
- الإعتماد على نظرية الاحتمال في الاسترجاع.

ثانياً: التحديات الخارجية التي تعوق استرجاع المحتوى في محركات البحث:

1. خادعات المحتوى لمحركات البحث:

وما تحمله من قضايا تزورق محركات البحث والتي تتمثل في:

- تصعيب مهمة المستفيدين في ارضاء حاجتهم المعلوماتية information needs.
- ارساء خلفيّة سلطة تجاه محرك البحث ونتائجها وعدم مصداقيتها.
- تلویث كشاف محركات البحث بمواقع زائفة.
- حرق النطاق الترددي للزواحف او ما يعرف ب Bandwidth.
- تشوية نتائج محركات البحث.
- قدرة الخادعات على توليد العديد من شبيهاتها.

وقد يمتد الضرار إلى أصحاب المواقع، فقد يدفع مدراء المواقع إلى التخلّي عن جهودهم في توفير صفحات ومحلى ذو جودة مرتفعة، اخذين على عاتقهم مهمة انشاء محتوى يستطيع ان يتعامل مع محركات البحث مما يستتبع ان يجعل محتوى الشبكة العنكبوتية موجه إلى محركات البحث بدلاً من ان يوجه إلى مستفيدي الشبكة العنكبوتية الامر الذي يشكل كارثة في نهاية المطاف على الشبكة العنكبوتية.

2. العنكبوتية الخفية:

يتمثل التحدي الرئيسي لمحركات البحث في التعامل مع محتوى العنكبوتية الخفية في عجزها الكامل في الوصول إليه ومن ثم عدم تكشيفه أو نظمه أو معالجته وذلك على الرغم من كون العنكبوتية الخفية تشمل على 5 اضعاف العنكبوتية المكشفة.

3. تفاعل المستفيد مع محركات البحث في استرجاع المحتوى:

يتخذ هذا التفاعل صورة الاستفسارات الموجهة من المستفيد إلى محرك البحث والتي تحمل معها الحاجات المعلوماتية أو المحتوى الفعلى المطلوب، أما عن سمات استفسارات المستفيدين فهي تتفاوت بين عناصر ومؤشرات تصعب على محرك

البحث الاسترجاع بالصورة التي يرضي عنها المستفيد، والمرجعية في ذلك تعود الى عدم المام المستفيد بحاجته الفعلية أو عدم قدرته على التعبير بصورة صحيحة عن المحتوى الذي يطلب، أو عدم فهمه لإمكانيات محرك البحث الذي يتعامل معه.

ثانياً: التوصيات:

يوصي الباحث في نهاية الدراسة بما يلي:

1. العمل على التخلص من البنية التكويدية الحالية للشبكة العنكبوتية المتمثلة في لغة (HTML) والتوجه نحو الاعتماد على التكويد بلغة XML .
2. الاعتماد على التشفير بالنظام UTF-8 في صياغة محددات المصادر URI .
3. التوجه نحو نسخة المحتوى المتاح على الشبكة العنكبوتية في مجموعة من نماذج للبيانات DATA MODEL .
4. اثراء المحتوى العربي بالانطولوجيات العامة والمتخصصة .
5. توفير نطاقات أسماء عامة ومتخصصة ترعاها رابطة اتحاد الويب من حيث التحديث وجعلها مظلة للمحتوى المتاح على الويب .
6. اثراء المحتوى العربي على الانترنت بالبحوث الاصلية العلمية في مختلف المجالات بهدف رفع الرتبة اللغوية العالمية للغة العربية على الويب .

المصادر:

المصادر الأجنبية:

1. Andrew Hammond. Arabic search engine may boost content. <http://www.abc.net.au>
2. Asadi, saied & hamied R.jamail."shifts in search engines development: a review of past, present, and future trends in research on search engines"[cited 2010-8-10] available at <http://www.webolog.ir>
3. Baeza-Yates, R., & Castillo, C. (n.d.). Web Search. Waterloo University. Retrieved July 20, 2011, from softbase.uwaterloo.ca/~tozsu/courses/cs856/W05/.../Ricardo-WebSearch.pdf.

4. Berry, M. W., & Browne, M. (1999). *Understanding search engines: mathematical modeling and text retrieval*. Philadelphia, PA: Society for Industrial and Applied Mathematics.
5. Castillo, C., (2005) “*Effective web crawling*”, SIGIR Forum, ACM Press,. Volume 39, Number 1, N, pp.55-56.
6. Castillo, Carlos. "EffectiveWeb Crawling." Diss. University of Chile, 2004. Web. 12 Oct. 2101. <www.chat0.cl/papers/crawling_thesis/effective_web_crawling.pdf>.
7. Christopher Olston and Marc Najork. Web Crawling. Foundations and Trends in Information Retrieval. Vol. 4, No. 3 (2010).
8. Craig Silverstein ,Hannes Marais ,Monika Henzinger,Michael Moricz. Analysis of a very large web search engine query log. ACM SIGIR Forum, 1999 - portal.acm.org.
9. Deerwester, S., Dumais, S.T., Furnas, G.W., Landauer, T.K., Harshman, R. (September,1990). Indexing by latent semantic analysis. *Journal of the American Society for Information Science*, 41(6): 391-407.
10. Detecting Spam Web Pages. Marc Najork. Microsoft Research, Silicon Valley.
11. Dominich, S. (2008). *The modern algebra of information retrieval* . Berlin: Springer.
12. Eric Convey.Porn sneaks way back on Web.The Boston Herald, May 22, 1996.
13. G. Madhu, A. Govardhan, T. V. Rajinikanth: Intelligent Semantic Web Search Engines: A Brief Survey CoRR abs/1102.0831: (2011).
14. Gyongyi, Z., & Garcia-Molina, H. (n.d.). Web Spam Taxonomy. *Web Spam Taxonomy*. Retrieved July 21, 2011, from airweb.cse.lehigh.edu/2005/gyongyi.pdf.
15. Gyongyi, Z., & Garcia-Molina, H. (n.d.). Web Spam Taxonomy. *Web Spam Taxonomy*. Retrieved July 21, 2011, from airweb.cse.lehigh.edu/2005/gyongyi.pdf.
16. HAIDAR MOUKDAD AND ANDREW. Lost In Cyberspace: How Do Search Engines Handle Arabic Queries?

