

الطريقة الاحتمالية في اعداد الكشافات اعتمادا على علاقة التشابه الموضوعي ما بين الوثائق المشيرة والمشار اليها .

د. نعيمة حسن رزوقي
كلية الاداب / الجامعة المستنصرية

المقدمة

كثيراً ما يهملنا في دراسة استرجاع المعلومات علاقة التشابه ما بين طائفتين
المستفيد و كل وثيقة بضمن مجموعة معينة من الوثائق . وعندما يكون مقياس
التشابه عالياً عندئذ نقول بأن الوثيقة ملائمة للطلب وقد تم استرجاعها . وقد
يكون مقياس التشابه هذا قائماً على مقدار احتمالية ملائمة الوثيقة للطلب او على
اساس الترتيب التنازلي للوثائق بحسب ملائمتها حيث تكون الوثائق في الرتبة
الاعلى هي الأكثر ملائمة مقارنة بالرتبة الادنى .

وفي الغالب تعتمد العبارات الدالة او الواصفات كوحداث تتمركز حولها
ألوثائق المتشابهة للطلبات المتشابهة، ومن هنا فقد اكد عدد من الباحثين (٢، ١)
على ان الغرض من دراسة علاقة التشابه ما بين الوثائق ضمن مجموعة معينة
هو تحقيق نتائج افضل في عملية الاسترجاع ، وقد عبر عن هذه العلاقة
بالفرضية العنقودية (Clustering Hypothesis) [3] والتي تنص على انه
في الغالب تكون الوثائق المتشابهة ملائمة لنفس الطلبات .
وعليه فقد سعت الدراسة الحالية على تطبيق الطريقة الاحتمالية في اختيار
العبارات الدالة التي تؤلف الكشاف او الدليل لمجموعة الوثائق وذلك اعتماداً

على علاقة التشابه ما بين الوثائق المصدريّة (Source Documents) ومجموعة الوثائق المشار إليها . ولتحقيق ذلك فقد اعتمدت مستخلصات المقالات كبديل عن المقالات في اختيار العبارات الدالة التي تمثل محتوى المقالة كما اعتمدت عناوين الوثائق المشار إليها كمصادر للبحث لنفس الغرض وكانت النتيجة لهذا التحليل الحصول على قائمة من العبارات الدالة ومن ثم اجريت المطابقة ما بين :

١ - مجموعة العبارات الدالة في عناوين الوثائق المشار إليها في المقالة الواحدة وعبارات مستخلص المقالة بغية التوصل الى عدد العناوين التي تكونت من تجانس عدد من العناوين ومستخلص المقالة من حيث تشابه العبارات الدالة فيها .

٢ - مجموعة العبارات الدالة في عناوين الوثائق المشار إليها في المقالات الواحدة لغرض التوصل الى عدد العناوين التي تتكون من تجانس عدد من العناوين فيما بينها من حيث تشابه العبارات الدالة في عناوينها . ومن ثم احتساب مجموع العناوين التي يمتزجها يتم قياس درجة التشابه ما بين الوثائق في المقالة الواحدة التي تمثل طلباً وجواباً للطلب ، ولانجاز هذه الدراسة تم اختيار فرضيتين هما :

- ١ - ان الوثائق المتشابهة ملائمة على وجه العموم لنفس الطلب .
 - ٢ - ان الوثائق المتشابهة تتجمع بشكل عناوين حول نفس العبارات الدالة .
- هذا وقد اقتضت الدراسة على احداث الاعداد التي تم الحصول عليها في مجال علم المعلومات وللدورتين الاتيتين :

1. Journal of the American Society for Information Science (JASIS). vol.36 (1985)
2. Journal of Information Science (JIS) vol. 14 (1983) .

