

Vers une nouvelle génération d'outils d'analyse et de recherche d'information

A New Generation of Analysis and Retrieval Tools

Hacia una nueva generación de herramientas de análisis y de investigación de información

Dominic Forest

Volume 55, Number 2, April–June 2009

URI: <https://id.erudit.org/iderudit/1029091ar>

DOI: <https://doi.org/10.7202/1029091ar>

[See table of contents](#)

Publisher(s)

Association pour l'avancement des sciences et des techniques de la documentation (ASTED)

ISSN

0315-2340 (print)

2291-8949 (digital)

[Explore this journal](#)

Cite this article

Forest, D. (2009). Vers une nouvelle génération d'outils d'analyse et de recherche d'information. *Documentation et bibliothèques*, 55(2), 77–89. <https://doi.org/10.7202/1029091ar>

Article abstract

The recent efforts to increase the dissemination and circulation of information in numeric format have led to a phenomenon known as information overload. It is now imperative to develop retrieval tools that are better adapted to the users' needs and that will enable them to retrieve relevant documents that meet their information needs. In this article, we will begin with a summary of observations of the consequences of the limits of the traditional tools used in numeric information retrieval. Following this, we will describe the concepts and techniques of textual searching, emphasizing automatic classification. Lastly, we will demonstrate how certain textual searching techniques contribute to the development of a new generation of information retrieval tools.

Vers une nouvelle génération d'outils d'analyse et de recherche d'information

DOMINIC FOREST

Professeur adjoint
École de bibliothéconomie et des sciences de l'information
Université de Montréal
dominic.forest@umontreal.ca

RÉSUMÉ | ABSTRACTS | RESUMEN

Les récents efforts visant à favoriser la diffusion et la circulation de l'information en format numérique ont contribué au phénomène de l'infobésité (information overload). Il est désormais important de concevoir des outils de recherche d'information plus adaptés aux besoins des utilisateurs afin de leur permettre de récupérer les documents pertinents répondant à leurs besoins informationnels. Dans cet article, nous ferons état, dans un premier temps, de certaines observations sur les conséquences découlant des limites des outils traditionnels en recherche d'information numérique. Dans un deuxième temps, nous exposerons les concepts et les techniques de base du domaine de la fouille de textes, en insistant sur les opérations de classification et de catégorisation automatiques. Finalement, nous montrerons comment certaines techniques de fouille de textes peuvent contribuer au développement d'une nouvelle génération d'outils de recherche d'information.

A New Generation of Analysis and Retrieval Tools

The recent efforts to increase the dissemination and circulation of information in numeric format have led to a phenomenon known as information overload. It is now imperative to develop retrieval tools that are better adapted to the users' needs and that will enable them to retrieve relevant documents that meet their information needs. In this article, we will begin with a summary of observations of the consequences of the limits of the traditional tools used in numeric information retrieval. Following this, we will describe the concepts and techniques of textual searching, emphasizing automatic classification. Lastly, we will demonstrate how certain textual searching techniques contribute to the development of a new generation of information retrieval tools.

Hacia una nueva generación de herramientas de análisis y de investigación de información

Los recientes esfuerzos tendientes a favorecer la difusión y la circulación de la información en formato digital han contribuido al fenómeno de la infobesidad (sobrecarga de información). Es importante, de aquí en adelante, diseñar herramientas de búsqueda de información que se adapten mejor a las necesidades de los usuarios a fin de facilitarles la recuperación de documentos pertinentes que respondan a sus necesidades informacionales. En este artículo, realizaremos, en un primer momento, ciertas observaciones sobre las consecuencias que derivan de los límites de las herramientas tradicionales para la búsqueda de información digital. En un segundo momento, expondremos los conceptos y las técnicas de base del dominio del registro de textos, insistiendo sobre las operaciones de clasificación y de categorización automáticas. Finalmente, mostraremos cómo determinadas técnicas de registro de textos pueden contribuir al desarrollo de una nueva generación de herramientas de búsqueda de información.

