



Introduction à la recherche d'information

Mohand Boughanem

bougha@irit.fr

<http://www.irit.fr/~Mohand.Boughanem>

Université Paul Sabatier de Toulouse

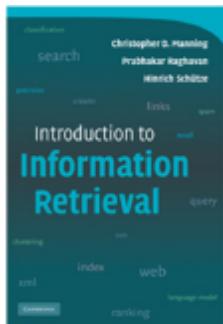
Laboratoire IRIT , UMR5055

Plan

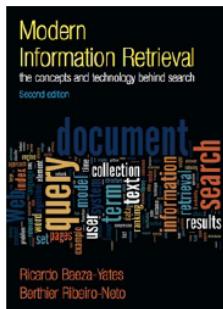
- Fondements de la Recherche d' information (RI)
 - Introduction : définition, contours de la RI
 - Problématique de la RI
 - Tour d'horizon sur les techniques de RI
- Panorama RI – scénarios et applications
 - Thématisques de recherche en RI
- Conclusion

- Recherche d'information (RI) :
 - Ensemble des méthodes et techniques pour l'acquisition, l'organisation, le stockage, la recherche et la **sélection d'information pertinente pour un utilisateur**





IR is finding material (usually documents) of an unstructured nature (usually text) that satisfies an information need from within large collections (usually stored on computers).



Information retrieval deals with the representation, storage, organization of, and access to information items such as documents, Web pages, online catalogs, structured and semi-structured records, multimedia objects. The representation and organization of the information items should be such as to provide the users with easy access to information of their interest.



IR: The techniques of storing and recovering and often disseminating recorded data especially through the use of a computerized system.



- Information retrieval (IR)
 - is the science of **searching for documents, for information within documents**, and for metadata about documents, as well as that of searching relational databases and the World Wide Web.
- IR is interdisciplinary,
 - **based on computer science, mathematics, library science, information science, information architecture, cognitive psychology, linguistics, statistics, and physics.**
 - are used to reduce what has been called "information overload".
 - Many universities and public libraries use IR systems to provide access to books, journals and other documents. **Web search engines are the most visible IR applications.**

