

# Vers une recherche d'information adaptative

Exploitation du contexte des requêtes et des documents  
dans l'environnement *Revue.org*

Clémentine Adam et Simon Leva

`{clementine.adam,simon.leva}@univ-tlse2.fr`

CLLE-ERSS & Université de Toulouse 2

21/10/2013

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

## De la recherche d'information orientée système. . .

### Principe

- L'utilisateur exprime son besoin d'information à travers la formulation d'une requête
  - À l'aide d'un modèle, le système identifie dans la collection de documents les informations (documents) pertinentes en réponse à cette requête
- 
- Approche initiale du domaine, apparue dans les années 1960
    - Méthodes de représentation des requêtes et des documents ?
    - Algorithmes d'appariement entre requêtes et documents ?
    - Méthodologies d'évaluation de l'efficacité de ces modèles ?
  - Systèmes de recherche d'information conçus pour tout type d'utilisateur, de tâche de recherche et de document

## ... à la recherche d'information orientée contexte

### Principe

- Influence du contexte et de la dimension cognitive de l'utilisateur au cours de l'interaction avec le système
- Des changements dans notre contexte de recherche peuvent influencer sur notre besoin d'information
- Remise de l'utilisateur au centre du processus de recherche
- Généralisation du *World Wide Web* dans les années 1990
  - Méthodes de représentation des requêtes et des documents intégrant une vision cognitive de leur contenu ?
  - Modèles d'accès contextuel et personnalisé à l'information ?
  - Pertinence système vs. pertinence utilisateur ?
- Systèmes capables de reconnaître des contextes différents et de s'adapter à nos besoins et à nos comportements

## Quels éléments de contexte considérer ?

- 1 **Contexte de l'utilisateur** : contexte personnel (âge, expertise, centres d'intérêts. . .) ou social (individu vs. communauté)
- 2 **Tâche de la recherche** : définie au début de la recherche et susceptible d'évoluer au cours de la recherche
- 3 **Contexte spatio-temporel** : lieu et heure de la recherche
- 4 **Contexte de l'information** : contexte direct de l'information (métadonnées) et source de l'information
- 5 **Mais aussi** : environnement de la recherche (privé vs. professionnel), moyen d'accès à l'information (ordinateur vs. téléphone portable), contexte psychologique de l'utilisateur, contexte de l'interaction avec le système. . .

## Pour quels usages ?

### Hypothèse 1

L'information contextuelle est trop riche et variée pour être traitée par la génération actuelle d'ordinateurs

- Le contexte pertinent n'est accessible qu'aux humains
- Les systèmes peuvent expliciter leur fonctionnement ou exploiter les interactions d'autres utilisateurs

### Hypothèse 2

Les systèmes contextuels peuvent directement exploiter des éléments de contexte dans leur fonctionnement

- Décisions du système incorporant des contraintes contextuelles
- Restriction du contexte à la tâche de la recherche

## Exemple : exploitation des interactions précédentes



## Exemple : exploitation des métadonnées

The image shows a Google search interface for the term "girolle". The search results are displayed in a grid of images. A dropdown menu is open over the "Taille" (Size) filter, showing various image dimensions. The selected option is "Toutes les tailles" (All sizes). Other options include "Grandes", "Moyennes", "Icônes", "Supérieure à...", and "Égale à...". The size options are listed with their dimensions and resolution: 400 x 300, 640 x 480, 800 x 600, 1024 x 768, 1600 x 1200 (2 Mpx), and 2272 x 1704 (4 Mpx). The search results include several images of yellow chanterelle mushrooms (girolles) in various settings, such as growing in a forest or on a wooden surface. A cookie consent banner is visible on the left side of the page.

# Exemple : tâche visant une information spécifique

Google

Web Images Maps Shopping Plus Outils de recherche

Environ 11 200 000 résultats (0,22 secondes)

Les cookies assurent le bon fonctionnement de nos services. En utilisant ces derniers, vous acceptez l'utilisation des cookies.

**Louis Pasteur** - Wikipédia  
[fr.wikipedia.org/wiki/Louis\\_Pasteur](http://fr.wikipedia.org/wiki/Louis_Pasteur)  
Louis Pasteur, né à Dole (Jura) le 27 décembre 1822 et mort à Marnes-la-Coquette (à cette époque en Seine-et-Oise) le 28 septembre 1895, est un scientifique ...  
Louis Pasteur Valléry-Radot - D:Louis Pasteur - Catégorie:Louis Pasteur

**Institut Pasteur** | Pour la recherche, pour la santé, pour demain  
[www.pasteur.fr](http://www.pasteur.fr)  
Centre de recherche dédié à la santé, principalement en biologie du développement, génétique, infectiologie et neurobiologie. L'Institut se présente pour le ...

**Clinique Pasteur, Accueil**  
[www.clinique-pasteur.com/](http://www.clinique-pasteur.com/)  
La Clinique Pasteur place le patient au cœur de son projet d'entreprise et maintient une tradition d'excellence, d'innovation, d'indépendance et d'éthique.  
Espace professionnel - Annuaire Cabinet - Vous êtes pris en charge pour ... - DMP

**pasteur à proximité de Toulouse**  
Cabinet d'Urologie, **Clinique Pasteur**  
[www.clinique-pasteur.com](http://www.clinique-pasteur.com)  
page Google+

**Clinique PASTEUR**  
[www.clinique-pasteur.com](http://www.clinique-pasteur.com)  
3 avis de Google

**Radiologie Pasteur**  
[www.clinique-pasteur.com](http://www.clinique-pasteur.com)  
page Google+

Afficher les résultats pour "pasteur" sur la carte »

**Louis Pasteur**  
Scientifique

Louis Pasteur, né à Dole le 27 décembre 1822 et mort à Marnes-la-Coquette le 28 septembre 1895, est un scientifique français, chimiste et physicien de formation, pionnier de la microbiologie, qui, de son ...  
Wikipédia

**Naissance** : 27 décembre 1822, Dole  
**Décès** : 28 septembre 1895, Marnes-la-Coquette  
**Formation** : École normale supérieure (1846)  
**Distinctions et récompenses** : Médaille Copley, Médaille Rumford, Médaille Lœuwenhoek  
**Enfants** : Marie Louise Pasteur, Jean Baptiste Pasteur, Jeanne Pasteur, Camille Pasteur, Cécile Pasteur  
**Livres** : Discours de Reception Ed 1862, Écrits scientifiques et médicaux

**Recherches associées**

# Exploitation du contexte de l'interaction

## Principe

Au cours du processus de recherche, l'utilisateur transmet de nombreuses informations au moteur de recherche à travers ses interactions avec le navigateur

