
La fiabilité des informations sur le web: le cas Wikipédia

Bernard Jacquemin* — **Aurélien Lauf*** — **Céline Poudat**** — **Martine Hurault-Plantet*** — **Nicolas Auray*****

* *LIMSI CNRS UPR 3251 — BP 133 — 91403 Orsay*

{Bernard.Jacquemin,Aurelien.Lauf,Martine.Hurault-Plantet}@limsi.fr

** *Sinequa — 12, rue d'Athènes — 75009 Paris*

poudat@sinequa.com

*** *ENST Paris — 46, rue Barrault — 75013 Paris*

auray@enst.fr

RÉSUMÉ. Les outils de recherche d'information sur le web doivent tenir compte des phénomènes nouveaux liés à l'apparition des blogs, wikis, et autres publications collaboratives. Parmi ces sites, l'encyclopédie Wikipédia constitue une source importante d'information. La qualité de ses informations a pourtant été récemment mise en cause. Mieux connaître les comportements des contributeurs peut permettre de guider les utilisateurs dans des contenus de qualité parfois disparate. Pour explorer cette voie, nous présentons une analyse du rôle de différents types de contributeurs dans le contrôle de la publication d'articles conflictuels.

ABSTRACT. Online IR tools have to take into account new phenomena linked to the appearance of blogs, wiki and other collaborative publications. Among these collaborative sites, Wikipedia represents a crucial source of information. However, the quality of this information has been recently questioned. A better knowledge of the contributors' behaviors should help users navigate through information whose quality may vary from one source to another. In order to explore this idea, we present an analysis of the role of different types of contributors in the control of the publication of conflictual articles.

MOTS-CLÉS: Wikipédia, Fiabilité de l'information, Conflit, Travail collaboratif

KEYWORDS: Wikipedia, Information reliability, Conflict, Collaborative work

1. Introduction

De plus en plus présent dans les résultats des moteurs de recherche, le projet encyclopédique Wikipédia est devenu par les usages une ressource informationnelle de référence, et l'un des sites web les plus visibles et les plus controversés sur Internet. Très éloignée du modèle encyclopédique des Lumières, dans lequel l'expert et sa signature garantissaient la qualité des textes, Wikipédia s'appuie sur cinq principes fondateurs¹ supposés garantir cette qualité : projet encyclopédique, neutralité de point de vue, contenu libre, règles de savoir-vivre, et, enfin, pas de règles fixes en dehors de ces principes. Ainsi, si les processus d'édition sont loin de ceux de l'encyclopédie traditionnelle, les buts affichés de pertinence encyclopédique et d'objectivité² en restent assez proches (Giles, 2005, Endrezzi, 2007). Néanmoins, la qualité de l'encyclopédie libre fait l'objet de débats : si (Giles, 2005) a constaté que la qualité de Wikipédia était finalement comparable à celle de l'encyclopédie *Britannica*, P. Assouline et ses étudiants (Gourdain *et al.*, 2007) se sont attachés à montrer le contraire lorsqu'il s'agit des sciences humaines.

Pour faire respecter ses principes fondateurs, la communauté wikipédienne a progressivement mis en place des outils formels ou informels de contrôle. Ainsi, aux articles sont parfois apposés des bandeaux spécifiques³ évaluant les articles en fonction de leur respect, ou non, des principes fondateurs (par exemple *articles de qualité* par opposition à *articles soupçonnés de non-pertinence* ou *articles non neutres*). Les pages de discussion de ces articles conflictuels accueillent les arguments des contributeurs et médiateurs (Stvilia *et al.*, 2005). Outre les bandeaux, un Comité d'arbitrage (CAr) a été mis en place pour régler les conflits personnels sévères entre contributeurs. Le CAr est un jury de sept arbitres issus de la communauté contributrice qui les élit pour une période de six mois. Les délibérations et les votes du CAr sont publics et cherchent autant que possible l'unanimité. Les arbitres ne se prononcent pas sur le contenu ou la ligne éditoriale, mais s'en tiennent au principe fondamental de savoir-vivre (appelé aussi *wikilove*). Ils ont des possibilités de sanction qui peuvent aller du blocage (interdiction technique et temporaire de contribuer sur un ou plusieurs articles) au bannissement définitif (interdiction de participer à tout contenu de Wikipédia). Bien que relativement rare – seule une centaine d'utilisateurs sur les 31 000 wikipédiens ont comparu devant le CAr en 5 ans –, l'arbitrage constitue un outil important de gouvernance de Wikipédia. C'est à travers ces outils, et les contributeurs qui les utilisent, que s'exerce le contrôle de la publication.