Introduction

LES DIX DERNIÈRES ANNÉES ont été caractérisées par une hausse importante du nombre d'initiatives visant à numériser et à rendre disponible, très souvent sur Internet ou à l'intérieur d'un Intranet, le patrimoine informationnel des organisations. De nos jours, la majorité des gestionnaires de l'information ne remettent plus en question les nombreux avantages que peuvent procurer les documents en format numérique (reproductibilité quasi parfaite et illimitée, dissémination rapide de l'information, etc.). Parallèlement, les nombreux avantages associés à la documentation numérique ont motivé le développement d'infrastructures performantes dédiées à la numérisation, ainsi qu'à la diffusion de l'information. À cet égard, les manifestations du numérique sont nombreuses et des plus variées. Ainsi, Bibliothèques et Archives nationales du Québec (BAnQ) est un des principaux acteurs d'un projet visant à permettre la diffusion en format numérique de plusieurs dizaines de milliers de documents généalogiques¹. À l'échelle internationale, il importe de souligner le succès, tant en termes de la qualité de la numérisation que de la quantité de documents disponibles et consultés du projet *Européana*², de la bibliothèque numérique *Gallica*³ ou encore du projet ARTFL⁴. Dans le domaine de la recherche universitaire, l'intérêt pour la diffusion numérique des résultats de la recherche scientifique est à la base de nombreux travaux en cours cherchant à promouvoir le développement de cyberinfrastructures pour la diffusion numérique des résultats de la recherche. Dans la Francophonie, les deux principaux chantiers dans ce domaine sont les projets Synergies⁵ et Adonis⁶.

L'évolution du numérique, indissociable du Web, est d'une telle ampleur qu'il est très difficilement quantifiable⁷. Cependant, les inconvénients du numérique,

1. <http://www.banq.qc.ca/portal/dt/genealogie/genealogie.jsp>

2. <http://dev.europeana.eu/>

3. <http://gallica.bnf.fr/>

4. <http://humanities.uchicago.edu/orgs/ARTFL/>


5. <http://www.synergiescanada.org/>

6. <http://www.tge-adonis.fr/>

7. Certaines études, dont la plus citée a été menée à l'Université de Berkeley en 2003 (*How much information?*), ont tenté de chiffrer la croissance du numérique. Si toutes les études démontrent que la quantité de documents disponibles en format numérique augmente radialement, aucun consensus n'émerge des études lorsqu'il s'agit de chiffrer précisément cette évolution.

Dans cet article, nous définirons d'abord le domaine de la fouille de textes, puis exposerons les principes fondamentaux des deux processus de fouille à la base de nouvelles stratégies de recherche d'information. Finalement, nous présenterons deux exemples d'outils de recherche sur le Web qui reposent en grande partie sur l'utilisation de techniques de classification et de catégorisation automatique pour la recherche d'information en ligne.

*La troisième étape de la démarche
consiste à convertir le corpus initial
dans un format pouvant être traité
par les algorithmes de fouille.*



sous-opérations. La première d'entre elles consiste à supprimer certains mots non pertinents pour l'analyse. Le filtrage du lexique peut être effectué à l'aide de plusieurs techniques, certaines étant de nature linguistique, d'autres de nature statistique. Une première opération a pour but de supprimer l'ensemble des mots fonctionnels présents dans le texte. Ce processus est réalisé en retirant les termes figurant dans une liste prédéfinie de mots fonctionnels. Il est aussi souhaitable d'appliquer certains filtres statistiques au lexique du corpus afin d'éliminer les unités qui, tout en ne figurant pas dans la liste des mots fonctionnels, ne sont pas pertinentes pour l'analyse. La pertinence des termes est très étroitement associée à leur potentiel discriminant. Ainsi, il importe de supprimer les mots dont la fréquence est supérieure ou inférieure à certains seuils, souvent déterminés empiriquement.