- **Indicateurs explicites** : requêtes, clic sur des résultats. . .
- **Indicateurs implicites** : temps passé sur les pages de résultat, comportement de navigation. . .
- Inférence de l'objectif de l'utilisateur à partir de ses actions et de son comportement de recherche
  - Succès/difficulté/échec de la recherche ?
  - Type de relation entre une action et l'objectif de l'utilisateur ?
- Étude statistique des interactions entre utilisateur et système

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

# CAAS : Contextual Analysis and Adaptive Search

## Hypothèse

- Le recours au contexte peut améliorer les performances d'un système de recherche d'information et expliquer certains aspects du processus de recherche
- Les éléments de contexte considérés concernent les requêtes, les documents et le système de recherche d'information

## Objectifs

- **Contrôle de la variété des contextes** : modèles représentant les divers aspects du contexte en RI
- **Reconnaissance et adaptation au contexte** : exploitation des modèles afin de choisir la meilleure stratégie de recherche en fonction du contexte détecté

# Éléments de contexte

## 1 Variété des requêtes

- Inférence des attentes de l'utilisateur à partir de ses requêtes ?
- Corrélation entre des types de requêtes et des traits portant sur les requêtes afin de détecter des catégories
- Corrélation entre des requêtes et les performances du système afin de prédire les requêtes difficiles

## 2 Variété des documents

- Détection de traits portant sur les documents permettant de prédire leur pertinence par rapport à une requête soumise dans un contexte donné

## 3 Variété des systèmes

- Évaluation des performances du système en fonction des traitements appliqués et du type de requête considéré

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

## Le portail *OpenEdition*

- Développé par le Centre pour l'édition électronique ouverte
- Libre accès à un ensemble de ressources électroniques dans le domaine des sciences humaines et sociales
  - *Revue.org* : 384 revues, 12 collections de livres
  - *Calenda* : 23 306 événements scientifiques
  - *Hypotheses* : 700 blogs et carnets de recherche
  - *OpenEdition Books* : 896 livres
- 30 millions de consultations en 2012
- Visiteurs provenant essentiellement du monde francophone, des États-Unis et d'Amérique du sud

# Un environnement de recherche à double entrée

The screenshot displays the OpenEdition website interface. At the top left, there is a section for 'Les Cahiers de Framespa' with a presentation of the journal. Below this, a search bar contains the text 'Le pouvoir de l'opinion publique / Micro'. The search results are displayed in a grid format, with a large orange arrow pointing from the search bar to the first result. The first result is a document titled 'Le pouvoir de l'opinion publique / Micro' by 'Micro', published in 2013. The document is available in PDF format and is part of the 'Cahiers de Framespa' collection. The interface also shows a sidebar with 'Cahiers de Framespa' and 'Rechercher' options, and a bottom section with 'Livres & revues à la Une' and 'Actualités'.

**Les Cahiers de Framespa**  
Nouveaux champs de l'histoire sociale

**openedition**  
REVUES.ORG CALENDA HYPOTHESES.ORG

**RECHERCHE**

Qui sommes-nous ?  
OpenEdition Recherche  
Auteurs et les Livres  
Editeurs et les Cahiers  
Plan du portail

**CATALOGUES**

DES LIVRES | DES REVUES | DES DOCUMENTS  
DES CAHIERS | DES CAHIERS

**RECHERCHE**

À PROPOS DES ALERTES ET ABONNEMENTS | NOUVELLES ALERTES | INDICATEUR ABONNEMENT | CRÉER UN COMPTE | SE CONNECTER

Recherche

**REVUES** | **RECHERCHES** | **CRÉER UNE ALERTE CONCERNANT CETTE RECHERCHE**

14 | 2013  
Le pouvoir de l'opinion publique / Micro

**revues.org**

Le portail officiel pour le traitement de l'édition, l'archivage et l'accès de la qualité. Importants en France et en Europe.

**CATALOGUES**

DES REVUES  
DES DOCUMENTS

**RECHERCHER**

**Livres & revues à la Une**

**Actualités**

**Derniers articles**

**Edits**

# Recherche par champs et par filtres

## RECHERCHE

A PROPOS DES ALERTES ET ABONNEMENTS

NOUVELLE ALERTE

NOUVEL ABONNEMENT

CRÉER UN COMPTE

SE CONNECTER

Jétou

Tous les Champs

CHERCHER

RÉINITIALISER

CRÉER UNE ALERTE ASSOCIÉE À CETTE RECHERCHE

31 résultats sur 1 page(s)

1



**Les corpus politiques : objet, méthode et contenu. Introduction**

>> <http://corpus.revues.org/292>

... parus] et [Jétou 2005 : actes sous presse]]. Plus que jamais, la revue Corpus justifie sa place ... : Longman Vergely P. (éd.) (2005). Rôle et place des corpus en linguistique, actes du colloque JÉTOU 2005 ...

### Publication

Corpus

Type de publication : Revues • Type de document : Article

### Auteur

Damon Mayaffre

### Date de publication

décembre 2005

### Disponibilité du document

Texte intégral disponible en accès libre

## FILTRES

Aucun

### Choisir un filtre

PLATEFORME DE PUBLICATION

Revues.org (28)

OpenEdition Books (2)

Calenda (1)

TYPE DE PUBLICATION

Revues (28)

Livres (2)

Événements scientifiques (1)

TYPE DE DOCUMENT

Article (15)

Numéro de revue (12)

Appel à contribution (1)

Chapitre (1)

## Journal de requêtes (1)

### ① Log d'accès initial

- 46 millions de transactions avec le domaine *OpenEdition* du 07 avril 2010 au 1<sup>er</sup> février 2012

### ② Opérations de nettoyage et de filtrage

- Élimination des informations inexploitable ou erronées
- Élimination des informations non pertinentes

### ③ Informations disponibles et exploitables

- Identifiant de l'utilisateur
- Date et heure de soumission de la requête
- Texte de la requête
- Origine de la requête
- Paramétrage éventuel du moteur de recherche par l'utilisateur

### ④ Log de requêtes final

- 1 057 471 requêtes / 227 302 utilisateurs
- Requêtes en français, mais aussi en anglais ou espagnol

## Journal de requêtes (2)

Utilisateur	Date et heure	Requête
130.104.10005	2012/01/25:16:02:41	temps
130.104.10005	2012/02/01:12:08:46	cahiers des sciences humaine
130.104.10005	2012/02/01:12:08:50	cahiers des sciences humaines
130.104.100926	2011/05/11:15:48:15	censure france
130.104.100926	2011/05/11:15:49:30	censure france presse
130.104.100926	2011/05/11:15:53:55	liberté de la presse france
130.104.10105	2011/12/07:00:36:12	absentéisme
130.104.10105	2011/12/07:00:42:34	absentéisme étudiant

## Collection de documents

- Prise en compte uniquement des données de Revues.org
- articles de sciences humaines et sociales
- Corpus de 253 millions de mots (62 204 documents)

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

# Requêtes navigationnelles (1)

## Définition

Requêtes visant à accéder à un document précis ou à une ressource particulière appartenant à la collection *Revue.org*

### ● Références

- Alexandre Lacassagne, *Le médecin devant les cours d'assises*, Paris, s.n., 1883
- M. Tozy et M. Mahdi , « Aspects du droit communautaire dans l'Atlas marocain » , *Droit et Société* , 1990 , p. 219-227 .

