



HAL
open science

Expériences de classification d'une collection de documents XML de structure homogène

Thierry Despeyroux, Yves Lechevallier, Brigitte Trousse, Anne-Marie Vercoustre

► **To cite this version:**

Thierry Despeyroux, Yves Lechevallier, Brigitte Trousse, Anne-Marie Vercoustre. Expériences de classification d'une collection de documents XML de structure homogène. 5ème Journées d'Extraction et de Gestion des Connaissances (EGC 2005), Jan 2005, Paris, France. inria-00000186v2

HAL Id: inria-00000186

<https://inria.hal.science/inria-00000186v2>

Submitted on 9 Aug 2005

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Expériences de classification d'une collection de documents XML de structure homogène

Thierry Despeyroux*, Yves Lechevallier*
Brigitte Trousse**, Anne-Marie Vercoustre*

*Inria - Rocquencourt
B.P. 105 - 78153 Le Chesnay Cedex, France

**Inria - Sophia Antipolis
B.P. 93 - 06902 Sophia Antipolis, France
email : Prénom.Nom@inria.fr
[http ://www-rocq.inria.fr/axis/](http://www-rocq.inria.fr/axis/)

Résumé. Cet article présente différentes expériences de classification de documents XML de structure homogène, en vue d'expliquer et de valider une présentation organisationnelle pré-existante. Le problème concerne le choix des éléments et mots utilisés pour la classification et son impact sur la typologie induite. Pour cela nous combinons une sélection structurelle basée sur la nature des éléments XML et une sélection linguistique basée sur un typage syntaxique des mots. Nous illustrons ces principes sur la collection des rapports d'activité 2003 des équipes de recherche de l'Inria en cherchant des groupements d'équipes (Thèmes) à partir du contenu de différentes parties de ces rapports. Nous comparons nos premiers résultats avec les thèmes de recherche officiels de l'Inria.

1 Introduction

Les documents XML sont maintenant incontournables et la classification de ces documents est un domaine de recherche très actif, en particulier pour définir des modèles de représentations de documents qui étendent les modèles traditionnels en tenant compte de la structure du texte (Yi and Dundaresan, 2000), (Denoyer and al.). Cela revient souvent à considérer que les même mots apparaissant dans des éléments XML différents sont en fait différents. Ces approches sont génériques, elles peuvent s'appliquer quelque soit la DTD, alors que notre approche suppose une connaissance d'une sémantique implicite des éléments pour les sélectionner.

Certaines méthodes de classification réduisent les documents XML à leur partie purement textuelle, sans prendre avantage de la structure qui pourtant véhicule une information riche. Nous nous intéressons à l'impact du choix des parties de documents sélectionnées sur le résultat de la classification, l'idée étant que ces différentes parties participent à différentes vues pouvant mener à des classifications différentes. Nous pratiquons successivement deux niveaux de sélection : une sélection utilisant la structure du document, puis une sélection linguistique au niveau du texte précédemment sélectionné. Nous utilisons ensuite un algorithme de classification qui va construire une partition des documents, affecter les documents à des classes et exhiber la liste des mots qui ont permis la classification.

Nos expériences utilisent la collection des rapports d'activité (RA) en XML rédigés par les équipes de recherche de l'Inria. Nous cherchons à regrouper les équipes de recherche travaillant dans des domaines proches, et à comparer le résultat aux deux groupements officiels en thèmes de recherche, le premier utilisé jusqu'en 2003 (Thèmes 2003), le second proposé en 2004 (Thèmes 2004).

2 Le rapport d'activité de l'Inria

L'Inria publie un rapport d'activité annuel dont l'annexe scientifique est accessible sur le WEB. La version 2003 de cette annexe peut être trouvée à l'adresse : <http://www.inria.fr/rapportsactivite/RA2003/index.html>. C'est un ensemble de rapports en anglais produits par chaque équipe de recherche. La version XML de ces rapports contient 146 fichiers, soit 229 000 lignes ou plus 14,8 Moctets de données.

La structure logique est définie par une DTD. Si le style et le contenu sont libres, la forme requiert certaines sections alors que d'autres sont optionnelles :

```
<!ELEMENT raweb (accueil, moreinfo?, composition, presentation,
fondements?, domaine?, logiciels?, resultats, contrats?,
international?, diffusion?, biblio) >
```

Les sections obligatoires contiennent la liste des membres de l'équipe, une présentation des objectifs, les résultats nouveaux et les publications. Les sections facultatives contiennent les pré-requis (fondements), les domaines d'application, les logiciels produits ainsi que les diverses collaborations.