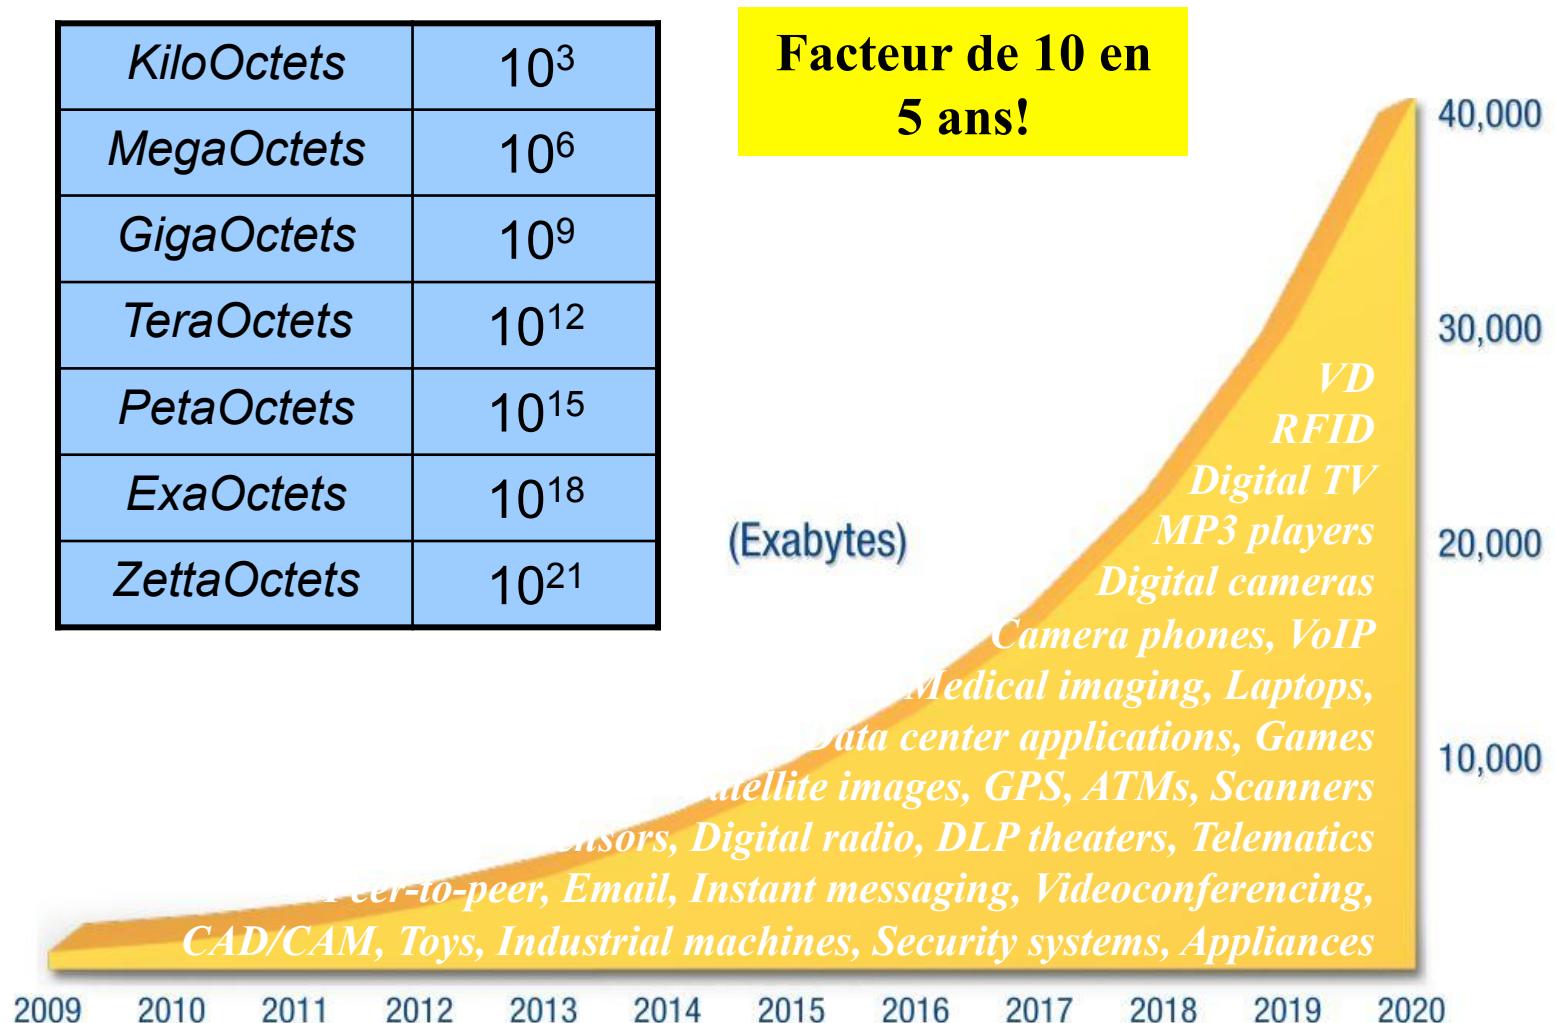


- Plusieurs domaines d'application
 - Internet (Web, Forum/Blog search, news)
 - Entreprises (entreprise search)
 - Bibliothèques numériques «digital library»
 - Domaine spécialisé (médecine, droit, littérature, chimie, mathématique, brevets, software, ...)
 - Nos propres PC (Yahoo! Desktop search)

Information est partout

<i>KiloOctets</i>	10^3
<i>MegaOctets</i>	10^6
<i>GigaOctets</i>	10^9
<i>TeraOctets</i>	10^{12}
<i>PetaOctets</i>	10^{15}
<i>ExaOctets</i>	10^{18}
<i>ZettaOctets</i>	10^{21}