Dans un dernier temps, il est d'usage d'appliquer un processus de généralisation sensible aux variantes sémantiques et syntaxiques présentes dans le corpus. Il importe alors d'appliquer au lexique du corpus une opération de lemmatisation⁹. L'opération de lemmatisation est réalisée d'abord en effectuant un marquage morphosyntaxique des différents lexèmes à analyser, ensuite en comparant ceux-ci à un dictionnaire. Ce processus permet de dégager une liste de lemmes propres à une langue donnée. S'il est impossible de lemmatiser les données à traiter (par manque de ressources linguistiques, par exemple), il est souhaitable de recourir à un processus d'amputation des terminaisons (*stemming*), lequel génère une liste de *stems* (racines).

La troisième étape de la démarche consiste à convertir le corpus initial dans un format pouvant être traité par les algorithmes de fouille. Cette opération est réalisée en structurant les documents du corpus en une matrice de vecteurs dans laquelle chaque document (ou segment de document) est représenté par l'absence ou la présence, binaire ou pondérée, de chaque unité lexicale retenue à l'étape précédente.

C'est à la quatrième étape de la démarche que sont réalisées les opérations permettant plus spécifiquement d'extraire et de structurer les informations présentes dans le corpus. Dans une perspective de fouille de textes,

la majorité des opérations d'extraction et de structuration des informations sont réalisées en utilisant des algorithmes développés dans les domaines de l'intelligence artificielle et de l'apprentissage machine.

Il est possible de distinguer deux principales familles d'algorithmes en fonction de la quantité d'information externe au système qu'ils requièrent. La première famille d'algorithmes est celle des techniques supervisées. La principale particularité des techniques supervisées réside dans leur capacité à projeter certaines caractéristiques des documents préalablement connues et apprises par le système sur un ensemble de documents pour lesquels les mêmes caractéristiques ne sont pas encore connues. En vertu de cette particularité, les techniques supervisées impliquent donc d'abord une phase d'apprentissage (réalisée sur un corpus d'apprentissage) et, ensuite, une phase de test (ou d'application) lors de laquelle l'apprentissage effectué par le système est projeté sur de nouveaux documents (en contexte de test ou d'application concrète). Les tâches de catégorisation automatique – qui consistent à attribuer une ou plusieurs catégories à chaque document d'un corpus – sont traditionnellement accomplies en utilisant des algorithmes d'apprentissage supervisés.

La seconde famille regroupe les algorithmes ne faisant intervenir aucune connaissance externe au système. Ces algorithmes, qualifiés de non supervisés, cherchent à extraire automatiquement certaines informations ou structures d'informations récurrentes dans un corpus. Contrairement aux algorithmes supervisés, les algorithmes non supervisés ne requièrent normalement pas d'ensembles d'apprentissage. Ils sont plutôt directement appliqués en contexte en tentant de décrire certaines régularités statistiques qui sont caractéristiques aux documents. Les tâches de classification automatique (*clustering*) – qui consistent à regrouper les documents d'un corpus dans un certain nombre de classes sur la base d'un ou de plusieurs critères de similarité – sont traditionnellement accomplies en utilisant des algorithmes non supervisés.


Outre ces deux principales opérations de catégorisation et de classification automatiques, on retrouve aussi dans le domaine de la fouille de textes des algorithmes davantage sensibles aux caractéristiques linguistiques des documents. Elles permettent d'assister l'identification d'entités nommées (dates, noms propres, lieux, etc.) et de liens sémantiques entre des termes.

La cinquième étape de la démarche réside dans l'interprétation, l'évaluation et l'intégration des résultats générés par les algorithmes de fouille de textes. Les opérations d'interprétation et d'évaluation sont des plus complexes, car elles sont dépendantes de plusieurs facteurs extrinsèques au processus de traitement des documents textuels. En effet, l'interprétation et l'évaluation des résultats de la fouille ne peuvent être réalisées adéquatement sans tenir compte de la nature des docu-

9. En linguistique, opération consistant à ramener les formes fléchies (conjugées, plurielles) à des formes standard (infinitif ou singulier). La lemmatisation implique normalement un processus complexe visant à lever toute ambiguïté sémantique.