### ● Titres

- Produits locaux entre nature et culture : de la ferme voisine au terroir. Entretien avec Laurence Bérard
- « L'Ovide moralisé et la tradition encyclopédique. Une approche générique comparative »

## Requêtes navigationnelles (2)

- **Auteurs**

- corinne mélis
- Gelinier O., Simon F.-X., Billard

- **Noms de revues**

- Bulletin de la Société Préhistorique Française
- ilcea

- **Extraits de documents**

- Pour un débat sur la notion d'ethnie, voir le Fait ethnique en Iran et en Afghanistan, sous la direction de J. P Digard, éd. Du CNRS, 1988
- "Maintenant que le théâtre est accessible sous forme de film, les théâtres vous paraissent-ils inutiles?"

# Requêtes informationnelles

## Définition

Requêtes visant à accéder à une information contenue dans un ou plusieurs documents de la collection *Revue.org*

- **Thématiques générales**
  - herméneutique
  - la femme à l'époque moderne
- **Thématiques spécifiques**
  - la loi n2000-516 du 15 juin 2000 renforçant la protection de la présomption d'innocence et des droits des victimes
  - Quelle citoyenneté pour les travailleurs migrants en République Populaire de Chine?
- **Couplage thème/auteur**
  - chiasme Merleau-Ponty
  - formes élémentaires vie religieuses durkheim

# Requêtes transactionnelles ?

## Définition

Requêtes visant à obtenir une information sous une forme particulière

- harris bibliographie
- biographie de maupassant
- quand les femmes ont pu voté pour la première fois?
- localisation des Araucans ou bien des Mapuches
- définition de la mobilité
- photo des enfants égyptiens allant travailler

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

## Problématique

- Les requêtes soumises par les utilisateurs d'un moteur de recherche comportent en moyenne 2 ou 3 mots-clés
  - Besoin d'information insuffisamment explicite par rapport à la collection de documents [Silverstein *et al.*, 1999]
  - Les requêtes tendent à être trop génériques ou trop spécifiques [Downey *et al.*, 2007]
  - Importance de la reformulation de requêtes
- Les requêtes soumises ne sont pas isolées, mais font partie d'une session de recherche
  - Une session fournit de nombreux indices sur le contexte de la recherche
- Construction d'une collection de référence manuellement annotée au niveau des sessions
  - Évaluation de méthodes de détection automatique des sessions

## Définition des sessions : structure séquentielle

### Définition [Silverstein *et al.*, 1999]

*A session is a series of queries by a single user made within a small range of time. A session is meant to capture a single user's attempt to fill a single information need.*

- Organisation des requêtes successives en séquences
- Caractérisation des sessions par leur longueur
- Notion d'épisode de recherche [Gayo Avello, 2009]

Utilisateur	Temps entre requêtes	Requête	Épisode	Session
158	0	masque	1	1
	339	double		2
	9107	exploitation agricole		3
	443	l'avenir familial de l'exploitation agricole		3

## Définition des sessions : structure imbriquée

### Problématique de la structure séquentielle des sessions

- Adaptée aux enregistrements des journaux de requêtes
- Ne reflète pas la complexité des parcours de recherche

Utilisateur	Temps entre requêtes	Requête	Épisode	Session
39	0	travail saisonnier	1	1
	630	industries de loisirs		2
	26	parc d'attraction		2
	207	fidélisation et emplois saisonniers		1
	387	travail saisonnier		1
	55	parc à thèmes		2
	31	parc astérix		2
	14	disneyland		2
	4	disneyland paris		2
	6	walibi		2
	7	compagnies des alpes		2

## Collections de référence existantes

Auteur	Journal	Requêtes	Utilisateurs	Sessions
(Göker et He, 2000)	Reuters 1999	9 534	1 440	-
(Jansen <i>et al.</i> , 2007)	Dogpile 2005	2 000	-	-
(Jones et Klinkner, 2008)	Yahoo! 2007	8 226	312	2 922
(Gayo Avello, 2009)	Excite 1997 Excite 1999 AlltheWeb 2001 Excite 2001 AltaVista 2002 AOL 2006	95 000	15 000	35 000

## Définitions adoptées

### Épisode de recherche

- Ensemble des requêtes soumises à un moteur de recherche par un utilisateur donné durant au plus une journée
- Un épisode peut contenir une ou plusieurs sessions de recherche

### Session de recherche

- Ensemble des requêtes reliées à un même besoin d'information
- Les requêtes d'une même session peuvent être non séquentielles au sein d'un épisode de recherche

## Consignes d'annotation manuelle des sessions

- Une session correspond à un ensemble de requêtes liées
  - Observation de l'ensemble des requêtes soumises avant d'attribuer une session à chaque requête : barrière de corail / nouvelle zélande / barrière de corail nouvelle zélande
- Des requêtes liées à un même besoin d'information implicite au sein d'une session
  - **Indices textuels** : femmes moralistes / femmes moralistes 18 siècle / moralistes
  - **Indices sémantiques** : foresterie / sylviculture
  - **Proximité thématique** : théâtre expérimental / grotowski
- Utilisation de sources de connaissance externes
- Une session possède un identifiant unique au sein d'un épisode

## Collection constituée pour l'annotation

- Sélection aléatoire de 947 requêtes/216 utilisateurs
- Segmentation automatique en 349 épisodes de recherche

Utilisateur	Requête	Épisode	Session
39	travail saisonnier	1	1
	industries de loisirs		2
	parc d'attraction		2
	fidélisation et emplois saisonniers		1
	travail saisonnier		1
	parc à thèmes		2
	parc astérix		2
	disneyland		2
	disneyland paris		2
	walibi		2
	compagnies des alpes		2