حيث بلغ مجموع الاعداد التي تم تحليلها لاغراض الدراسة (10) اعداد ، ستة منها لمجلة (JASIS) والأربعة الأخرى لمجلة (JIS) وكانت الحصيلة المحاصلة من هذه الاعداد العشرة (69) مقالة متضمنة مجموعة من

الوثائق التي تمت الإشارة إليها وحجمها (1597) عناوياً وقد استمر التحليل لاختيار العبارات الدالة عن مجموع كلي مقداره (267) عبارة دالة من المستخلصات و (2116) عبارة دالة من عناوين الوثائق المشار إليها ، يمثل الجدولان (1) و (2) خلاصة تفصيلية للبيانات المتعامة بالعينة والتي تدل الرموز فيها على ما يأتي :

- 1 - رق « رقم العدد »
- 2 - مج م « مجموع المقالات المصدارية في العدد الواحد »
- 3 - مج و « مجموع الوثائق المشار إليها في مجموع مقالات العدد الواحد »
- 4 - مج مس « مجموع العبارات الدالة في مجموع مستخلصات المقالات في العدد الواحد . »
- 5 - مج وثق « مجموع العبارات الدالة في مجموع الوثائق المشار إليها في مجموع مقالات العدد الواحد »
- 6 - مج ع م « مجموع العناقيد المتكونة من ترابط عدد من الوثائق ----- المستخلص بعباراتها الدالة »
- 7 - مج ع و « مجموع العناقيد المتكونة من ترابط عدد من الوثائق فـ..... قائمة المراجع بعباراتها الدالة »
- 8 - مهمة « مجموع عناوين الوثائق المشار إليها والتي اسقطت من التحليل واحتساب التشابه للأسباب الآتية :
أ - تكرارها في مراجع المقال الواحد
ب - عدم دلالة عباراتها
ج - كونها بلغة غير الانكليزية كالفرنسية والالمانية

رق	مج م	مج و	مج مس	مج وثق	مج ع م	مج ع و	مهمة
1	7	96	38	171	23	21	2
2	6	213	34	243	20	46	13
3	9	256	62	311	33	57	18
4	6	170	21	205	11	47	7
5	9	218	47	314	25	54	9
6	9	135	44	171	26	19	16
6	46	1088	246	1415	128	199	65

الجدول رقم (١)

البيانات التفصيلية لمجلة (JASIS)

رق	مج م	مج و	مج مس	مج وثق	مج ع	مج ع و	مهمة
1	7	214	37	284	21	51	5
2	6	161	34	218	1	48	1
3	5	37	23	58	218	3	10
4	5	97	27	141	15	22	/
4	23	509	121	701	55	124	16

الجدول رقم (2)

البيانات التضمينية لمجلة (JIS)

تعريفات Definition

نظراً لمتطلبات الدراسة في استخدام عدد من المصطلحات وبمعنى محدد
توجب احاطة تعريف مختصر لكل منها على النحو الآتي .

العتلة (Clustering)

هي عملية تكوين مجموعات متجانسة (Homogeneous groups) من
الوثائق بالشكل الذي تكون فيها كل وثيقة في المجموعة الواحدة مرتبطة
ارتباطاً وثيقاً ببقية الوثائق اقرانها في تلك المجموعة ويقل ارتباطها بالوثائق
الاخرى في المجموعات الاخرى ويطلق على كل مجموعة متجانسة بالعنقود
[4] كما ان وحدة الارتباط هنا هي العبارة الدالة .

الوثيقة المصدر (Source Document)

هي الوثيقة المتوفرة والمعتمدة في التحليل والتي بدورها قد اشارت الى عدد
من الوثائق ، وفي مجال الدراسة الحالية فان الوثيقة المصدر تمثل المقالة فسي
الدورية المتضمنة بالتحليل .

الوثيقة المشار اليها (Cited Document)

هي الوثيقة التي تظهر في قائمة المصادر او المراجع والتي تمت الاشارة اليها
من قبل الوثيقة المصدر .


من خلال فهم ادبيات الموضوع وخصوصاً الدراسات السابقة المتعلقة بطرق قياس درجة التشابه بين الوثائق (Documents) والطلبات (queries) تم استخلاص ثلاث افتراضات ينص الأول منها على ان علاقة التشابه بين الوثائق المشيرة الى (Citing) والمشار اليها (Cited) تشكل مجموعات (عناقد) من المواد المترابطة والتي يمكن بدورها ان تحقق نظام استرجاع كفء وفعال (6, 7) وعليه فقد دعت تلك الدراسات الى عنقدة الوثائق من اجل تحسين الاسترجاع .