Figure 1

Méthodologie générique de la fouille de textes (d'après Fayyad *et al.* 1996)



ments traités, du contexte de réalisation des traitements, des objectifs poursuivis, etc.


Les algorithmes supervisés peuvent être évalués selon les mesures classiques de rappel et de précision. En contrepartie, l'évaluation des résultats générés par les algorithmes non supervisés ne peut être accomplie en utilisant de telles mesures objectives. Les processus non supervisés permettent principalement d'identifier et de décrire certaines caractéristiques récurrentes observables statistiquement à l'intérieur du corpus de documents. Pour cette raison, il est fréquent de comparer les résultats obtenus par un algorithme non supervisé à ceux obtenus en utilisant plusieurs autres algorithmes comparables. Ceci permet de s'assurer de la stabilité des résultats. Idéalement, les mêmes patrons (*patterns*) devraient être observés, indépendamment de l'algorithme utilisé. Lorsque cela est possible, il peut aussi être utile de comparer les résultats à ceux obtenus par une analyse manuelle.

Par ailleurs, l'interprétation des résultats des algorithmes de fouille ne peut être dictée par aucun cadre théorique qui ferait abstraction du contexte dans lequel l'opération de fouille est réalisée. Finalement, les résultats doivent normalement faire l'objet d'un processus d'intégration à l'intérieur d'une application finale plus complexe dans laquelle le processus de fouille ne constitue qu'une étape bien précise. Les applications finales intégrant des processus de fouille de textes sont

de plus en plus nombreuses et variées. Parmi celles-ci, on trouve entre autres les applications de veille scientifique, de gestion électronique des documents et de recherche d'information. La figure 1, inspirée de Fayyad *et al.* (1996), présente les principales étapes de la méthodologie générique de fouille de textes.

Le développement d'outils d'analyse et de traitement de l'information numérique intégrant efficacement des fonctionnalités de fouille de textes est actuellement un important domaine de recherche dans les milieux académique et industriel. Certains domaines d'activités (dont, entre autres, ceux de la gestion des connaissances, de la bioinformatique et du génie biomédical) ont très rapidement perçu la pertinence d'intégrer des opérations de fouille de textes dans leurs pratiques. Depuis quelques années, plusieurs projets de recherche en sciences humaines et sociales explorent des modalités d'application de stratégies de fouille de textes en tenant compte des particularités d'analyse propres à chaque discipline (Forest, 2006). En sciences de l'information, les processus de fouille de textes sont de plus en plus souvent couplés aux outils de recherche d'information. Plus loin dans l'article, nous exposerons deux exemples d'outils de recherche d'information en ligne de nouvelle génération. Ces outils sont fondés sur l'application d'une opération de classification automatique des documents au sein du processus de recherche. Mais avant d'aborder plus précisément cette dimension applicative, il importe

La distinction entre les opérations de catégorisation et de classification se manifeste aussi dans le domaine de la fouille de textes.



d'expliciter les particularités de l'opération de classification automatique dans son acception dans le domaine de la fouille de textes. L'opération de classification automatique est au cœur des travaux de fouille de textes. Il s'agit d'une opération distincte de la catégorisation automatique, mais qui lui est complémentaire.

Catégorisation et classification automatiques

Les opérations de catégorisation et de classification automatiques font l'objet de travaux de recherche dans les secteurs de l'intelligence artificielle et de l'apprentissage machine. Elles s'inscrivent dans deux catégories de techniques informatiques. La catégorisation automatique figure dans la catégorie des méthodes dites supervisées ; les méthodes supervisées impliquent une intervention directe de l'utilisateur dans le processus réalisé. Cette intervention prend différentes formes : dans le cas de la catégorisation automatique, l'intervention consiste à guider le processus d'apprentissage en indiquant au système quelles catégories doivent être associées à certains documents. L'ensemble des documents catégorisés manuellement porte le nom d'ensemble d'apprentissage. Sur la base de cet ensemble, l'algorithme de catégorisation effectue un apprentissage (la nature de celui-ci est fonction de la nature de l'algorithme employé) et projette l'information apprise sur un ensemble de test, constitué de documents dont le système ne connaît pas *a priori* les catégories auxquelles ils appartiennent.