## Comparaison des annotations (1)

- Comparaison basée sur l'identification d'une nouvelle session (NS) ou d'une continuation de la session précédente (CS) par les annotateurs
  - Et non sur les identifiants de session

Utilisateur	Requête	Épisode	Ann. 1	Ann. 3
142	Flandre Wallonie	2	1 NS	1 NS
	BHV		1 CS	2 NS
	conflit périphérie		1 CS	1 NS
	conflit périphérie Bruxelles		1 CS	1 CS
	citoyen définition		<b>2 NS</b>	<b>3 NS</b>
	définition citoyen		2 CS	3 CS

- Pas de prise en compte des cas triviaux
  - Première requête d'un épisode de recherche
  - Un épisode de recherche ne contient qu'une seule requête et constitue donc une seule session

## Comparaison des annotations (2)

		Ann. 2			Ann. 3		
		CS	NS	Total	CS	NS	Total
Ann. 1	CS	<b>490</b>	57	547	<b>514</b>	33	547
	NS	12	<b>39</b>		51	11	
Total		502	96	<b>598</b>	525	73	<b>598</b>

		Ann. 3		
		CS	NS	Total
Ann. 2	CS	<b>482</b>	20	502
	NS	43	<b>53</b>	96
Total		525	73	<b>598</b>

## Comparaison des annotations (3)

- Évaluation du degré de concordance entre chaque paire d'annotateurs

$$\kappa = \frac{P_a - P_e}{1 - P_e}$$

Paired d'annotateurs	$\kappa$
Annotateurs 1 et 2	0,47
Annotateurs 1 et 3	0,61
Annotateurs 2 et 3	0,57

- Sélection pour chaque requête des annotations faisant l'objet d'un accord entre au moins deux annotateurs
- 406 sessions identifiées pour 947 requêtes
- 2,33 requêtes par session en moyenne

## Exemple de désaccord entre les annotateurs

Utilisateur	Requête	Épisode	Session ann. 1	Session ann. 2
7	bank	1	1	1
	bank crisis		1	1
	China party		2	1
	china financial		2	1
	bank		1	1
72	philosophie	1	1	1
	jean lasrière		1	2
	jean ladrière		1	2
	"jean ladrière"		1	2

- Difficulté de choisir le lien pertinent entre les requêtes parmi plusieurs liens possibles
- Difficulté d'exploitation systématique d'une ressource externe pour les liens sémantiques faibles

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

## Détection automatique : méthode temporelle

### Principe [Silverstein *et al.*, 1999 ; He et Göker, 2000]

- Plus la durée entre deux requêtes consécutives est longue, moins il est probable que ces requêtes appartiennent à la même session
- Choix d'un seuil temporel approprié
- Simplicité de mise en œuvre
- Ne détecte pas les sessions très courtes résultant d'un changement soudain du besoin d'information
- Ne détecte pas les sessions très longues comportant des pauses importantes entre chaque requête

## Détection automatique : méthode lexicale

### Principe [He *et al.*, 2002 ; Ozmutlu et Çavdur, 2005]

- Plus les requêtes ont un contenu lexical en commun, plus il est probable que ces requêtes appartiennent à la même session
- Détection des reformulations entre requêtes successives
  
- Combinaison possible avec la méthode temporelle
- Nécessite la présence d'au moins un mot commun entre les requêtes
- Ne détecte pas les requêtes sémantiquement reliées mais ne comportant pas de lien lexical explicite

# Détection automatique : méthodes basées sur des sources de connaissance externes

## Principe

- Exploitation de sources de connaissances externes au journal de requêtes
- Évaluation de la similarité entre les requêtes à partir d'une représentation plus riche de leur contenu
- Divers types de sources de connaissances
  - autre journal de requêtes, documents retournés [Jones et Klinkner, 2008]
  - *Wikipédia* et *Wiktionary* [Lucchese *et al.*, 2011]
  - métadonnées des documents pertinents cliqués [Kramár et Bieliková, 2012]
- Approche présentant les meilleures performances

## Baseline : méthode temporelle

### Implémentation [Jansen *et al.*, 2007]

- Seuil temporel fixant la durée maximale entre deux requêtes successives appartenant à la même session
- Rupture : durée entre les requêtes supérieure au seuil
- Continuité : durée entre les requêtes inférieure au seuil

Utilisateur	Temps entre requêtes	Requête	Épisode	Session
54	0	alexandrie arabe	1	1
	12	alexandrie sources arbaes		2
	5	alexandrie sources arabes	2	
	18	alexandrie cadiz sources arabes	3	
	5	alexandrie cadiz sources	3	