Après une description du corpus utilisé, nous établirons une typologie des contributeurs suivant des paramètres qui reflètent leur implication dans les conflits et leur activité générale de publication et d'administration dans l'encyclopédie. Nous étu-

1. http://fr.wikipedia.org/wiki/Wikipédia:Principes_fondateurs

2. L'articulation entre neutralité de point de vue et objectivité est réalisée ainsi : « Ce que les gens croient, voilà un fait objectif, et nous pouvons présenter cela assez facilement d'un point de vue neutre. » (Jimbo Wales, le fondateur de Wikipédia, http://fr.wikipedia.org/wiki/Wikipédia:Neutralité_de_point_de_vue).

3. http://fr.wikipedia.org/wiki/Catégorie:Maintenance_des_articles

dierons ensuite la répartition de ces types de contributeurs dans l'édition des articles signalés par la communauté wikipédienne comme particulièrement conformes, ou au contraire non conformes, aux principes de pertinence encyclopédique et d'objectivité. Nous concluons sur les liens entre types de contributeur et conformité d'un article aux principes encyclopédiques.

2. Corpus

Wikipédia est un terme générique qui recouvre à la fois une initiative de création d'encyclopédie en ligne⁴ libre, collaborative et multilingue, et l'ensemble des instances de cette encyclopédie, distinctes géographiquement et souvent linguistiquement. Nous disposons de la sauvegarde réalisée le 2 avril 2006, regroupant tous les articles de Wikipédia-France⁵ depuis ses débuts, soit plus de 600 000 pages comprenant notamment près de 370 000 pages d'articles auxquelles sont associées plus de 40 000 pages de discussion sur article. Les corpus que nous étudions sont des pages extraites de cette base transformées en XML par Wiki2Tei⁶.

Nous nous sommes particulièrement intéressés aux conflits entre wikipédiens (Auray *et al.*, 2007, Kittur *et al.*, 2007, Viégas *et al.*, 2004) car ils sont révélateurs de la manière dont le contrôle de la publication s'effectue. Le premier des corpus collectés comprend les 1000 articles de notre collection qui comportent ou ont comporté à un moment de leur évolution un bandeau de controverse de neutralité, ainsi que leur éventuelle page de discussion. Environ 1600 contributeurs apparaissent dans ces pages. Ces contributeurs, bien qu'en petit nombre, ont un poids important dans Wikipédia car ils ont participé à environ 300 000 articles sur les 370 000 pages d'articles de notre collection, soit 81%. Dans les pages d'articles et de discussions, le balisage spécifique des informations consiste essentiellement à associer à chaque intervention sa taille, le nom de son auteur, et la date de son insertion.

L'autre corpus est constitué des quatre-vingts pages d'arbitrages qui se sont tenus durant la période des débuts de Wikipédia-France à avril 2006. Le balisage de chaque page se répartit en rubriques qui répondent à la structure-type des arbitrages. On a ainsi une description du conflit, qui identifie le plaignant et la date de la plainte, le (ou les) accusé(s), la décision de recevabilité et la décision de jugement. Ensuite viennent les argumentaires des protagonistes, les discussions des arbitres sur la recevabilité de la plainte, et enfin le jugement proprement dit qui est composé d'une proposition de sanction et d'un vote des arbitres. Si l'unanimité ne peut se faire autour de la première proposition, d'autres propositions et votes peuvent suivre.

4. Consultable sur <http://www.wikipedia.org/>.

5. Consultable sur <http://fr.wikipedia.org/>

6. Logiciel libre disponible sur <http://wiki2tei.sourceforge.net/> et distribué conformément à la licence BSD (<http://www.opensource.org/licenses/bsd-license.php>). Il convertit les balises de mise en forme du wikitexte en balises XML et insère un en-tête descriptif du document conforme au modèle de la *Text Encoding Initiative* (TEI)

3. Typologie des wikipédiens en conflit personnel

Dans la centaine d'arbitrage de notre corpus, certains noms de contributeurs apparaissent plus souvent, soit dans le rôle du plaignant qui dépose la plainte, soit dans le rôle de l'accusé. Ces deux pôles, fréquence de comparution et rôle dans la plainte, nous permettent de dégager une première typologie des contributeurs en conflit.