Quant à la classification automatique, elle figure traditionnellement dans la catégorie des méthodes dites non supervisées. Les différentes méthodes utilisées ici sont réalisées de manière autonome, sans aucune intervention de l'utilisateur. Ces méthodes non supervisées intègrent, tout comme les méthodes supervisées, un mécanisme d'apprentissage. Cependant, celui-ci opère uniquement sur la base de l'information soumise au système, sans aucun recours à des informations ou métadonnées spécifiées par l'utilisateur. L'algorithme peut nécessiter l'utilisation d'un ensemble d'apprentissage et d'un ensemble de test, mais ce n'est pas obligatoire. L'objectif de l'opération consiste à regrouper les données en ensembles homogènes en employant uniquement les traits caractéristiques ayant servi à décrire chaque élément.

La distinction entre les opérations de catégorisation et de classification se manifeste aussi dans le domaine de

la fouille de textes. Ces deux opérations correspondent à deux types d'analyse distincts. L'opération de catégorisation automatique, réalisée en employant certaines métadonnées préalablement connues, est très étroitement reliée à des processus d'analyse de nature prédictive ou normative. Par exemple, une telle opération semble des plus adaptées à l'identification du contenu thématique des documents. L'opération de catégorisation présuppose cependant que nous disposions *a priori* d'informations valides ou attestées pouvant être employées pour effectuer l'apprentissage. En ce sens, sur le plan théorique, l'opération de catégorisation automatique fait nécessairement appel à des informations externes aux données à traiter. En d'autres termes, la réalisation de cette opération implique l'application d'une structure d'informations sur les données textuelles. Dans une tâche de catégorisation thématique, cette structure externe prend la forme d'une taxinomie de catégories thématiques ou d'un plan de classification.

Par contre, l'opération de classification automatique est effectuée en ne considérant que les données provenant exclusivement des documents textuels soumis au système. L'opération de classification vise à regrouper des documents (ou des segments de documents) en ne considérant que leur contenu. Il s'agit d'une opération exploratoire et descriptive.

Dans son application au traitement automatique des documents, le processus de catégorisation implique plusieurs considérations. Premièrement, le processus de catégorisation présuppose l'élaboration *a priori* d'une taxinomie ou d'une hiérarchie de catégories thématiques adaptées au contenu et aux spécificités de la collection à traiter. Deuxièmement, ce processus implique non seulement l'identification, à partir de l'ensemble des documents, des caractéristiques (linguistiques et statistiques) qui serviront de base à la catégorisation, mais aussi le choix d'une méthode d'attribution des catégories aux documents.

Pour Charniak (1993), le défi de la classification automatique s'organise autour de trois axes. Le premier axe concerne la description des différents éléments à soumettre à l'opération de classification. En effet, il importe à cet égard de ne retenir que les traits caractéristiques discriminants, sur la base desquels les différents segments de documents seront comparés. Très souvent, cette description implique l'application d'une ou de plusieurs fonctions de filtrage et de nettoyage. Pour que le résultat soit pertinent, il importe que le processus de classification repose sur des descripteurs significatifs. Les décisions prises à cet égard doivent tenir compte aussi bien des objectifs de la classification que de la nature même des objets à classer. Le deuxième axe concerne la fonction discriminante, à la base de toute opération de classification. Cette fonction discriminante peut faire appel à plusieurs critères : l'identité, la similarité, l'homogénéité, l'équivalence, etc. Finalement, le dernier axe concerne le choix de l'algorithme employé pour réaliser

Figure 2
Représentation d'un regroupement plat






Figure 3
Représentation d'un regroupement hiérarchique



Actuellement, les processus de classification et de catégorisation automatiques ont été les plus exploités dans le contexte de la recherche d'information.



l'opération de classification. Ce choix implique des enjeux à la fois théoriques et pratiques qui relèvent tant de la nature des données à regrouper que des caractéristiques de la classification souhaitée.