اما الافتراض الثاني فانه يؤكد على ان الوثائق المشار اليها من قبل الوثيقة المصدر تؤلف عينة ملائمة لطلب المؤلف على افتراض سابق مفاده انه غالباً ما يشير المؤلف الى الوثائق ذات العلاقة بموضوع الوثيقة المصدر التي اعدها والتي بدورها جميعاً تشكل عنقوداً ملائماً من الوثائق المتشابهة لحاجته من المعلومات ، بعبارة اخرى تمثل اجابات ملائمة لمتطلبات الوثيقة المصدر التي يمكن التعامل معها هنا بمثابة طلب (query) من منطلق ان ارضاء حاجة المستفيد المرتبطة بطلب محدد [7] .

ومن هنا يتبين لنا ان مجموعة الوثائق المتوفرة مسرزة اساساً بجميع الوثائق التي تمت الإشارة اليها من قبلها فهي بذلك قابلة للزيادة ليس على اساس اضافة مصدر فعلي للمجموعة فحسب بل مع المصادر المضافات قائمة من المصادر الاخرى التي تسند الوثيقة وتبرزها وبالتالي تبرز المجموعة ككل والتي يمكن لنا ان نطلق عليها بالمجموعة المعززة او القابلة للزيادة ، ثم هو واضح بالشكل (١) الذي يشير فيه المربع (B) بالمخطوط المنقطعة الى مجموع الوثائق التي تمت الإشارة من قبل الوثائق المصدر التي يمثلها المربع (A) اما المثلث في الوسط فانه يعني مجموع الاجابات لطلب معين . كما يشترك المربعان في جزء منهما ليمثل الوثائق المتوفرة ضمن المجموعة وقسند

ظهرت في نفس الوقت ضمن الوثائق المشار اليها . فاذا ما عبرنا عن مجموع الوثائق المصدرية ب (٤x) ومجموع الوثائق المشار اليها لكل وثيقة مصدر ب (٤٢) فان المجموعة المعززة (N) تساوي :

$$N = ٤ (x + ٤٢)$$



الشكل رقم (١)

المجموعة المعززة والعلاقة ما بين المتوفر والمشار اليه للطلاب

اما الافتراض الثالث والاختير فإنه يشير الى ان نجاح مؤلف ما في البحث العلمي لها مدلول على ان ذلك المؤلف قد راجع ادبيات الموضوع واعمل ذات العلاقات المنجزة حديثاً او قديماً ، وان درجة الشمول لتغطية تلك الأعمال من خلال الاشارة اليها في البحث تعتمد على المؤلف نفسه ، ومع ذلك فممن الطبيعي ان تظهر في نهاية البحث او هوامشه قائمة من الوثائق ذات العلاقة

والملائمة التي يراها مناسبة فإشار إليها . وهذا بدوره يعني ان علاقة التشابه قائمة ويمكن ان ينظر اليها على اساس ان بحث المؤلف بمثابة طلب وان الوثائق المشار اليها بمثابة استرجاع وبأي طريقة يختارها المؤلف [8] . وعليه فـسان خلف كل وثيقة مصدر (x) هناك مجموعة من الوثائق الملائمة (٤٢) والتي يكون محتواها الموضوعي هو ما يبحث عنه المؤلف ويرغب الكتابة والبحث عليه . هذا وقد اعتبر كوك (kwok) [٩] ان مستخلص الوثيقة وعنوانها بدائل عن النص الاصيل في تمثيلها للطلبات وبناء على ذلك فـسان العبارات الدالة الواصفات التي يتم اختيارها من المستخلص او العنوان يمكن لها ان تمثل تلك الوثائق ليعتمد عليها كروابط تجمع حولها الوثائق المتشابهة لتكون عناقيد وكل عنقود بحد ذاته يؤلف عينة عشوائية لجميع الوثائق الملائمة للطلب بضمن المجموعة المعززة التي اشرنا اليها سابقاً .

نتائج التحليل

بعد تحليل مستخلصات المقالات عينة الدراسة وعناوين الوثائق الملحقة بكل مقالة وتبويب البيانات وجد الاتي :

١ - بالرغم من اختلاف في مجموع الاعداد التي تم تحليلها للدورتين وماتبعه من اختلاف في المجموع النهائي للمقالات والوثائق المشار اليها الا ان هناك توافقاً في المعدلات النهائية للعبارات والعناقيد في المقال الواحد حيث كان :

١ - معدل عدد العبارات الدالة في المستخلص الواحد هو (5) عبارات لكلتا الدورتين .