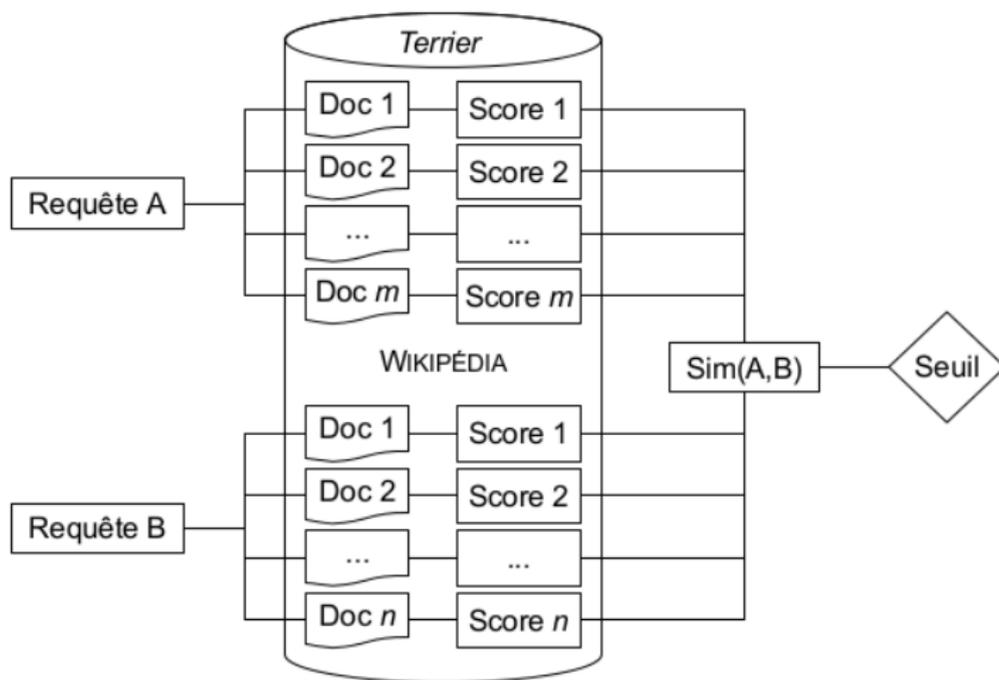
## Baseline : méthode lexicale

### Implémentation [Jansen *et al.*, 2007]

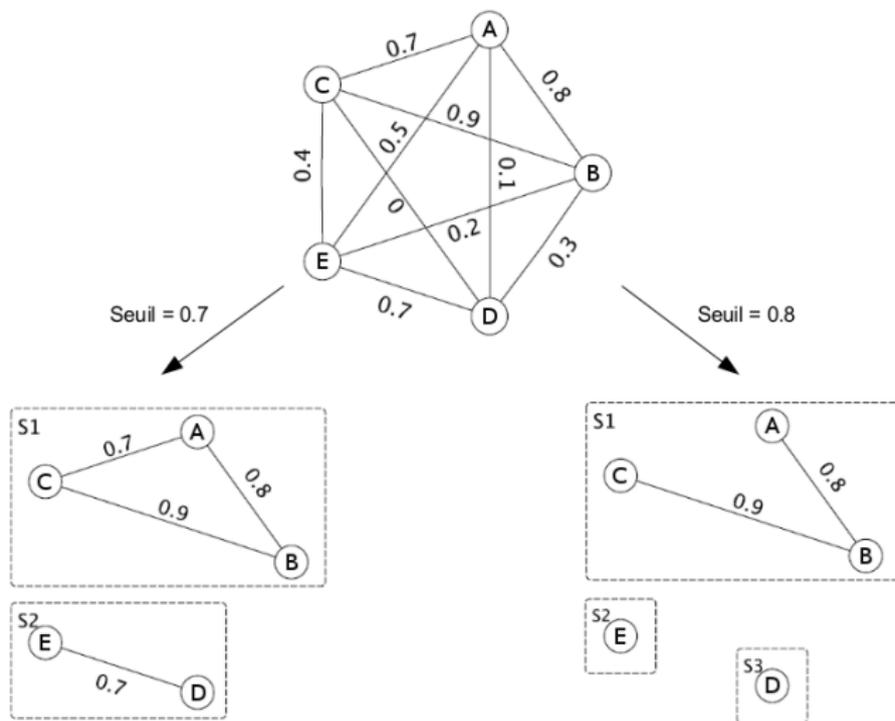
- Calcul du nombre de mots communs et de la différence de longueur entre deux requêtes successives afin de détecter des types de reformulation
- Rupture : aucun type de reformulation détecté
- Continuité : reformulation détectée entre les requêtes

Utilisateur	Temps entre requêtes	Requête	Épisode	Session
54	0	alexandrie arabe	1	1
	12	alexandrie sources arbaes		1
	5	alexandrie sources arabes		1
	18	alexandrie cadiz sources arabes		1
	5	alexandrie cadiz sources		1

## Méthode développée : similarité à l'aide de *Wikipédia* (1)



## Méthode développée : similarité à l'aide de *Wikipédia* (2)



# Évaluation des sessions séquentielles : mesures d'évaluation

## Principe [Gayo Avello, 2009]

- Mesures de précision  $P$ , rappel  $R$  et F-mesure  $F$
- Comparaison entre le nombre de ruptures de sessions détectées par le système et le nombre de ruptures de sessions de la référence

$$P = \frac{N_{RuptureCorrecte}}{N_{RuptureSysteme}} \quad R = \frac{N_{RuptureCorrecte}}{N_{RuptureReference}} \quad F = \frac{2PR}{P + R}$$

- Annotation automatique de la collection de référence en ruptures et continuations de sessions
- Suppression des cas triviaux n'entraînant aucune décision de la part du système
  - Collection de référence réduite à 598 requêtes

## Évaluation des sessions séquentielles : méthode temporelle

Précision	0,31
Rappel	0,31
F-mesure	0,31

		Rupt.	Cont.	
Réf.	Rupt.	22	48	70
	Cont.	49	479	528
		71	527	598

- Seuil temporel variant de 10 à 5 120 secondes
- Meilleure performance pour un seuil de 640 secondes
- Efficacité de 84 %

Util.	Requête	Réf.	Syst.
18	loup	1	1
	Le monde agricole confronté au loup	1	2
32	Après la catastrophe	1	1
	Recherches sociologiques et anthropologiques	2	1

## Évaluation des sessions séquentielles : méthode lexicale

Précision	0,24
Rappel	1
F-mesure	0,38

		Rupt.	Cont.	
Réf.	Rupt.	70	0	70
	Cont.	225	303	528
		295	303	598

- Efficacité de 62 %
- Aucun faux négatif

Util.	Requête	Réf.	Syst.
35	éclaircissants	1	1
	peau claire	1	2
	tshoko	1	3
	maquillage afrique	1	4
	dépigmentation	1	5

## Évaluation des sessions séquentielles : méthode *Wikipédia*

Précision	0,31		Rupt.	Cont.		
Rappel	0,8	Réf.	Rupt.	56	14	70
F-mesure	0,45		Cont.	124	404	528
				180	418	598

- Seuil de similarité variant de  $1 \cdot 10^{-5}$  à  $5 \cdot 10^{-1}$
- Meilleure performance pour un seuil de  $5 \cdot 10^{-3}$
- Efficacité de 77 %

Util.	Requête	Réf.	Syst.
71	philippe dasseto	1	1
	dasseto	1	2
	Dasseto	1	3
106	divorce	1	1
	adoption	2	1