Nous avons distingué trois catégories de contributeurs suivant la fréquence de comparution, les *très habitués* qui cumulent entre 3 et 14 comparutions⁷, les *habitués* qui en ont deux, et les *occasionnels* qui ont une seule comparution. Quant à leur rôle dans la plainte, nous avons distingué les *plaignants*, qui sont plus souvent en position d'accusateurs, les *accusés*, qui ont plus de plaintes déposées contre eux qu'ils n'en déposent, et ceux qui comparaissent de façon assez équilibrée tantôt en plaignants tantôt en accusés. On voit sur le tableau 1 que les wikipédiens qui comparaissent souvent, les *très habitués*, sont en majorité plaignants, alors que les *occasionnels*, qui n'ont comparu qu'une fois, sont en majorité des accusés. On constate aussi que la majorité de ceux qui ont comparu deux fois ont été une fois plaignants, une fois accusés.

Comparutions	Contributeurs	Plaignant	Accusé	Les 2
Très habitués	10	50%	30%	20%
Habitués	17	12%	29%	59%
Occasionnels	74	30%	70%	0%

Tableau 1. *Les comparutions au Comité d'arbitrage*

Nous avons ensuite introduit dans cette typologie le mode de contribution à Wikipedia. Ainsi, nous avons considéré le nombre d'interventions dans l'édition de l'ensemble des pages d'articles et de discussions de Wikipédia-France. Nous avons établi quatre catégories, les *très gros contributeurs* dont le nombre d'interventions varie entre environ 12 000 et 40 000 pendant la période considérée, les *gros contributeurs*, entre 2 800 et 12 000, les *contributeurs moyens* entre 600 et 2 800, et les *petits contributeurs*, entre 1 et 600. Nous avons enfin distingué trois catégories de contribution suivant que celle-ci concernait plus souvent les articles, plus souvent les discussions, ou étaient répartis entre les deux.

Contributions	Contributeurs	-> article	-> discussion	Les 2
Très gros contributeurs	7	100%	0%	0%
Gros contributeurs	23	96%	0%	4%
Contributeurs moyens	31	81%	0%	19%
Petits contributeurs	40	70%	5%	25%

Tableau 2. *Les contributions des protagonistes du Comité d'arbitrage*

Le tableau 2 montre que les contributeurs en conflit personnel participent dans l'ensemble davantage à l'élaboration des articles qu'aux discussions qui les accom-

7. 14 est un record, on en a ensuite deux à 7 et un à 4, les autres étant à 3 comparutions.

pagent. En revanche, on constate que moins ils contribuent aux articles, plus ils ont tendance à en discuter. En croisant la fréquence de comparaison et la taille des interventions (tableau 3), on se rend compte que les *très habitués* du CAr sont en majorité des *gros contributeurs*, les *occasionnels* étant plutôt des *petits contributeurs*. En croisant la taille des contributions et le rôle dans la plainte (tableau 4), on constate que les *gros contributeurs* sont plus souvent plaignants et les *petits contributeurs* plus souvent accusés. La part des protagonistes qui sont, de façon comparable, tantôt plaignants, tantôt accusés, reste pour chaque groupe marginale.

Comparutions	Contributeurs	très gros	gros	moyen	petit
Très habitués	10	20%	50%	30%	0%
Habitués	17	13%	29%	29%	29%
Occasionnels	74	4%	18%	31%	47%

Tableau 3. Les types de contributeurs dans les comparutions

Contributions	Contributeurs	Plaignants	Accusés	Les 2
Très gros contributeurs	7	57%	29%	14%
Gros contributeurs	23	39%	44%	17%
Contributeurs moyens	31	32%	58%	10%
Petits contributeurs	40	15%	75%	10%

Tableau 4. Rôle dans la plainte par taille de contribution

Ces tableaux nous suggèrent que les gros contributeurs à Wikipédia en ont bien intégré les principes fondamentaux, et tiennent à les faire respecter. En effet, la tendance qui émerge est que plus ils contribuent aux articles et plus ils jouent un rôle de contrôle de la publication parallèlement à leur participation (Bryant *et al.*, 2005). Ce contrôle s'exerce dans le cadre du CAr par leur rôle plus intensif en tant que plaignant. Il s'exerce majoritairement vis-à-vis de *moyens* et *petits* contributeurs.