Les équipes de recherche sont regroupées dans des *thèmes* dont le rôle est de faciliter la présentation de l'activité globale de l'institut et de faciliter leur évaluation. Le nombre de ces thèmes, et leur composition, vient de changer récemment en relation avec les objectifs stratégiques de l'institut ce qui a motivé notre étude de l'impact du changement des Thèmes 2003 en Thèmes 2004. La question est donc de savoir s'il existe un regroupement naturel des équipes en fonction du rapport d'activité et de voir quelles sont les parties du texte caractérisent au mieux les équipes vis à vis des présentations qui sont faites.

3 Méthodologie pour classer les documents XML

Notre objectif est de regrouper automatiquement les équipes Inria en *thèmes* de recherche, en s'appuyant sur leur rapports d'activité. Nous supposons donc que les RA reflètent les domaines de recherche des équipes et que certaines parties de ces rapports sont plus spécifiques que d'autres dans la caractérisation des domaines de recherche des équipes ; par exemple, nous supposons que les conférences et revues dans lesquels les chercheurs publient sont très représentatives de leur domaine.

3.1 Sélection structurelle et sélection du vocabulaire

La première étape consiste à sélectionner les parties des RA pertinentes pour cette tâche de classification. Cette extraction utilise les outils décrits dans (Despeyroux,

Experiences	number of projects	extrated words	selected words	voca- bulary
K-F	80	2234	1053	134
K-all	121	8671	6171	382
T-P	138	63711	16036	365
T-PF	139	320501	87416	809
T-C	131	10806	7915	887

TAB. 1 – Taille des données dans les différentes expériences

2004), mais d’autres outils standard XML sont utilisables si l’extraction ne requiert pas d’inférence.

Comme nous supposons que différentes parties du RA peuvent jouer un rôle différent pour la classification des équipes, nous avons mené cinq expériences utilisant des parties prédéfinies du RA. Le but est d’identifier les parties les plus significatives.

1. Expérience K-F : Mots-clefs attachés à l’élément *fondation*
2. Expérience K-all : Tous les Mots-clefs du document.
3. Expérience T-P : Plein texte de l’élément *présentation*
4. Expérience T-PF : Plein texte des éléments *présentation* et *fondation*
5. Expérience T-C : Noms des conférences, workshops, congrès, etc.

La seconde étape de prétraitement est la sélection automatique de mots représentatifs des cinq expériences de l’étape précédente. Les méthodes traditionnelles de sélection de mots sont basées sur des approches statistiques, par exemple utilisant la fréquence des mots, ou le gain d’information. Nous avons choisi une approche basée sur l’analyse de la langue naturelle, qui ne peut généralement pas être appliquée pour un volume de textes trop important en raison du coût de calcul. Nous utilisons l’outil TreeTagger développé à l’Institut de Linguistique Computationnelle de l’Université de Stuttgart (Schmid, 1994). TreeTagger marque les mots d’un texte avec des annotations grammaticales (nom, verbe, article, etc.) et transforme les mots en leur racine syntaxique (lemmatisation).

Pour les expériences K-F et K-all (mots-clefs), nous conservons les noms, verbes et adjectifs, tandis que pour T-PF et T-P (texte), nous ne gardons que les noms. Il y a une difficulté avec les conférences qui sont écrites de façon très hétérogène par les équipes : certaines utilisent le nom complet, d’autre l’acronyme sous des formes variées (e.g. POPL’03, POPL03, POPL 2003). Pour résoudre ce problème, nous avons construit manuellement une liste normalisée de conférences et réalisé automatiquement la correspondance entre l’intitulé trouvé dans le RA et la forme normalisée. Enfin, nous avons éliminé dans toutes les cas tous les mots qui ne sont pas utilisés au moins une fois par deux équipes. La table 1 donne la taille des données utilisées dans chaque expérience.

3.2 Méthode de classification et évaluation externe

L’objectif de cette troisième étape est de regrouper les documents (rapport d’activité d’une équipe) en un ensemble de classes disjointes à partir des vocabulaires issus des cinq expériences décrites dans le paragraphe précédent.

Pour réaliser ce classement nous utilisons une méthode de partitionnement, proposée dans (Celeux et al., 1989), où la distance est basée sur les fréquences des mots du vocabulaire choisi. Le principe de l'algorithme est proche de l'algorithme des k-means. Comme pour la méthode des k-means nous représentons les classes par des prototypes qui résument, au mieux, l'information des documents appartenant à chacune des classes.

