

Fouille des données complexes.

Dirigé par **Omar Boussaïd, Pierre Gançarshi, Florent Massiglia et Brigitte Trousse.**
Revue des Nouvelles Technologies de l'Information, série E, n°4, Cépadués-Éditions, 2005, 286 p.

L'exploitation des données collectées à partir des différents supports est en passe de devenir un enjeu industriel important. En effet, les objets du monde réel ne se présentent pas tous de façon unimodale : un dossier médical, par exemple, comporte certes des données numériques pouvant être structurées de façon tabulaire comme les résultats d'analyses biochimiques, mais incorpore également des données textuelles comme les comptes-rendus d'observations cliniques, des graphiques tels que les tracés d'électrocardiogramme ou d'électro-encéphalogramme, voire des images complexes fournies par les radiographies, échographies et scanners. De même, les données recélées par les sites web se présentent selon différents modes : tableaux, textes, graphiques, images, voire sons qui ne sont pas forcément redondants du point de vue informationnel. Ainsi dans bien des domaines comme le multimédia, la télédétection, l'imagerie médicale, les systèmes d'information géographique, la bio-informatique, les données traitées pour l'extraction de connaissances regroupent différents formats de codage pour le texte, les graphiques, les images ou les sons voire différentes catégories d'information qu'il s'agisse de descriptions factuelles, de connaissances, voire de véritables ontologies.

Le défi que rente de relever la fouille des données complexes est de pouvoir prendre en compte la totalité des informations disponibles concernant les entités qui constituent les unités taxinomiques élémentaires. Cela suppose d'être capable d'intégrer des informations de nature différente et de pouvoir ainsi les rattacher à une même catégorie sémantique. Sur le plan méthodologique, il s'agit donc de définir une mesure de ressemblance ou de dissemblance entre deux objets dont la description est fournie par un complexe d'informations. Jusqu'à présent, les approches proposées ont surtout été fondées sur la juxtaposition de similarités ou de dissimilarités partielles.

Dans ce contexte, ce numéro 4 de la thématique Extraction et gestion des connaissances dédié à la Fouille de données complexes dresse donc un premier bilan du groupe de travail créé sur l'initiative du professeur Zighed sous l'égide de l'association Extraction et Gestion des Connaissances Certains articles portent sur la qualité, l'hétérogénéité et le caractère multi-sources des données. D'autres s'intéressent à l'image, soit pour l'indexer, soit pour en extraire de l'information, soit pour en pondérer les attributs. Signalons également des contributions portant sur la fouille de documents effectuée soit directement par des méthodes prenant en compte le contexte structurel ou en étudiant l'adéquation des modèles de représentation aux méthodes de catégorisation, soit indirectement en étudiant la sélection de règles issues de la fouille de textes ou en concevant un modèle de cartes topologiques pour données catégorielles, voire en élaborant des méthodes de recherche d'informations inattendues dans des textes. Des contributions plus spécifiques à la gestion des bases de données figurent également dans ce numéro, portant notamment sur la sélection d'index bitmap de jointure.

Parmi les travaux présentés, d'autres contributions se situent au confluent de l'extraction de connaissances et de l'ingénierie des connaissances en manipulant à la fois des données et des connaissances du domaine d'application comme en accidentologie ou dans le domaine de la médecine. La modélisation multivues des connaissances et leur formalisation sous forme de méta-données permet leur intégration au processus d'extraction : certains auteurs tentent alors d'optimiser l'extraction en utilisant des connaissances issues du domaine de l'analyste.

La complexité des données amène souvent à adapter certaines méthodes existantes ou à en concevoir de nouvelles, notamment pour les processus de classification ou de catégorisation en utilisant soit des règles d'association, soit la programmation logique inductive, soit des algorithmes génétiques.

Certes, la fouille de données peut se concevoir comme un processus isolé mais elle est également une étape essentielle du processus d'extraction des connaissances. En amont, le choix des techniques de représentation des données peut avoir un impact sur le processus de fouille : cette problématique est explorée par des contributions sur les méthodes de représentation des documents en vue de leur catégorisation. En aval, l'utilisation des méthodes de visualisation comme les cartes topologiques peut constituer une aide décisive à l'interprétation des résultats.

La complexité en temps comme en dimension d'un processus d'extraction de connaissances requiert des méthodologies de fouille permettant d'anticiper les résultats définitifs dès les premières étapes du processus d'extraction. Un certain nombre de contributions s'attachent donc à améliorer la recherche d'informations en exploitant les résultats d'une fouille de données, soit dans des entrepôts de données textuelles, soit dans une base d'images fixes.

L'interactivité du processus d'extraction des connaissances est également abordée soit pour permettre à l'utilisateur d'intervenir au cours du processus de fouille des données en proposant un apprentissage supervisé permettant de réduire le bruit de fonds en imagerie médicale, soit d'éviter les boucles éternelles dans les analyses textuelles, soit d'obtenir des informations temporelles utiles pour un processus d'analyses ultérieures (cas des dépêches épidémiologiques).

Espérons que dans le domaine des nouvelles technologies de l'information, de telles éditions thématiques puissent se multiplier afin de permettre aux chercheurs francophones, contribuant à ce champ scientifique en pleine expansion qu'est l'extraction de connaissances à partir des entrepôts de données, de mieux faire connaître leurs travaux et les possibilités d'application à l'ensemble des communautés techniques concernées.

Dominique Desbois.