4. Les contributeurs en conflit dans les articles non neutres

En amont de l'arbitrage, le bandeau de controverse de neutralité constitue pour nous le premier indice tangible de désaccord entre wikipédiens. Nous avons observé que 77% des protagonistes du CAr figurent parmi les 1600 contributeurs à au moins un article non neutre. Cette forte présence suggère qu'une grande partie des conflits naît de controverses sur l'objectivité. Les *très gros contributeurs* et les *très habitués* du CAr figurent tous dans le corpus des articles non neutres, et les *plaignants* presque tous (90%), alors que les *accusés* y sont moins présents (73%). Ce sont les *petits contributeurs* présents au CAr qui participent le moins aux articles non neutres (57%).

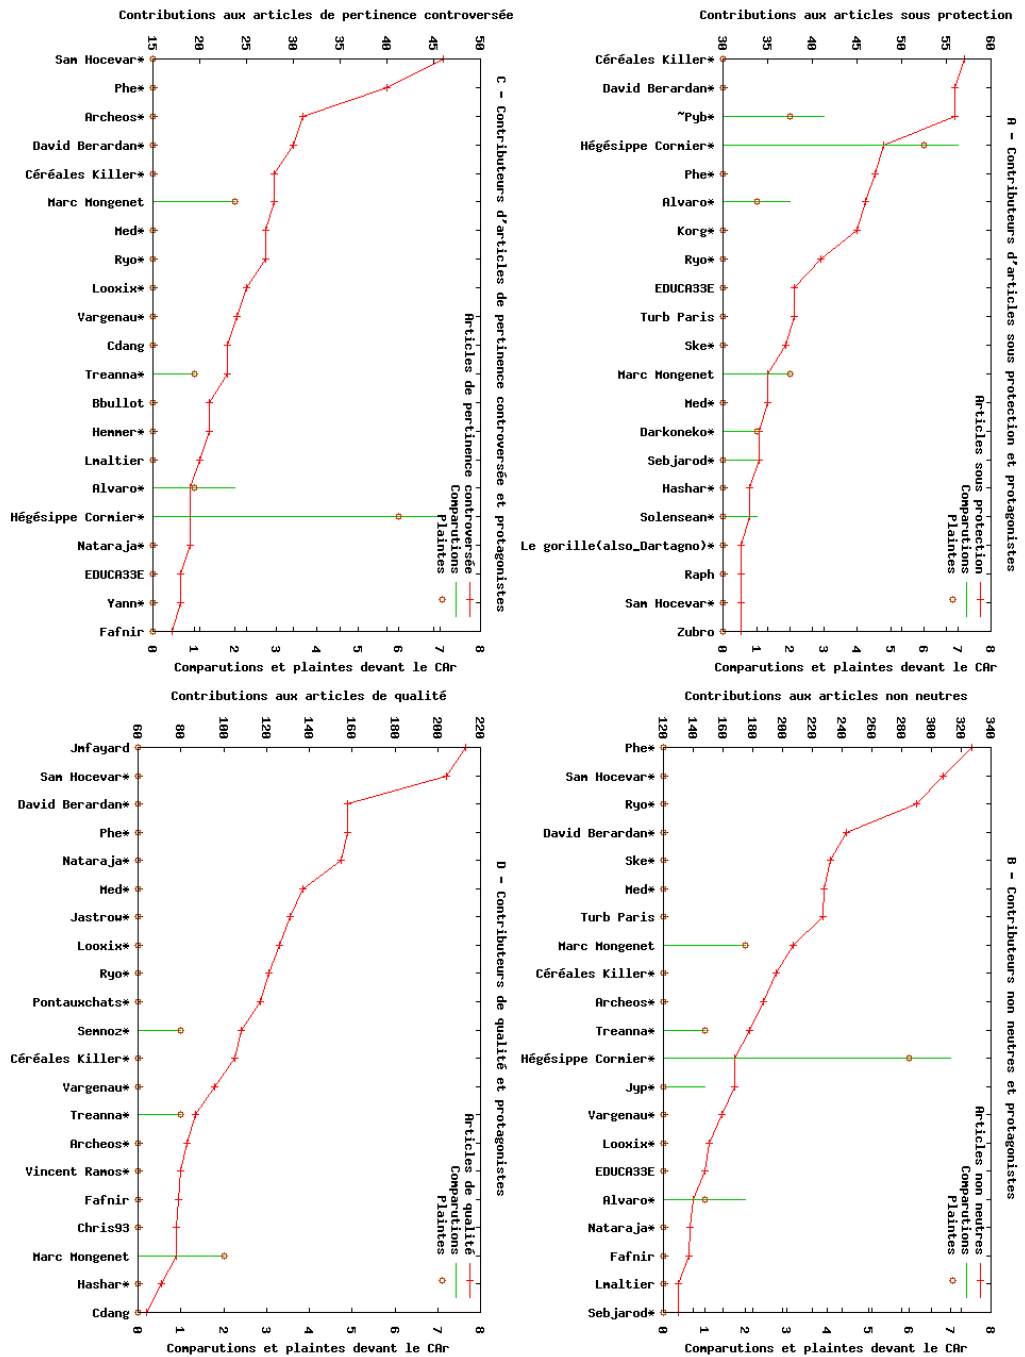


Figure 1. Types d'articles et contributeurs en conflit

Pour donner une idée plus précise des types de comportements des wikipédiens dans le processus de validation de l'information, nous étudions à présent leurs participations à des articles couverts par un bandeau particulier⁸. Nous avons utilisé ces bandeaux pour typer les articles en *articles de qualité*, *articles en controverse de neutralité*, *articles en controverse de pertinence*, et *articles en protection*.

La figure 1 représente, en courbe décroissante, le nombre de contributions respectivement aux articles sous protection (A), aux articles non neutres (B), aux articles en controverse de pertinence (C), et aux articles de qualité (D), des vingt contributeurs les plus prolifiques du corpus des articles non neutres. Sur ces graphes, les wikipédiens de statut particulier⁹ sont marqués d'un astérisque, et leur implication éventuelle dans un arbitrage est indiquée par une ligne verticale proportionnelle au nombre d'arbitrages. On observe que parmi les vingt principaux contributeurs aux articles sous protection (1A), 35% ont comparu devant le CAR. Leur rôle lors de ces arbitrages est assez disparate, tantôt plaignants, tantôt accusés, habitués ou occasionnels devant le CAR. On note par contre qu'au sein des wikipédiens les plus prolifiques dans les articles de qualité (1D), trois seulement sont impliqués dans des arbitrages, toujours comme plaignants. Toutefois, aucun d'eux n'est un habitué du CAR, ce qui tempère cette apparence d'agressivité. Entre ces deux tendances, les contributeurs aux articles non neutres et aux articles non pertinents montrent une tendance moyenne au conflit. En effet 25% des principaux contributeurs aux articles