Plus précisément, si le vocabulaire choisi est constitué de p mots alors chaque document s est représenté par le vecteur $x_s = (x_s^1, \dots, x_s^j, \dots, x_s^p)$ où x_s^j est le nombre d'occurrence du mot j dans le document s , alors le prototype g d'une classe U_i est représenté par $g_i = (g_i^1, \dots, g_i^j, \dots, g_i^p)$ où g_i^j est calculé par $g_i^j = \sum_{s \in U_i} x_s^j$.

Le prototype de chaque classe i étant fixé, chaque document est alors affecté à la classe dont la proximité du prototype avec ce document est la plus petite. Dans nos expériences la proximité est calculée par une distance entre les distributions associées aux documents et aux prototypes (Celeux et al., 1989).

L'évaluation de la qualité des classes générées par la méthode de classification est basée sur sa comparaison avec les deux listes de thèmes utilisés par l'Inria. Il s'agit d'une évaluation *externe* puisque ces deux listes de thèmes n'ont pas été utilisées par l'algorithme de classification. Pour cette évaluation externe deux mesures complémentaires ont été utilisées : la *F-measure* et le *corrected rand*.

La **F-measure** proposée by (Larsen and Aone, 1999) combine les mesures de *précision* et *rappel* bien connues en recherche d'information. Soient n_{ik} le nombre des équipes de recherche Inria ayant leurs rapports classés dans la classe U_i et affectés au thème C_k , n_i le nombre de rapports de la classe U_i , n_k le nombre d'équipes du thème C_k et n est le nombre d'équipes analysées. Alors la F-measure $F(i, j)$ entre le groupe calculé U_i et le groupe a priori C_k est égale à $(2 * R(i, j) * P(i, j) / (R(i, j) + P(i, j)))$ où $R(i, k) = n_{ik} / n_i$ est le rappel et $P(i, k) = n_{ik} / n_k$ est la précision.

La F-measure entre la partition a priori U en K groupes et la partition P des équipes Inria obtenue par la méthode de classification est égale à :

$$F = \sum_{k=1}^K \frac{n_{.k}}{n} * \max_j (F(k, j)) \quad (1)$$

L'index **corrected Rand** (CR) a été proposé par (Hubert and Arabie (1985)) pour comparer deux partitions. Nous rappelons sa définition. Soit $U = \{U_1, \dots, U_i, \dots, U_r\}$ et $P = \{C_1, \dots, C_k, \dots, C_K\}$ deux partitions d'un même ensemble de équipes ayant respectivement r et K classes. L'index du *corrected Rand* est :

$$CR = \frac{\sum_{i=1}^r \sum_{k=1}^K \binom{n_{ik}}{2} - \binom{n}{2}^{-1} \sum_{i=1}^r \binom{n_i}{2} \sum_{k=1}^K \binom{n_k}{2}}{\frac{1}{2} [\sum_{i=1}^r \binom{n_i}{2} + \sum_{k=1}^K \binom{n_k}{2}] - \binom{n}{2}^{-1} \sum_{i=1}^r \binom{n_i}{2} \sum_{k=1}^K \binom{n_k}{2}} \quad (2)$$

où $\binom{n}{2} = \frac{n(n-1)}{2}$.

La valeur de $CR \in [0, 1]$. Une valeur proche de 0 correspond à une partition aléatoire.

4 Analyse des résultats

La table 2 résume les résultats obtenus pour différentes sélections de mots et différents nombres de classes (4, 5, 9). Nous analysons d'abord les résultats pour Thèmes

Exp.	Number clusters	F themes2003	Rand themes2003	F subthemes	Rand subthemes	F themes2004	Rand themes2004
K-F-a	4	0.53	0.14	0.38	0.09	0.46	0.11
K-F-b	5	0.44	0.05	0.35	0.06	0.37	0.03
K-F-c	9	0.42	0.10	0.37	0.08	0.43	0.12
K-all-a	4	0.52	0.17	0.36	0.09	0.47	0.15
K-all-b	5	0.53	0.17	0.37	0.10	0.54	0.22
K-all-c	9	0.46	0.13	0.40	0.12	0.38	0.10
T-P-a	4	0.55	0.19	0.40	0.14	0.50	0.19
T-P-b	5	0.45	0.11	0.42	0.12	0.47	0.15
T-P-c	9	0.44	0.11	0.45	0.16	0.44	0.14
T-PF-a	4	0.66	0.32	0.49	0.27	0.50	0.21
T-PF-b	5	0.56	0.22	0.43	0.18	0.51	0.20
T-PF-c	9	0.48	0.22	0.55	0.29	0.46	0.19
T-C-a	4	0.51	0.15	0.39	0.15	0.50	0.21
T-C-b	5	0.44	0.18	0.45	0.24	0.47	0.17
T-C-c	9	0.45	0.13	0.47	0.21	0.45	0.15

TAB. 2 – Résultats avec mesure de validité externe

2003 et Thèmes 2004 séparément, puis entre eux.