ب - معدل عدد العناقيد المتكونة من مستخلص كل مقالة مصدرية والوثائق التي اشيرت اليها (3) عناقيد في كلتا الدورتين .
تمثل بثلاث عبارات دالة .

ج - معدل عدد العناقيد المتكونة من الوثائق المشار اليها في المقالات الواحد ما بين (10) عنقوداً .

وعليه تم الاعتماد في التحليل على المجموع الكلي للبياناتول الدوريتين ولم نجد جدوى من التمييز بينهما .

٢ - وجد ان هناك ترابطاً موضوعياً بين قائمة العبارات في المقالة الواحدة لتكون عناقيد فرعية صغيرة يمكن ربطها باحالات لتمثل مجموع... متجانسة اكبر ذات علاقة بموضوع اساسي . ففي المقالة المنشورة في مجلة علم المعلومات (Jis) [10] هناك ست عبارات دالة تعدد استخدامها في عناوين الوثائق ومستخلص المقالة وبالتالي فانها مرتبطة موضوعياً بالنظم الصوتية وهذه العبارات هي :

- Speech technology
- Voice Systems
- Speech Interface
- Man Machine interface
- Speech recognition
- Human Factor

٣ - كما وجد انه كلما زاد عدد الوثائق المشار اليها في المقالة الواحدة تعددت العناقيد و كثر فيها المترادفات او الصيغ المختلفة للعبارات مثل المفرد والجمع والمختصرات التي يمكن لها ان ترتبط مع بعضها .


٤ - افتقار عدد من المقالات الى الارتباط ما بين عبارات المستخلص والوثائق المشار اليها وقد وجد ان هذا مرتبط بطبيعة المقالة فاذا كانت من المقالات الاستعراضية العامة كان مقدار التشتت في الموضوعات واضحاً لمحاولة موقف المقالة تغطية الموضوع المدروس لكل جوانبه مما يحدث انعدام الترابط بين العناوين من خلال العبارات الدالة المتشابهة حيث يكون عدد العناقيد فيها صفرأ او التشتت الواضح لعناوينها وتناثرها في مجموعات صغيرة جداً لا تتعدى ثلاثة عناوين فقط بسبب تعدد العبارات المستعملة .

ولابتهات ذلك ثم احتساب الوسط الحسابي والانحراف المعياري للبيانات الواردة في الجدول (3) الذي يمثل الحقل الأول في مجموع المقالات التي يحصل او لا يحصل فيها ترابط ما بين عبارات مستخلصاتها وعناوين الوثائق المشار اليها في حين يمثل الحقل الثاني منه عدد العناوين المتنوعة من الترابط او التشابه في العبارات المستخدمة، كما احتسب الوسط الحسابي والانحراف المعياري للبيانات الواردة في الجدول (4) الذي يمثل الحقل الاول فيه مجموع المقالات التي تشترك عناوين الوثائق التي اشارت اليها كل مقالة باستخدام عبارات متشابهة تمثل بعدد العناوين في الحقل الثاني . ومن ثم تم تمثيل هذه البيانات في الشكلين (2، 3) حيث تظهر الحالات المتطرفة في طسرفسي المنحني لكل منها ففي الجدول (3) والشكل (2) يبار ان هناك مقالتين لم يحصل ترابط فيها بين عبارات المستخلص وعبارات العناوين التي اشارت اليها في حين ان هناك ثلاث مقالات تجاوز فيها عدد العناوين الستة وهو بعدد عن الوسط الحسابي ويقع على طرف المنحني .