Plusieurs techniques informatiques ont été explorées afin d'accomplir des tâches de classification des documents textuels (Jain, Murty and Flynn, 1999). On distingue les différentes méthodes de classification en fonction de la rigidité des regroupements effectués (*hard clustering* vs *soft clustering*) (Manning et Schütze, 1999). Les méthodes de *hard clustering* permettent de positionner un document dans un seul groupe. Par contre, certaines techniques de *soft clustering* permettent de situer le document dans plus d'un ensemble en précisant, pour le document, son degré d'appartenance à chacun de ceux-ci.

Par ailleurs, les techniques de *hard clustering* peuvent aussi faire l'objet de distinctions supplémentaires. Il est possible de distinguer, d'une part, les techniques effectuant des regroupements ou des partitionnements plats (*flat*) et, d'autre part, les techniques effectuant des regroupements hiérarchiques.

Les regroupements plats sont caractérisés par le fait qu'aucune relation précise n'est déterminée entre les différents regroupements générés (figure 2). Les méthodes de cette catégorie sont très souvent de nature itérative. En effet, elles procèdent d'abord en déterminant un nombre fini de regroupements, ensuite en raffinant chacun des regroupements effectués.

Quant aux techniques de classification permettant d'effectuer des regroupements hiérarchiques, elles se caractérisent par la production de nœuds qui représentent chacun une sous-classe d'un nœud de niveau supérieur (figure 3). Les méthodes les plus fréquemment employées pour la classification hiérarchique peuvent être regroupées en deux sous-catégories. La première englobe les méthodes dites « agglomératives » (*bottom-up*) ; celles-ci procèdent d'abord en identifiant tous les éléments à classer, ensuite en effectuant successivement plusieurs regroupements. La seconde sous-catégorie englobe les méthodes dites « divisives » (*top-down*) ; celles-ci procèdent d'abord en identifiant un seul regroupement, ensuite en divisant ou en fractionnant le groupe initial.

Application à la recherche d'information

Dans le domaine de la fouille de textes, les récents développements techniques (concernant, entre autres, le développement d'algorithmes d'extraction et d'organisation automatiques d'information) et méthodologiques (desquels relève principalement la modélisation des démarches à suivre afin d'appliquer efficacement les techniques) ont récemment été explorés au sein d'applications de recherche d'information en ligne. D'ailleurs, depuis quelques années, plusieurs prototypes d'applications industrielles d'analyse et de recherche d'information ont été proposés afin d'intégrer certaines techniques de fouille de textes davantage sensibles à la dimension sémantique des documents.

Actuellement, les processus de classification et de catégorisation automatiques ont été les plus exploités dans le contexte de la recherche d'information. Ces deux processus, bien qu'ils puissent être exploités afin d'assister différentes tâches liées à l'analyse de l'information numérique, sont principalement utilisés dans un contexte de recherche d'information afin de lever l'ambiguïté sémantique des termes de requête. Cette perspective d'application repose en partie sur l'hypothèse suivante : les mots avec lesquels les termes de la requête cooccurrent sont de bons indices pour identifier la signification précise des termes de la requête en question. Cette hypothèse est d'ailleurs à la base même de l'utilisation du modèle vectoriel pour la recherche d'information (Salton et McGill, 1983). Lors de l'utilisation de stratégies d'extraction et d'organisation automatiques d'information, l'objectif est d'exploiter au maximum cette idée en procédant, en plus, au regroupement automatique des documents. Comme nous l'avons souligné, le regroupement automatique des documents peut être accompli en utilisant soit un algorithme de classification, soit un algorithme de catégorisation. Dans les deux cas, au terme du processus, les documents sont regroupés sur la base de thématiques communes, permettant ainsi à l'utilisateur de porter son attention sur les documents inscrits dans des regroupements thématiques qui combleront plus adéquatement son besoin d'information.