Avec les Thèmes 2003 comme référence, les meilleurs résultats sont obtenus de façon consistante pour les deux mesures et dans tous les cas quand le nombre de classes est fixé à 4. Une exception est le groupement en 9 classes quand à la fois le texte des éléments *présentation* et *fondation* (T-PF-c) est utilisé. Le meilleur résultat de tous est obtenu avec 4 classes qui utilise le texte des éléments *présentation* et *fondation* (T-PF-a).

Une analyse plus fine utilisant les sous-thèmes (omise par manque de place) montre une bonne correspondance entre classes et sous-thèmes, sauf pour les sous-thèmes 1c et 2a regroupés dans la classe 4, et le thème 3a divisé entre les classes 1 et 4.

Pour Thèmes 2004, nous obtenons les meilleurs résultats pour 5 classes et en utilisant tous les mots clefs (K-all-b).

Dans les deux cas, les sections *fondation* semblent représentatives des domaines de recherche mis en avant par les thèmes, que ce soit par le texte de ces sections ou les mots-clefs qui y sont attachés (pour les équipes qui en ont fourni).

On peut noter que les comparaisons sont généralement meilleurs avec Thèmes 2003 qu'avec Thèmes 2004, à l'exception du cas de 5 classes créées en utilisant tous les mots-clefs. Il y a peu de différences quand la classification se fait à partir des noms de conférence. Bien que décevant, ceci peut s'expliquer par le fait que nous n'utilisons pas TreeTagger dans ce cas, résultant en l'utilisation d'un vocabulaire plus large et hétérogène (voir table 1).

On peut aussi noter que les deux mesures utilisées sont très cohérentes entre elles : une valeur élevée de la F-mesure correspond à un bon rand index.

5 Conclusion

Nous avons présenté une méthodologie pour la classification de documents XML de structure homogène et son évaluation par rapport à deux typologies existantes. Nous pensons que l'approche peut être utilisée pour d'autres collections XML dont la sémantique de la DTD est connue, même informellement.

Les résultats montrent que la qualité de la classification dépend fortement des parties de documents sélectionnées. Dans notre application, l'utilisation de la partie *fondation* des rapports donne de meilleurs résultats que l'utilisation des mots-clefs. On peut tourner ces conclusions à l'envers, comme une indication qu'un meilleur choix des mots-clefs et de la partie *présentation* permettrait de mieux décrire nos domaines de recherche stratégiques.

Remerciements : Les auteurs tiennent à remercier Mihai Jurca, ingénieur dans l'équipe AxIS, pour son aide dans le prétraitement des données.

Références

- Celex G., Diday E., Govaert G., Lechevallier Y., Ralambondrainy, H. (1989) : *Classification Automatique des Données, Environnement statistique et informatique*. Bordas, Paris.
- Denoyer L., Vittaut J.-N., Allinari P., Brunessaux S., Brunessaux S. (2003), Structured Multimedia Document Classification, In *DocEng'03*, Grenoble, France, pp 153-160.
- Despeyroux Th. (2004), Practical Semantic Analysis of Web Sites and Documents, In *Proceedings of the 13th World Wide Web Conference (WWW2004)*, New York City, pp 685-693.
- Guillaume D., Murtagh F. (2000), Clustering of XML documents, *Computer Physics communications*, Vol. 127, pp 215-227.
- Hubert L., Arabie P. (1985), "Comparing Partitions", *Journal of Classification*, Vol. 2, pp 193-218.
- Larsen B., Aone C. (1999), Fast and effective text mining using linear-time document clustering, In *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining*, pp 16-22.
- Schmid H. (1994), Probabilistic Part-of-Speech Tagging Using Decision Trees, In *Proc. of the International Conference on New Methods in Language Processing*, Manchester, UK, pp 44-49.
- Yi J., Sundaresan N. (2000), A classifier for semi-structured documents, In *Proc. of the 6th International Conference on Knowledge Discovery and Data mining*, pp 340-344.

Summary

This paper presents some experiments in clustering homogeneous XML documents to validate an existing organisational structure. Our approach integrates techniques for extracting knowledge from documents with document clustering method. We focus on the feature selection used for clustering and its impact on the emerging classification; We mix the selection of structured features with the selection of textual features that is based on syntactic typing by means of a tagger. We illustrate and evaluate this approach with a collection of XML activity reports written by Inria research teams for year 2003. The objective is to cluster teams into larger groups (Themes) and to compare the results with Inria official research themes.