non neutres (figure 1B) et 20% des contributeurs les plus concernés par des articles non pertinents (figure 1C) sont également protagonistes d'un arbitrage. Par ailleurs, il est remarquable que la majorité de ces gros contributeurs ont également un statut particulier. Cela confirme la corrélation déjà signalée entre l'implication forte d'un contributeur, tant par le nombre de contributions que par un statut particulier, et sa présence là où les principes fondateurs de Wikipédia ont besoin d'être défendus. Il en découle une tendance au respect des règles de qualité wikipédiennes de l'information là où ces contributeurs interviennent.

5. Conclusion

En tant qu'espace collaboratif visant à concentrer et structurer des contenus encyclopédiques, Wikipédia est à l'origine de processus coopératifs, d'échange d'information et de désaccords. À la suite d'une étude des habitudes des wikipédiens – tant à travers leurs contributions qu'au cours des controverses et conflits – nous avons dégagé des comportements de nature à guider d'autres utilisateurs et à accorder une certaine confiance à l'information. En effet, notre étude exploratoire a montré une tendance des gros contributeurs impliqués dans l'administration de Wikipédia à s'investir pour faire respecter les règles du projet, notamment dans son principe qualitatif

8. Défini dans Wikipédia comme étant « un type de cadre figurant dans les articles pour transmettre une information ou un lien ».

9. Nous entendons par *statut particulier* une distinction spécifique de droits et de fonctions accordée à certains contributeurs volontaires élus par la communauté. On y retrouve les administrateurs, les arbitres, les wikipompiers, etc.

de neutralité de point de vue, quitte à demander un arbitrage si le comportement d'un contributeur n'est pas conforme au principe du *wikilove*.

Principalement plaignants mais peu habitués du conflit, ces gros contributeurs semblent occuper une position de contrôle éditorial et qualitatif sur l'encyclopédie. En cela, la présence de tels wikipédiens parmi les contributeurs d'un article apporte une certaine fiabilité à l'information qui y a été déposée. En revanche, une forte concentration de contributeurs habitués des conflits personnels pourrait indiquer un article sujet à caution. Cette tendance demande cependant à être confirmée d'une part par une validation qualitative sur des articles non conflictuels, et d'autre part par un examen des mêmes classes de contributeurs dans d'autres instances de Wikipédia.