عدد العناوين	مجموع المقالات
0	2
1	11
2	16
3	20
4	13
5	4
6	3
21	69
21	69
المجموع	
الوسط الحسابي لعدد العناوين = 3	
الانحراف المعياري = 2	

الجدول رقم (3)

تمثيل مجموع المقالات وعدد العناوين مع العناوين



الشكل (٢)

منحنى الترابط بين المستخلصات والوثائق المشار إليها

مجموع المقالات			عدد العناوين		
مجموع المقالات			عدد العناوين		
8	1	9	0	13	1
10	1	10	1	10	2
11	1	11	2	8	3
13	2	12	3	8	4
15	2	13	4	5	5
17	1	14	5	4	6
18	1	15	6	2	7
22	2	16	7	6	8
30	2	17			


مجموع العناوين = 172

مجموع المقالات = 69

الوسط الحسابي لعدد العناوين = 10

الانحراف المعياري = 8

الجدول رقم (٤) تمثيل مجموع المقالات وعدد العناوين مع العناوين



الشكل رقم (3)

منحنى الترابط بين عناوين الوثائق المشار إليها

التوصيات

١ - لغرض تقليص عدد العناقيد المشتتة في المقال الواحد يقترح وضع عدد من الصيغ التي يعمل بموجبها على تعديل قائمة العبارات الدالة المحسرة وتتضمن هذه التعديلات الآتي :

- ١ - الاتفاق على استخدام صيغة الجمع بدلا عن المفرد .
- ب - الابتعاد عن المختصرات مثل (SDI) والتعبير عن العبارة كاملة (Selective Dissemination of Information)

وان كانت مطولة .

ج - توحيد استخدام بعض العبارات التي تعطي مدلولاً موضوعياً واحداً على سبيل المثال

- Technical Technological
- Aging Elderly
- Developing Countries / Third World / Less developed Countries

د - استخدام المضاف والمضاف اليه بدلا من الجملة .
Gathering of Information

تصحيح

- Information gathering

٢ - لقد اقترح في دراسة سابقة (١١) ونؤكد الاقتراح هنا الى استخدام النص الكامل للمقالة بدلاً عن المستخلص في اختيار العبارات الدالة ومما يساعد على تحقيق هذا المقترح هو التطورات الواسعة في تقنيات التخزين والمعالجة الحديثة التي تسهل هذه العملية مثل استخدام الأقراص المكتتزة (D-ROM) وعليه فإن شيوع استخدام هذه التقنية قد يدفع بطريقة اختيار العبارات الدالة من عنوان المقالة او مستخلصها نحو..... الزوال . اما بالنسبة الى عناوين الوثائق المشار اليها فانها استخدمت في الأساس لتغذية نظام الاسترجاع ولذا يبقى اعتمادها مفيداً لتحسين الاسترجاع ، وقد اكد على هذه الاهمية لعناوين الوثائق المشار اليها..... كليفلاند (Cleveland) (١٢) حيث اوضح ان لعناوين الوثائق المشار اليها دوراً لا يختلف عن النص الكامل للوثيقة في انجازها لتغذية النظام وتكامله بأارتباطها مع الوثيقة المصدرية .

1. Van Rijsbergen, C.J. Information Retrieval. 2nd ed. London: Butterworths, 1979.
2. Salton, G. and Megill, M.J. Introduction to Modern Information Retrieval. New York: McGraw Hill, 1983.
3. Ibid.
4. Can, Fazli and Ozkaran, Esen A. "Similarity and Stability Analysis of the Two Partitioning Type Clustering Algorithms," Jasis. 36: 1 (1985) 3-14.
5. Van Rijsbergen. OP. Cit.
6. Salton, G. Dynamic Information and Library Processing. Englewood, Cliffs, N.J.: Prentice-Hall, 1975.
7. Saracevic, T. "Relevance: a Review of and a Framework for the Thinking on the Notion in Information Science." JASIS. 26 (1975) 321-343.
8. Goffman, W. "An Indirect Method of Information Retrieval." Information Storage and Retrieval-4 (1969) 361-373.
9. Kwok, K.L. "A Probabilistic Theory of Indexing and Similarity Measure Based on Cited Citing Documents. JASIS. 36: 5 (1985) 342-351.
10. Philip, G; Smith, F.J.; and Crookes, D. Voice Input/ Output Interface for Online Searching: Some Design and Human Factor Consideration. JIS. vol 14: 2 (1983) 93-98.
11. Kwok, K.L. "A Probabilistic Theory of Indexing and Similarity Measure Based on Cited and Citing Documents. "JASIS. 36:5 (1985) 350.
12. Cleveland, D.B.; Cleveland, A.B.; and Wise, O.B. "Less than Full text Indexing Using a Non-Boolean Searching Model." JASIS. 35 (1984) 19-28.