Les principales applications de recherche d'information en ligne fondées sur l'utilisation de la classification ou de la catégorisation automatiques des documents sont *Grokker*¹⁰ et *Clusty*¹¹. Ces deux applications possèdent plusieurs caractéristiques communes, mais se distinguent l'une de l'autre à plusieurs égards.

La différence importante entre ces deux outils est qu'ils ne sont pas actuellement applicables sur des corpus de même type. *Clusty* interroge la partie visible du Web en entier, alors que *Grokker* n'offre actuellement que la

10. <http://www.grokker.com>

11. <http://www.clusty.com>

Figure 4
Interface de recherche du moteur *Clusty*



les principales catégories thématiques présentes dans les documents préalablement regroupés.

L'exemple suivant illustre bien la pertinence de recourir à des procédés de classification et de catégorisation automatiques des documents pour assister la recherche d'information. En utilisant le terme « *mercury* » comme requête, les deux outils de recherche offrent à l'utilisateur la possibilité de parcourir les documents récupérés, tout en lui indiquant qu'il s'agit d'un terme très polysémique. En effet, le terme anglais « *mercury* » peut être utilisé pour désigner tantôt un dieu romain, tantôt une planète, tantôt un élément chimique, ou encore une marque de voiture, et même d'autres types de moyen de transport, plusieurs lieux géographiques, un chanteur, etc¹³. Compte tenu de la polysémie du terme « *mercury* », il n'est donc pas surprenant qu'une majorité de documents récupérés par les moteurs de recherche traditionnels sur le Web présentent des informations non pertinentes pour les utilisateurs. Ce problème pourrait être corrigé, en partie, en spécifiant la requête. Mais cette solution, très imparfaite dans les faits, implique que l'utilisateur sache *a priori* quelle information il recherche et quels sont les meilleurs termes pour y accéder. Or, en pratique,

les utilisateurs parcourent (*browse*) le Web sans y chercher des documents précis. De plus, ils sont souvent peu compétents dans la formulation des requêtes. Pour ces raisons, la classification et la catégorisation automatiques des documents s'avèrent des plus fécondes pour assister la découverte d'information, car elles permettent de mettre en lumière certaines dimensions thématiques potentiellement inconnues de l'utilisateur, sans toutefois lui imposer de faire des choix inutiles.

Dans notre exemple, il n'est pas étonnant de constater le nombre élevé de regroupements proposés tant par *Clusty* que par *Grokker*. Ainsi, pour le moteur de recherche *Grokker*, on note les principaux regroupements suivants (la valeur entre parenthèses correspond au nombre de documents dans chaque regroupement) : *Planet Mercury* (39), *General* (28), *Mercury Information* (17), *Solar System* (15), *Project Mercury* (12), *Mercury in Fish* (9), *Mercury Element* (8), *Mercury Levels* (8), *Sun* (8), etc.

Voici les résultats du moteur de recherche *Clusty* (la valeur entre parenthèses correspond ici aussi au nombre de documents dans chaque regroupement) : *Planet* (34), *Photos* (39), *Element* (15), *Dealer Ford-Mercury* (12), *Project* (11), *Events* (11), *Poisoning* (10), etc.

Dans les deux applications, il importe de mentionner que les regroupements sont effectués par un algorithme

13. On retrouve dans la version anglaise de Wikipédia plus d'une trentaine d'entrées associées au terme « *mercury* ».

Figure 5
Interface de recherche du moteur *Grokker* (sans visualisation graphique)




Figure 6
Interface de recherche du moteur *Grokker* (avec représentation graphique de la même structure présente dans la figure 5)