Remerciements

Ce travail a été réalisé dans le cadre du projet Autograph ANR-05-RNRT-03002 (S0604108 W).

6. Bibliographie

- Auray N., Poudat C., Pons P., « Democratizing scientific vulgarization. The balance between cooperation and conflict in French Wikipedia », *Observatorio*, vol. 1, n° 3, p. 185-189, 2007.
- Bryant S. L., Forte A., Bruckman A., « Becoming Wikipedian : transformation of participation in a collaborative online encyclopedia », *Proceedings of the 2005 international ACM SIGGROUP conference on Supporting Group Work*, ACM Press, Sanibel Island, Florida, USA, p. 1-10, 6-9 novembre, 2005.
- Endrezzi L., « La communauté comme auteur et éditeur : l'exemple de Wikipédia », *Journée d'étude des URFIST "Évaluation et validation de l'information sur Internet"*, 2007.
- Giles J., « Internet encyclopaedias go head to head », *Nature*, vol. 438, n° 7070, p. 900-901, 15 décembre, 2005.
- Gourdain P., O'Kelly F., Roman-Amat B., Soulas D., von Droste zu Hülshoff T., *La Révolution Wikipédia. Les encyclopédies vont-elles mourir ?*, Éditions Mille et une nuits, Paris, 2007.
- Kittur A., Suh B., Pendleton B., Chi E., « He says, She Says : Conflict and Coordination in Wikipedia », *Proceedings of the SIGCHI conference on Human factors in computing systems*, San Jose, Californie, USA, p. 453-462, 2007.
- Stvilia B., Twidale M., Gasser L., Smith L., Information Quality Discussions in Wikipedia, Technical Report n° ISRN UIUC LIS-2005/2+CSCW, University of Illinois at Urbana-Champaign, 2005.
- Viégas F. B., Wattenberg M., Dave K., « Studying Cooperation and Conflict between Authors with history flow Visualizations », *Proceedings of the SIGCHI conference on Human factors in computing systems*, Vienne, Autriche, p. 575-582, avril, 2004.

ANNEXE POUR LE SERVICE FABRICATION
A FOURNIR PAR LES AUTEURS AVEC UN EXEMPLAIRE PAPIER
DE LEUR ARTICLE ET LE COPYRIGHT SIGNÉ PAR COURRIER
LE FICHER PDF CORRESPONDANT SERA ENVOYÉ PAR E-MAIL

1. ARTICLE POUR LES ACTES :
CORIA 2008 Trégastel 12-14 mars 2008
2. AUTEURS :
Bernard Jacquemin — Aurélien Lauf* — Céline Poudat** — Martine Hurault-Plantet* — Nicolas Auray****
3. TITRE DE L'ARTICLE :
La fiabilité des informations sur le web: le cas Wikipédia
4. TITRE ABRÉGÉ POUR LE HAUT DE PAGE MOINS DE 40 SIGNES :
Fiabilité des informations sur le web
5. DATE DE CETTE VERSION :
15 février 2008
6. COORDONNÉES DES AUTEURS :
 - adresse postale :
 - * LIMSI CNRS UPR 3251 — BP 133 – 91403 Orsay
{Bernard.Jacquemin,Aurelien.Lauf,Martine.Hurault-Plantet}@limsi.fr
 - ** Sinequa — 12, rue d'Athènes – 75009 Paris
poudat@sinequa.com
 - *** ENST Paris — 46, rue Barrault – 75013 Paris
auray@enst.fr
 - téléphone : 01 69 85 80 24
 - télécopie : 01 69 85 80 88
 - e-mail : Bernard.Jacquemin@limsi.fr
7. LOGICIEL UTILISÉ POUR LA PRÉPARATION DE CET ARTICLE :
L^AT_EX, avec le fichier de style `article-hermes.cls`,
version 1.2 du 03/03/2005.
8. FORMULAIRE DE COPYRIGHT :
Retourner le formulaire de copyright signé par les auteurs, téléchargé sur :
<http://www.revuesonline.com>

SERVICE ÉDITORIAL – HERMES-LAVOISIER
14 rue de Provigny, F-94236 Cachan cedex
Tél : 01-47-40-67-67
E-mail : revues@lavoisier.fr
Serveur web : <http://www.revuesonline.com>