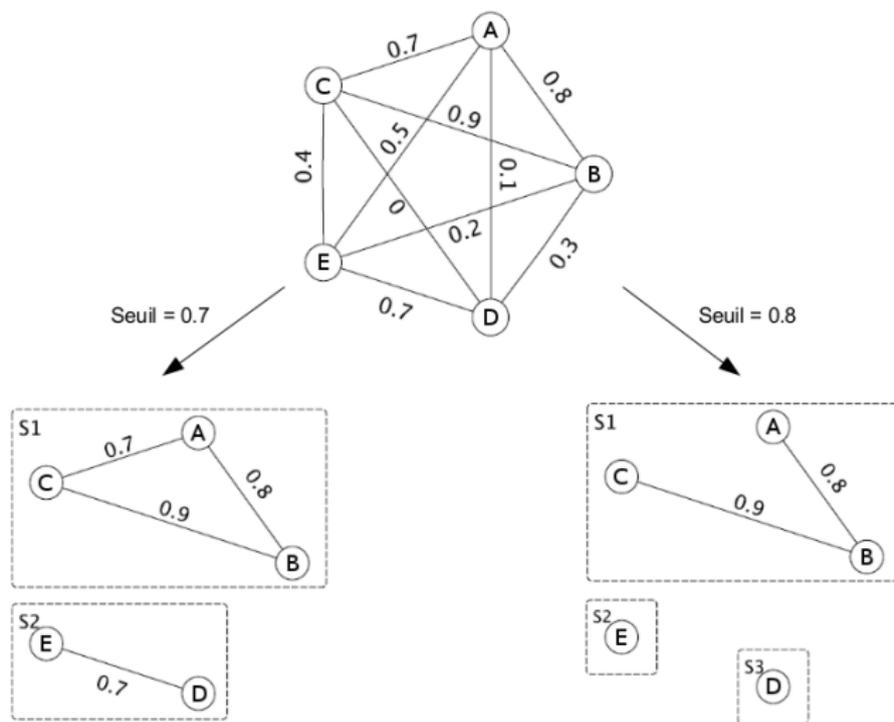
## Évaluation des sessions imbriquées : mesures d'évaluation

### Principe [Lucchese *et al.*, 2011]

- Index de Rand  $R$  [Rand, 1971]
- Index de Jaccard  $J$  [Jaccard, 1901]
- Vérification de la cohérence de répartition des paires de requêtes entre les sessions détectées par le système et les sessions de référence
- $f_{ij}$  paire de requêtes apparaissant dans une session système identique ( $i = 0$ ) ou différente ( $i = 1$ ) et dans une session de référence identique ( $j = 0$ ) ou différente ( $j = 1$ )

$$R = \frac{f_{00} + f_{11}}{f_{00} + f_{01} + f_{10} + f_{11}} \quad J = \frac{f_{11}}{f_{01} + f_{10} + f_{11}}$$

## Évaluation des sessions imbriquées : illustration



## Évaluation des sessions imbriquées : méthode de similarité

Seuil	Rand	Jaccard
$1 \cdot 10^{-5}$	0,786	0,726
$5 \cdot 10^{-5}$	0,786	0,726
$1 \cdot 10^{-4}$	0,786	0,726
$5 \cdot 10^{-4}$	0,788	0,728
$1 \cdot 10^{-3}$	0,786	0,722
$5 \cdot 10^{-3}$	0,758	0,668
$1 \cdot 10^{-2}$	0,728	0,626

- Meilleur résultat pour un seuil de similarité de  $5 \cdot 10^{-4}$ 
  - Liste des résultats obtenus pour chaque requête sensible aux types de reformulation
  - Seuil optimal pour la détection des sessions dépendant de notre jeu de données

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

## Les données de départ

### Données brutes

- Métadonnées des articles de Revues.org récupérées sur le serveur OAI-PMH (au 24/01/2013)
  - auteur(s), date de publication, date de mise en ligne/modification, titre, langue, url
  - Articles correspondants au format HTML moissonnés sur les serveurs

### Filtrage

- Identification de la langue avec *Textcat Language Guesser* → 85 % d'articles en français
- Identification des articles en texte intégral → 82 % des documents

## Le corpus de travail

Corpus constitué de documents divers (des articles de revues, mais aussi des compte-rendus de lecture, des entretiens, des annonces d'événements scientifiques...) en texte intégral et en français :

Nombre de mots	253 millions
Nombre d'articles	62 204
Nombre de revues	279

TABLE : Caractéristiques du corpus mobilisé

# Traitements

Les traitements effectués :

- Normalisation du HTML
- Repérage et analyse des références bibliographique avec Bilbo (<http://bilbo.hypotheses.org/>)
- Analyse syntaxique avec Talismane
- Analyse distributionnelle

# Analyse distributionnelle du corpus

## Principe de l'analyse distributionnelle

Mesure de la similarité sémantique entre les mots/termes du corpus en fonction des contextes syntaxiques qu'ils partagent

## Exemple : les voisins de *linguistique*

voisin	contextes partagés
sémiotique	génératif, structural, comparé, textuel
philologie	roman, sémitique, comparé, historique
sémantique	génératif, structural, cognitif, formel
vs dans Wikipédia :	
grammaire	génératif, comparé, formel, historique
anthropologie	s'intéresser_suj, étudier_suj, discipline_de
géologie	professeur_de, utiliser_en, enseigner_obj

## Analyse distributionnelle du corpus

Les voisins de Revues.org sont exploitables pour :

- analyser les requêtes (typage des reformulations)

## Analyse distributionnelle du corpus

- Les voisins de Revues.org sont exploitables pour :
- analyser les requêtes (typage des reformulations)

### Croisement des voisins de Revues.org avec les substitutions de mots dans les reformulations de requêtes

relations entre espace pouvoir et **société**  
relations entre espace pouvoir et **identité**

**performance** système d'information  
**évaluer** système d'information

musique et **apprentissage**  
musique et **mémorisation**  
**rythmique** et **mémorisation**

→ environ 50 % des paires de mots impliquées dans des substitutions  
sont des voisins

## Analyse distributionnelle du corpus

- Les voisins de Revues.org sont exploitables pour :
- analyser les requêtes (typage des reformulations)
  - mesurer certaines caractéristiques des documents

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

## Caractérisation des documents

Calcul d'un ensemble de caractéristiques :

- Pour chaque document du corpus
- Pour chaque paire <requête,document renvoyé>

## Caractérisation des documents

### Caractéristiques des documents :

- Caractéristiques structurelles de base : longueur du texte, présence et quantité de certains éléments (résumé, tableaux, figures, références bibliographiques, notes), nombre et niveaux des titres de section, etc.
- Complexité syntaxique (sur la base de l'analyse de TALISMANE) : profondeur de l'arbre, distance moyenne des dépendances syntaxiques

Exemple :

- Forte complexité : <http://1895.revues.org/1632>
- Faible complexité : <http://cem.revues.org/11450>

## **Revue du livre : Mary Ann Doane, *The Emergence of Cinematic Time : Modernity, Contingency, the Archive* (1895)**

S'inscrivant, d'un point de vue méthodologique, dans la perspective d'une archéologie foucauldienne des savoirs (ici sur le temps et sa représentation), ce livre construit une partie de ce que l'on pourrait appeler une « épistémologie du cinéma » déjà balisée par les études de Friedrich Kittler (1986) ou Jonathan Crary (1990 et 1999) – citées à plusieurs reprises par Doane –, mais aussi par des ouvrages collectifs comme ceux édités par Leo Charney et Vanessa R. Schwartz (1995) ou plus récemment par François Albera, Marta Braun et André Gaudreault (2002). Tous ces travaux manifestent, à des degrés divers, une volonté de mettre à jour l'*épistémé* qui voit l'émergence du cinématographe, c'est-à-dire à déchiffrer la grille symbolique à travers laquelle cette période appréhende divers savoirs, discours et pratiques, et, plus précisément, à rendre compte du rôle joué par le cinéma à l'intérieur des mutations épistémiques engendrées par la modernité.