Gros volumes d'information



Source: IDC's Digital Universe Study, sponsored by EMC, December 2012

Information est partout

Origine

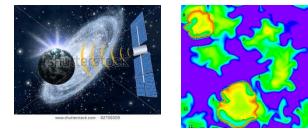
Enterprise Apps



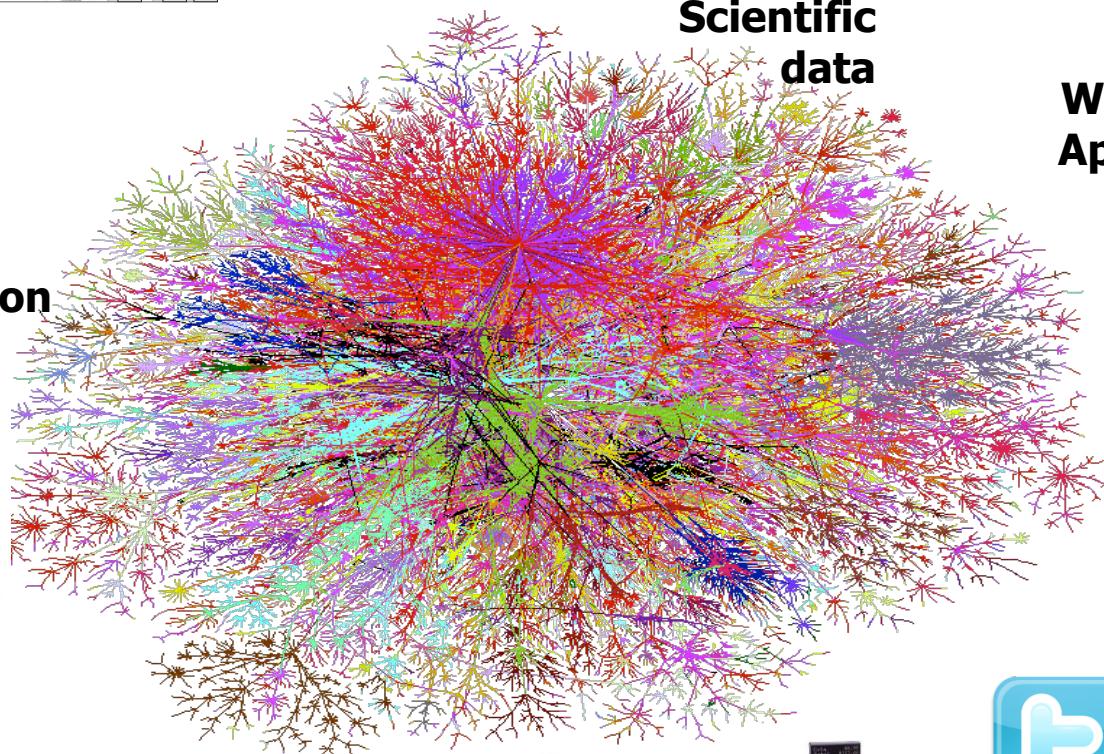
Device explosion



Machine Data



Scientific data



Web Apps



Social Media Data



.. L'information (numérique) est
disponible partout

- Average Number of Tweets Sent Per Day:
500 million
 - 2 billions queries per day on twitter
- Every minute 510,000 posted comments
FaceBook
- 45 milliards (Google), 25 milliards (Bing)
- 672 Exabytes - 672,000,000,000
Gigabytes (GB) of accessible data.