17. History of Search Engines: From 1945 to Google Today. *Search Engine History.com*. Retrieved July 20, 2011, from <http://www.searchenginehistory.com>
18. Internet world stat.<http://www.Internetworkdsta.com>
19. Jansen, B. J., & Spink, A. (2005). How are we searching the World Wide Web? A comparison of nine large search engine transaction logs. *Information Processing and Management*, 42(1), 248-263.
20. K. Sparck Jones. A probabilistic model of information retrieval: development and comparative experiments. *Information Processing and Management* 36 (2000) 779±808.
21. Langville, A. N., & Meyer, C. D. (2006). Google's PageRank and beyond: the science of search engine rankings. Princeton, N.J.: Princeton University Press.
22. Lawrence, S., & Giles, C. L. (1998, March 4). Searching the World Wide Web. SCIENCE. Retrieved July 20, 2011, from clgiles.ist.psu.edu/papers/Science-98.pdf.
23. Lee, T., & Fischetti, M. (2010). Weaving the web: the original design and ultimate destiny of the World Wide Web by its inventor ([Nachdr.] ed.). New York, NY: Harper-Business.
24. Levene, M. (2010). *An introduction to search engines and web navigation* (2nd ed.). Hoboken, N.J.: John Wiley.
25. Levene, M. (2010). An introduction to search engines and web navigation (2nd ed.). Hoboken: Wiley.
26. Maron, M. E., & Kuhns, J. (1960). On relevance, probabilistic indexing and information retrieval. *Journal of the Association for Computing Machinery*, 7(3), 216–244.
27. Meghabghab, George, and Abraham Kandel. Search engines, link analysis, and user's web behavior: 74 tables; [a unifying web mining approach]. Berlin: Springer, 2008. Print.
28. MICHAEL K. BERGMAN. The Deep Web: Surfacing Hidden Value.available:
<http://brightplanet.com/images/uploads/12550176481-deepwebwhitepaper.pdf>.

29. Ozgener, Isil. (2005). Publishing content on the web. : Stanford university.
30. Pant, G., Srinivasan, P., & Menczer, F. (n.d.). Crawling the Web. *University of Iowa*. Retrieved July 21, 2011, from <http://dollar.biz.uiowa.edu/~pant/Papers/crawling.pdf>.
31. Peter Brusilovsky , Carlo Tasso, Preface to Special Issue on User Modeling for Web Information Retrieval, User Modeling and User-Adapted Interaction, v.14 n.2-3, p.147-157, June 2004.
32. S. E. Robertson and K. Sparck Jones. Relevance weighting of search terms. *Journal of the American Society for Information Sciences*, 27(3):129-146, 1976.
33. Sherman, C., & Price, G. (2001). *The Invisible Web: uncovering information sources search engines can't see*. Medford, N.J.: CyberAge Books.
34. Stuckenschmidt, Heiner, and Frank Harmelen. *Information sharing on the semantic Web* . Berlin: Springer, 2005.
35. The Search Engine Industry. *Tommaso Buganza and Emanuele.springer* .2010.
36. *The size of the world wide web*. Retrieved 8, 2, 2010, from The size of the world wide web: <http://www.worldwidewebsize.com/>
37. Top Ten Internet Languages - World Internet Statistics. (n.d.). *Internet World Stats - Usage and Population Statistics*. Retrieved July 20, 2011, from <http://www.internetworldstats.com/stats7.htm>
38. Wu, B. FINDING AND FIGHTING SEARCH ENGINE SPAM. *CiteSeerX* Retrieved July 21, 2011, from <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.91.6961>.
39. Yates, R., & Neto, B. (1999). Modern information retrieval . New York: ACM Press ;.
40. Yates, R., & Neto, B. (1999). *Modern information retrieval* . New York: ACM Press ;.

41. Zdravko, Markov & Daniel T. Larose. Data-mining the Web : uncovering patterns in Web content, structure, and usage. John Wiley & Sons, Inc.2007.

المصادر العربية:

- 1- محمد عبد المولى محمود . محركات البحث: من اين بدأت وإلى اين انتهت: بنيتها واساليب الاسترجاع. العربية 3000 متاح في: <http://www.arabcin.net/arabiaall/index.html>.
- 2- نبيل علي. العرب وعصر المعلومات. عالم المعرفة. الكويت: المجلس الوطني للثقافة والفنون والاداب. 1994. ص 333.