## **AVALLON - Église collégiale Saint-Lazare (Bulletin du centre d'études médiévales)**

### **Le site**

La tradition mentionne la fondation d'une collégiale au IX<sup>e</sup> siècle. L'église actuelle a été reconstruite au XII<sup>e</sup> siècle. Au XIX<sup>e</sup> siècle fut découverte, sous le chevet et antérieur à celui-ci, une petite crypte. Transformée plus tard en espace technique pour le calorifère, elle attend aujourd'hui une restauration.

### **La fouille**

Les recherches se sont concentrées sur l'analyse du bâti et des enduits de la crypte. Les relevés et les observations ont souligné des problèmes d'accès et de datation du site. Elles ont révélé au moins trois états successifs de construction antérieurs à l'édifice actuel (XII<sup>e</sup> siècle).

## Caractérisation des documents

### Caractéristiques des paires <requête,document>

- fréquence et couverture des mots de la requête dans le document
- présence des mots de la requête dans des éléments spécifiques : titre du document, auteur, résumé, titres de section...
- caractéristiques des chaînes lexicales construites à partir des mots de la requête en utilisant les Voisins de Revues.org : densité, couverture

Exemple : `assr_23491.html`

- caractéristiques des snippets générés pour chaque paire <requête,document> : structure (nombre de « morceaux »), fréquence des mots de la requête, cohésion lexicale...

Exemple :

`http://search.openedition.org/?q=caricature+religion`



**Jean-Claude Gardes, Guillaume Doizy (textes réunis par), Ridiculous 15, Caricature et Religion(s)**

Brest, Université de Bretagne occidentale, décembre 2008, 574 p.

>> <http://assr.revues.org/23491>

... à caricaturer la religion, les mots « détournement », « déplacement », « métonymie », « décalage ... de religions, les caricatures du pape et de la papauté y ajoutaient un piment de vulgarité scatologique devenue ... ) de l'université de Bretagne occidentale, rend compte d'une série de manifestations intitulées « Caricature ...

**Publication**

Archives de sciences sociales des religions

Type de publication : Revues • Type de document : Compte-rendu

**Auteur**

Jean-Louis Schlegel

**Date de publication**

décembre 2011

**Disponibilité du document**

Texte intégral disponible en accès restreint sur Cairn



## Grands Hommes vus d'en bas

L'iconographie officielle et ses usages populaires

>> <http://gradhiva.revues.org/1632>

... » (Duprat 2002 : 10). Ces caricatures inversent l'esthétique officielle de la grandeur en peignant ... à la caricature politique contemporaine, comme en témoigne l'émission télévisée du Bébête Show (Collovald 1992 ... par la caricature, qui pousse à l'excès cette fétichisation grotesque pour en dévoiler la vacuité (Mbembe 1996 ... de la panthéonisation, cf. Ben-Amos 1990. 5 Sur la caricature du Bébête Show et des Guignols de l'info, cf. également ... ou demi-dieu ? La mise en place d'une religion napoléonienne », Romantisme 28(100) : 131-141. Bourdieu ... -Pascal 1996 « Les ambivalences dans la caricature des dirigeants politiques. Illustrations africaines ... de papier : la caricature de Henri III à Louis XVI. Paris, Belin. Durkheim, Émile 1975 (1883) « Le rôle ...

### Publication

Gradhiva

Type de publication : Revues • Type de document : Editorial

### Auteurs

Julien Bonhomme, Nicolas Jaoul

### Date de publication

mai 2010

### Disponibilité du document

Texte intégral disponible en accès restreint sur Cairn

# Plan

- 1 De nouveaux enjeux en recherche d'information
  - La recherche d'information : remise en contexte
  - Un cadre d'étude : le projet ANR CAAS
  - Des données : le portail *OpenEdition*
- 2 Contexte des requêtes soumises au moteur *OpenEdition*
  - Typage *a priori* des requêtes
  - Construction d'une collection de référence
  - Détection automatique des sessions de recherche
- 3 Travail sur les documents
  - Le corpus et les traitements
  - Caractérisation des documents
  - Analyse croisée : parcours de recherche et documents consultés
- 4 Conclusion et perspectives

## Quels éléments des logs peut-on croiser avec les caractéristiques des documents ?

Liens entre les caractéristiques du document et :

- sa « popularité » globale : le nombre de clics sur celui-ci dans l'ensemble des logs
- pour une requête donnée :
  - le fait qu'il ait été consulté ou non (document cliqué vs collection de documents renvoyés par le moteur de recherche)
  - le temps de consultation

Vers un point de vue plus global... :

- Typologie des requêtes selon leurs interactions avec les documents renvoyés par le moteur de recherche
- Typologie des documents selon l'ensemble des requêtes par lesquelles ils sont abordés

# Popularité et caractéristiques des documents

## Méthode

- Pour chaque document, recherche de l'ensemble des accès dans les logs disponibles (en évitant les doublons d'utilisateur+requête)
- Croisement avec l'ensemble des caractéristiques de documents et recherche de corrélations

## Résultats

Les documents plus souvent cliqués :

- sont plus longs (effet du moteur de recherche)
- sont plus structurés (plus de titres et plus de niveaux de titres)
- ont plus tendance à contenir des références bibliographiques

# Temps passé et caractéristiques des documents

## Méthode

- Extraction de toutes les séquences requête - accès à un document - requête (pour un même utilisateur)
  - La différence entre l'heure de la seconde requête et l'heure d'accès au document donne la durée de consultation
- Croisement avec l'ensemble des caractéristiques (du document, de la paire document-requête) et recherche de corrélations

# Temps passé et caractéristiques des documents

## Résultats

- Le temps passé sur un document est légèrement corrélé avec sa longueur.
- Mais pas avec :
  - la fréquence / couverture des mots de la requête dans le document
  - la cohésion lexicale avec les mots de la requête dans le document
  - la complexité syntaxique du document

## Choix d'un document suite à une requête

### Méthode

- Pour chaque requête ayant donné lieu à au moins un clic, prise en compte de tous les documents affichés par le moteur de recherche sur la même page que le(s) document(s) cliqué(s)
- Recherche de corrélations entre les caractéristiques des documents et leur choix au sein de la collection de documents renvoyés