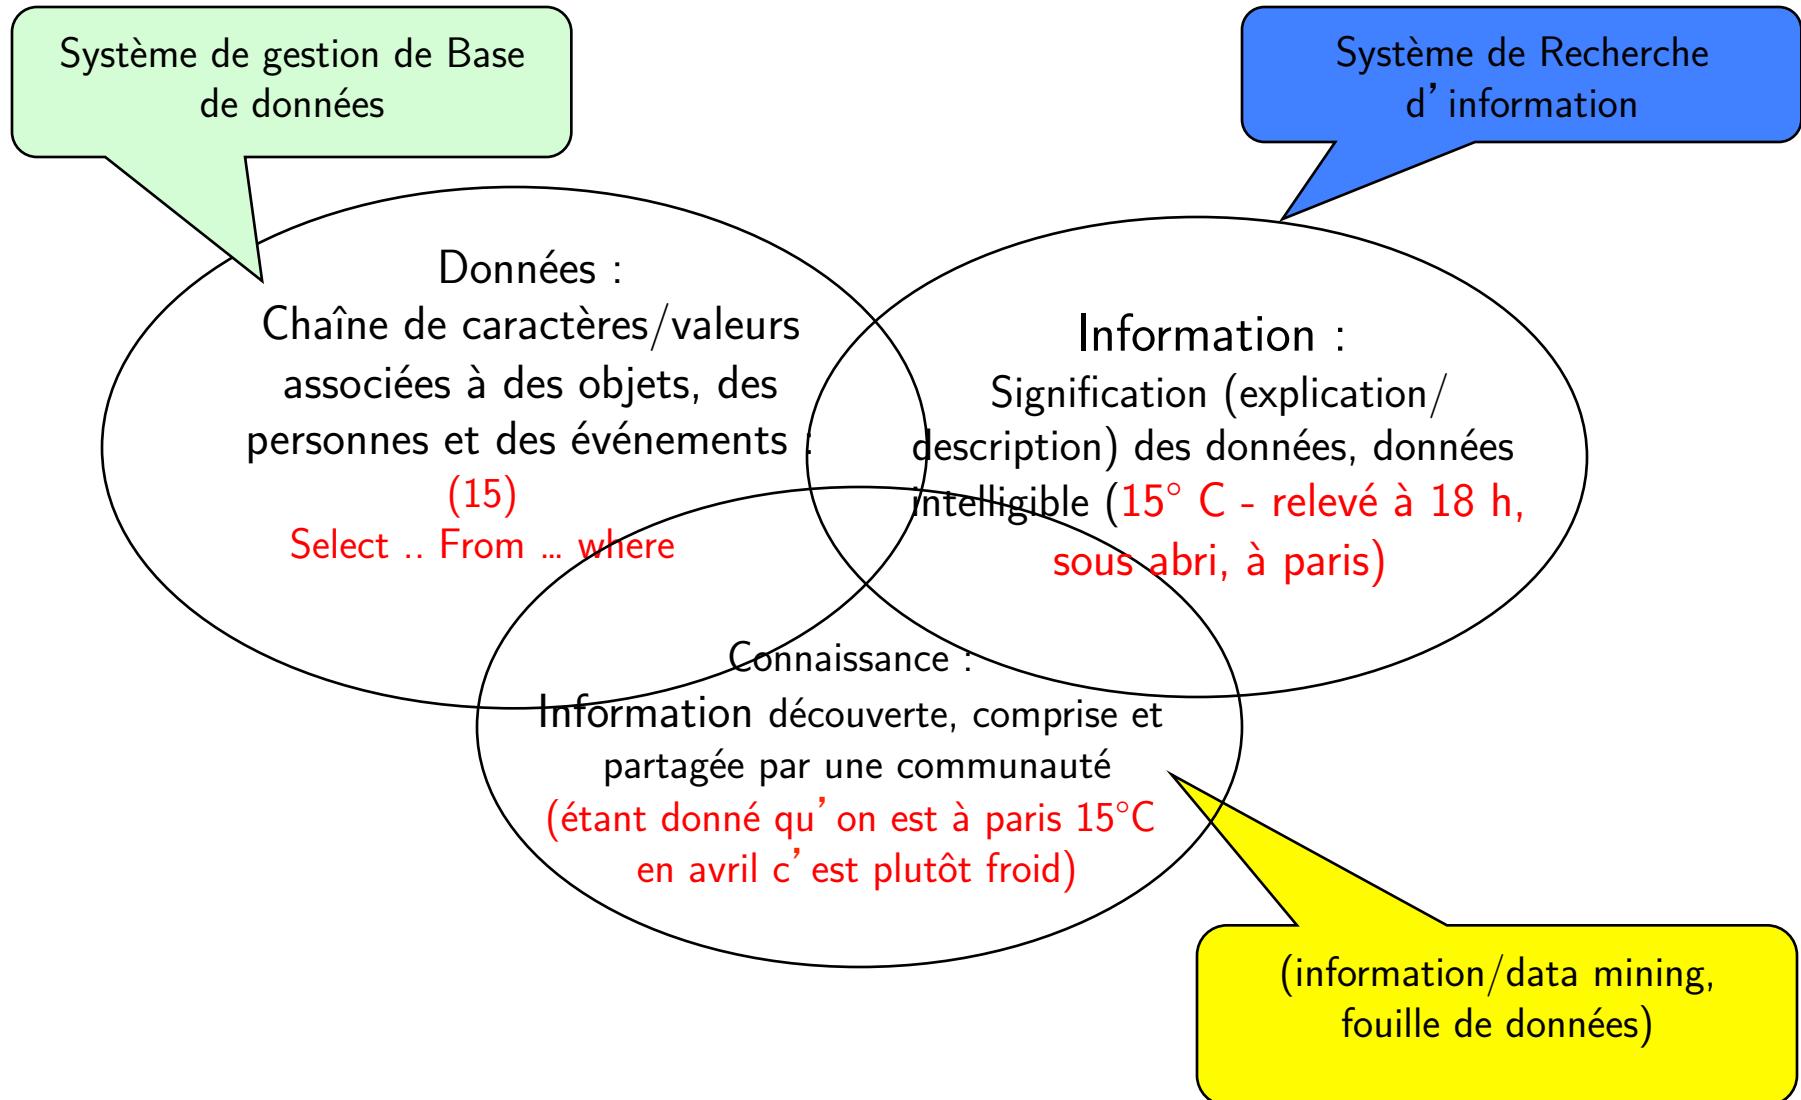
- n'est pas tant la disponibilité de l'information
- MAIS
- sa sélection, son identification → **arriver à trouver au bon moment l'information utile**



