

# JEP-TALN-RECITAL 2012

JEP : Journées d'Études sur la Parole  
TALN : Traitement Automatique des Langues Naturelles  
RECITAL : Rencontre des Étudiants Chercheurs en Informatique  
pour le Traitement Automatique des Langues

---

Actes de la conférence conjointe JEP-TALN-RECITAL 2012

Atelier DEFT 2012: DÉfi Fouille de Textes

---

## **Éditeurs**

Cyril Grouin  
Dominic Forest  
Gilles Sérasset

4 – 8 Juin 2012  
Grenoble, France

© 2012 Association Francophone pour la Communication Parlée (AFCP) et  
Association pour le Traitement Automatique des Langues (ATALA)

Des versions imprimées de ces actes peuvent être achetées auprès de :

GETALP-LIG  
Laurent Besacier  
BP 53  
38041 Grenoble Cedex 9  
France  
Laurent.Besacier@imag.fr

# Préface

Créé en 2005 à l'image des campagnes d'évaluation internationales TREC (*Text Retrieval Conference*), le défi fouille de texte (DEFT) propose chaque année une campagne d'évaluation francophone en fouille de texte, sur des thématiques et des corpus régulièrement renouvelés.

Plusieurs champs d'activité ont ainsi été abordés au cours des différentes éditions : les ruptures de style en 2005, la segmentation thématique en 2006, la fouille d'opinion en 2007 puis de nouveau en 2009, la classification en genres et thèmes en 2008, et la variation diachronique en 2010 et 2011.

Les campagnes ont porté sur des corpus de discours politiques (de 2005 à 2007), des corpus de critiques grand public sur des livres, des films et des jeux vidéo (en 2007), et des corpus de journaux contemporains (en 2008 et 2009) ou anciens (en 2010 et 2011).

A partir de 2011, un nouveau type de documents a été utilisé dans le défi : les articles scientifiques qui ont paru en revues dans le domaine des Sciences Humaines et Sociales. Plusieurs applications ont ainsi été envisagées sur la base de ce nouveau corpus. En 2011, une tâche d'appariement entre un article scientifique et le résumé qui lui correspond a été proposée, dans une perspective d'identification des éléments saillants d'un article à mettre en avant dans le résumé ; cette édition a permis aux participants d'obtenir d'excellents résultats. Pour cette nouvelle édition, nous proposons de travailler sur l'indexation des articles scientifiques dans une tentative d'identification des mots-clés choisis par les auteurs pour indexer leur article.

Cyril Grouin et Dominic Forest, *co-présidents du Comité de Programme*



# Comités

## Comité de programme

Daille, Béatrice (LINA, Nantes)

Forest, Dominic (EBSI, Université de Montréal), *co-président*

Grouin, Cyril (LIMSI-CNRS, Orsay), *co-président*

Paroubek, Patrick (LIMSI-CNRS, Orsay)

Torres-Moreno, Juan Manuel (LIA, Avignon)

Zweigenbaum, Pierre (LIMSI-CNRS, Orsay)

## Comité d'organisation

Forest, Dominic (EBSI, Université de Montréal)

Grouin, Cyril (LIMSI-CNRS, Orsay)

Paroubek, Patrick (LIMSI-CNRS, Orsay)

Ponton, Claude (Lidilem, Université Stendhal Grenoble 3)

Zampa, Virginie (Lidilem, Université Stendhal Grenoble 3)

Zweigenbaum, Pierre (LIMSI-CNRS, Orsay)



# Sponsors

## ATALA

Association pour le Traitement Automatique des Langues.



## Projet DoXa

Financement Cap Digital.





# Table des matières

## Présentation et résultats

*Indexation libre et contrôlée d'articles scientifiques. Présentation et résultats du défi fouille de textes DEFT2012*

Patrick Paroubek, Pierre Zweigenbaum, Dominic Forest et Cyril Grouin ..... 1

## Méthodes des participants

*Key-concept extraction from French articles with KX*

Sara Tonelli, Elena Cabrio et Emanuele Pianta ..... 15

*Acquisition terminologique pour identifier les mots-clés d'articles scientifiques*

Thierry Hamon ..... 25

*Indexation à base des syntagmes nominaux*

Amine Amri, Maroua Mbarek, Chedi Bechikh, Chiraz Latiri et Hatem Haddad ..... 33

*Détection de mots-clés par approches au grain caractère et au grain mot*

Gaëlle Doualan, Mathieu Boucher, Romain Brixtel, Gaël Lejeune et Gaël Dias ..... 41

*Participation de l'IRISA à DeFT2012 : recherche d'information et apprentissage pour la génération de mots-clés*

Vincent Claveau et Christian Raymond ..... 49

*Participation du LINA à DEFT2012*

Florian Boudin, Amir Hazem, Nicolas Hernandez et Prajol Shrestha ..... 61

*Algorithme automatique non supervisé pour le Deft 2012*

Murat Ahat, Coralie Petermann, Yann Vigile Hoareau, Soufian Ben Amor et Marc Bui .... 69

*Enrichir et raisonner sur des espaces sémantiques pour l'attribution de mots-clés*

Adil El Ghali, Daniel Hromada et Kaoutar El Ghali ..... 77