### Résultats

- Résultats triviaux : corrélation avec la fréquence des termes de la requête dans le snippet/document, la couverture...
- Pas d'apport des indices plus fins : par exemple de la cohésion lexicale de la requête avec le document ou avec le snippet

## Vers une typologie du lien requête-document

- Approche plus qualitative
  - Pour un document, extraction de l'ensemble des requêtes qui y ont abouti dans les parcours de recherche
  - Visualisation des requêtes dans le document
  - Typologie des requêtes en fonction de leurs liens avec les documents qu'elles renvoient
  - Typologie des documents en fonction des points de vue à travers lesquels ils sont abordés

# Une typologie des requêtes en lien avec les documents qu'elles visent

Exemples :

- La présentation de soi. Ethos et identité verbale
- Colloque « Le muet a la parole »

## Partie du document ciblée

- élément unique / zone restreinte du document
- ensemble du document
- élément particulier (saillant) : titre, auteur

## Exemples

### Requêtes titre ou auteur

Jean-Paul Fourmentraux

monique selim

gunthert

alain rabatel

yves defrance

a) Pierre DELEAGE, 2010. « Mythe et chant rituel chez les Sharanahua »

Les jeunes sur Internet. Se construire un autre  
chez-soi

## Exemples

### Requêtes ciblant l'ensemble des documents

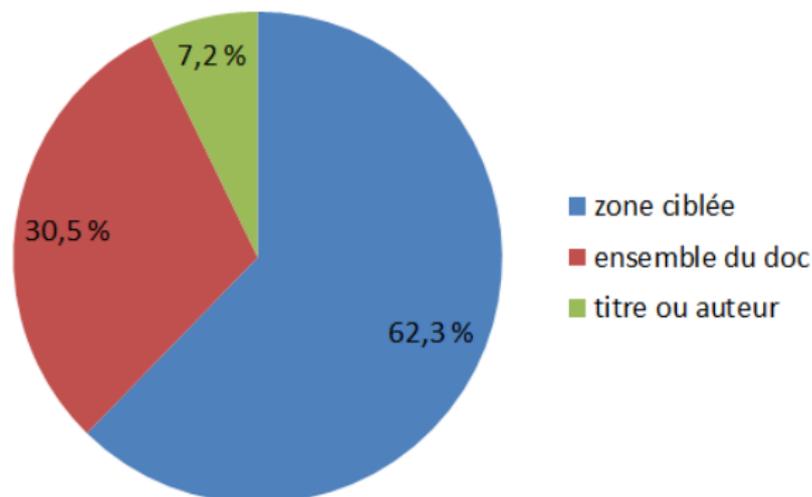
articles influence sociale processus de changement et enjeux de pouvoir au travail ; formation professionnelle ; tourisme solidaire ; projet urbain ; communication interne en entreprise ; les femmes immigrantes ; travail et emploi des femmes ; formation continue ; politique culturelle ; engagement parents apprentissage enfants ;

### Requête ciblant une zone restreinte des documents

diphonie ; OGM ; intertextualité polyphonie ; amish ; la démocratie participative ; ostéopathie ; nudisme ; téléspectateur ; sans-abris ; médecine tibétaine ; Heteronormativité ; kerbrat ; l'amour ; GERARD MENDEL ;

## Typologie des requêtes

Représentation des différents types de requêtes



# Une typologie des documents selon la façon dont ils sont abordés par les requêtes

- Pour chaque document, analyse de l'ensemble des requêtes ayant conduit un utilisateur à y accéder
- Différents profils de documents selon la façon dont ils sont abordés par les requêtes :
  - Proportions de requêtes titre/auteur, portant sur l'ensemble du document ou ciblées  
Exemples :
    - Un document abordé presque uniquement par l'anecdote :  
Une cuiller à pot pour demander la pluie
    - Un document toujours entièrement balayé par les requêtes :  
Les risques du journalisme dans les conflits armés
  - Homogénéité des ensembles de requêtes liées aux documents

## Homogénéité des ensembles de requêtes : exemples

**Article** : « Le vécu de l'accident nucléaire de Fukushima, Japon : les paroles des enfants » (Akiko IDA)

**Requêtes** : FUKUSHIMA ; accident nucléaire 2011 ; articles de presse accident nucleaire japon ; japon nucleaire ; japon ; Accident nucléaire Japon ; accident nucléaire fukushima 2011 ; Fukushima ; accident nucléaire au Japon ; fukushima daiichi ; fukushima ; centrale nucleaire de fukushima

**Article** : Stylistique des fantômes (Philippe-Alain Michaud)

**Requêtes** : gladiator ; stylistique ; feu d'artifice ; Philippe-Alain Michaud ; platon

→ Calculer un score d'homogénéité (comment est mesurée la similarité entre deux requêtes : distance d'édition ? similarité sémantique ?)

## Conclusion et perspectives

### Des données riches et pléthoriques

- beaucoup d'énergie consacrée à l'acquisition, au nettoyage, au tri, au recouplement des données...
- de nombreux types d'informations à croiser :
  - sur les requêtes : caractéristiques des requêtes, inscription dans une session de recherche, types de reformulations...
  - caractéristiques des documents, informations tirées du corpus, interactions document-requête...
  - comportement de l'utilisateur à travers différents indicateurs : clics, informations temporelles...

## Conclusion et perspectives

### Création/extraction de nouvelles données

- une base distributionnelle : les Voisins de Revues.org
- une collection de référence comprenant des épisodes de recherche annotés en sessions de recherche
- extraction de données : par exemple, listes de paires de requêtes présentant des liens sémantiques

# Conclusion et perspectives

## Quelques résultats

- Méthodes de détection de sessions de recherche
- Analyse des mouvements sémantiques dans les reformulations de requête
- Quelques corrélations entre accès aux documents et caractéristiques

**MAIS** des indicateurs du comportement / de la satisfaction de l'utilisateur assez frustes, un corpus très hétérogène...

→ difficultés à faire émerger des résultats qui valorisent l'approche linguistique / TAL

# Conclusion et perspectives

## Perspectives

- Avancer dans la typologie (des requêtes, des reformulations, des documents...) :
  - Faire une typologie *a posteriori* des requêtes, exploitant des informations contextuelles issues des sessions (position de la requête dans la session, consultation d'un document, etc.)
- Vers des études :
  - plus qualitatives ?
  - plus circonscrites / contrôlées
    - se limiter à un type de requête ? → étude des requêtes auteur