- Rechercher une information a un coût
 - « On» passe (en moyenne) 35% de son temps à rechercher des informations
 - Les managers y consacrent 17% de leur temps
 - Les 1000 grandes entreprises (US) perdent jusqu'à \$2.5 milliards par an en raison de leur incapacité à récupérer les bonnes informations
- Nécessité de développer des systèmes automatisés efficaces permettant
 - Collecter, Organiser, Rechercher, Sélectionner

- Contenu : donnée-information-connaissance
 - Tâches : adhoc; filtrage, classification, question réponse





• Recherche adhoc

- Je cherche des infos (pages web) sur un sujet donné
 - Je soumets une requête → retour liste de résultats
 - Requête «recherche d'info» → SRI → renvoie une liste de documents traitant de la » recherche d'information »
- Plusieurs types de RI adhoc
 - Recherche adhoc (tâches spécifiques)
 - Domaine spécifique (médical, légal, chimie, ...)
 - Recherche d'opinions(Opinion retrieval) (sentiment analysis)
 - Recherche d'événements
 - Recherche de personnes (expert)

- Classification / Catégorisation
 - Regrouper les informations (documents) selon un ou plusieurs critères
- Question-réponses (*Query answering*)
 - Chercher des réponses à des questions
 - par exemple
 - « Qui est averroes ? »
 - « Quelle la hauteur du Mont Blanc ? »



averroes



Input interpretation:

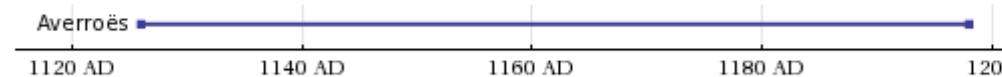
Mathematica form

Averroës (philosopher)

Basic information:

full name	Abu al-Walid Muhammad
date of birth	1126 AD (884 years ago)
place of birth	Cordoba, Spain
date of death	1198 AD (age: 72 years) (812 years ago)
place of death	Marrakech, Marrakech-Tensift-Al Haouz, Morocco

Timeline:



Computed by: Wolfram Mathematica

Source information »

Download as: PDF | Live Mathematica



Now Available



Wolfram|Alpha
App for the iPhone
& iPod touch
Computation at
your fingertips

New to Wolfram|Alpha?

A few things to try:

- enter any date (e.g. a birth date)
june 23, 1988
- enter any city (e.g. a home town)
new york
- enter any two stocks
IBM Apple
- enter any calculation
\$250 + 15%
- enter any math formula
 $x^2 \sin(x)$
- more »

- Filtrage d'information/ recommandation (filtering/recommendation)
 - Recommandation
 - Dissémination sélective d' information
 - Système d' alerte
 - Dissémination sélective d' information
 - Push
 - Profilage (profiling)

- Résumé automatique (document summarization)
- Recherche agrégée (Aggregated search)
 - Agréger des moteurs : interroger les résultats de plusieurs moteurs (méta-moteurs)
 - Agréger des résultats : interroger plusieurs sources (vertical search)
 - Agréger des contenus : former un résultat à partir de plusieurs contenus

Vertical search

[Page D'accueil](#)

[Le Cop](#)

[Musée](#)

[Rugbyrama](#)
[Stade Toulouse Transferts](#)
[Stade Français](#)

[**Stade Toulousain - Page d'accueil**](#) [Translate this page](#)

www.stadetoulousain.fr/index2.php

Saracens / Stade Toulousain - Interview de Maxime MÉDARD Election du stadiste de la saison. Le Stade dans les Médias . Suivre ...

[**Videos of stade Toulousain**](#)

bing.com/videos



Compilation des
essais du Stade ...
YouTube

Stade Toulousain -
RC Toulon [Final...
YouTube

Stade Toulousain -
Montpellier [Final...
YouTube

stade toulousain
compilation
YouTube

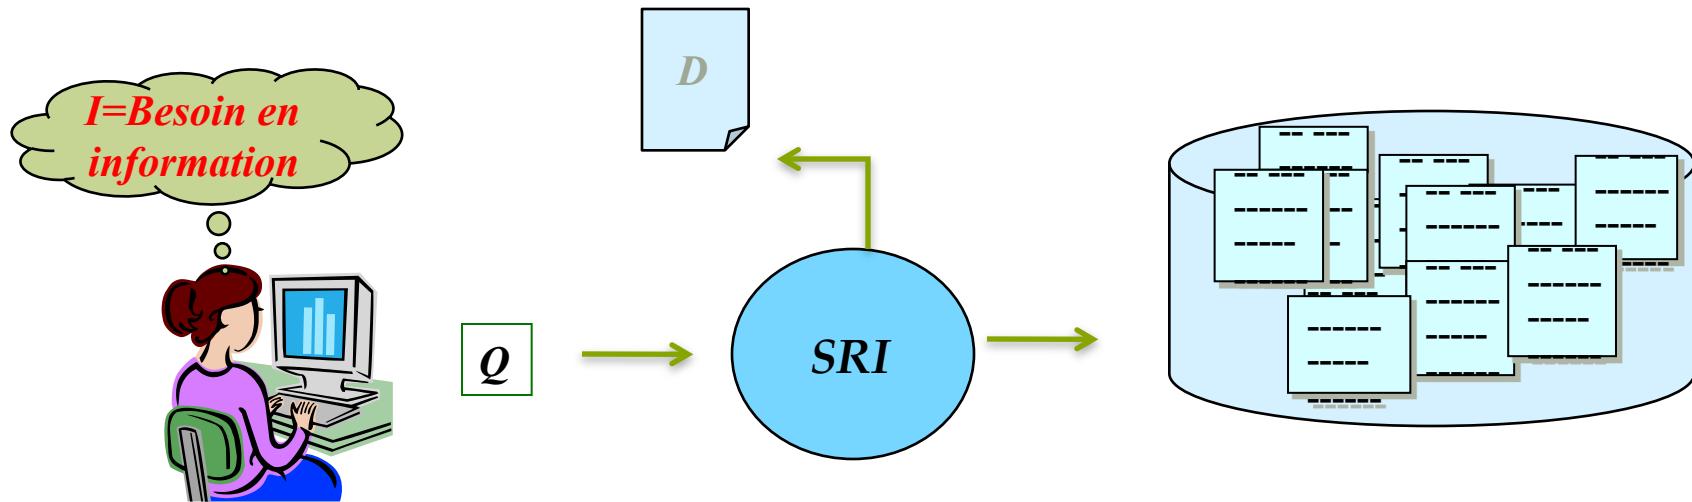
[**Stade toulousain - Wikipédia**](#) [Translate this page](#)

fr.wikipedia.org/wiki/Stade_toulousain

Histoire · Palmarès · Les finales du Stade ... · Personnalités ...

Stade toulousain Généralités Fondation 1907 Statut professionnel depuis le 1 er février 1998 Couleurs rouge et noir Stade Stade Ernest-Wallon (19 500 places ...

- Introduction
- Chapitre 1 : Concepts de base de la RI
- Chapitre 2: Langage de requêtes
- Chapitre 3 : Indexation et pondération
- Chapitres 4 : Modèles de RI
- Chapitre : Evaluation de RI
- Chapitre 5: RI sur le WEB
- Chapitre : XML et RI
- Chapitre : Techniques de reformulation



- Sélectionner dans une collection
 - les informations (items, documents, ...)
 - ... pertinentes répondant aux
 - ... besoins en information des utilisateurs

• Formes

- Texte, images, sons, vidéo, graphiques, etc.
 - Exemples texte : web pages, email, livres, journaux, publications, blog, Word™, Powerpoint™, PDF, forum postings, brevets, etc.

• Hétérogénéité

- langage (multilingues)
 - media (multimédia)



Question

- Comprendre le contenu vs. l'interpréter → Ambiguité du langage naturel (polysémie, synonymie, ...)
 - Information, document, unité/granule/passage



- Besoin en information est une expression mentale d'un utilisateur
- Requête
 - Ensemble de mots-clés
 - → Une représentation possible du besoin en information



Requête



Question

- Comment capturer le besoin de l'utilisateur

What's in a query?

apple



- Au cœur de tout système de RI
 - Relation entre le document et ... la requête ou le besoin de l'utilisateur ?
- Plusieurs facteurs influencent la décision de l'utilisateur, tâche, le contexte, nouveauté, style, compréhension, temps, ...
- Pertinence par document

Goffman, 1969: ‘...the relevance of the information from one document depends upon what is already known about the subject, and in turn affects the relevance of other documents subsequently examined.’

Type of relevance(survey) (Saracevic 2007)

- Plusieurs pertinences

- Thématique (topical): relation entre le sujet exprimé dans la requête et le sujet couvert dans le document.
- Contextuelle (Situation) : relation entre la tâche, le problème posé par l'utilisateur, la situation de l'utilisateur et l'information retrouvée.
- Cognitive : relation entre l'état de la connaissance de l'utilisateur et l'information sélectionnée



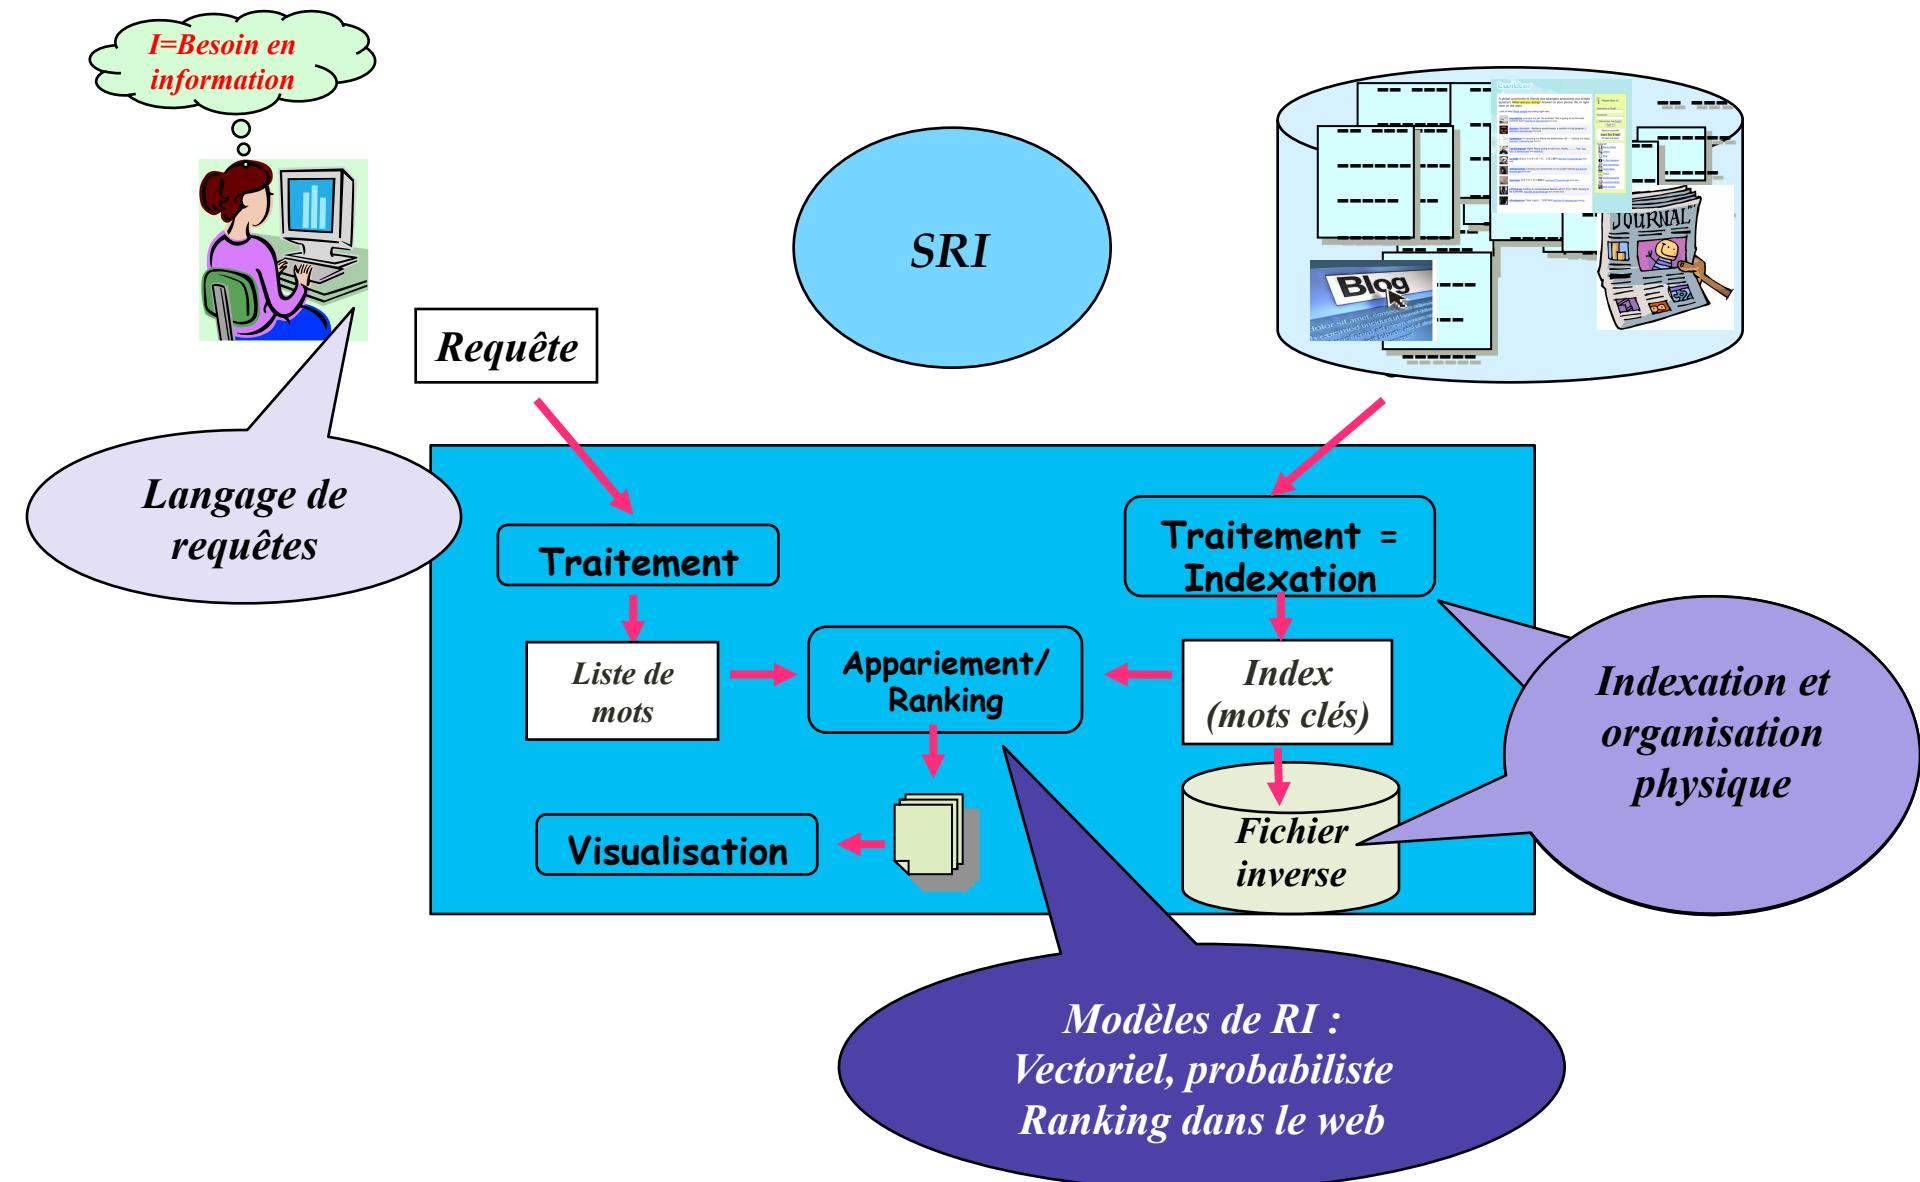
Question

- Processus subjectif (humain), dépend de plusieurs facteurs
→ difficile à automatiser

- Besoin = requête
 - Besoin confondu avec la requête utilisateur (une liste de mots clés)
- Document et requête
 - Représentés par des termes (mots simples, groupes de mots, ...) → Sac de mots
- Pertinence
 - Traduite par la similarité de vocabulaire (mots) entre la requête et le document → thématique

Démarche RI

- Interpréter le texte au lieu de le comprendre
- Exploiter les propriétés statistiques (comptage de mots) du texte plutôt que ses propriétés linguistiques



Concepts de base de la RI

Fichier inverse

d1:
So let it be
with
Caesar. The
noble
Brutus hath
told you
Caesar was
ambitious

d2:
I did enact
Julius
Caesar I
was killed
i' the
Capitol;
Brutus
killed me.

Traitement =

Indexation

Term	N docs	Tot Freq	Ptr	Doc #	Freq
ambitious	1	1	1	2	2
be	1	1	2	1	1
brutus	2	2	3	2	2
capitol	1	1	5	1	1
caesar	2	3	6	2	2
did	1	1		2	2
enact	1	1		1	1
hath	1	1		1	1
I	1	2		2	2
i'	1	1		1	1
it	1	1		1	1
julius	1	1		2	2
killed	1	2		1	1
let	1	1		1	1
me	1	1		2	2
noble	1	1		1	1
so	1	1		2	2
the	2	2		2	2
told	1	1		1	1
you	1	1		2	2
was	2	2		2	2
with	1	1		2	2
				1	
				2	
				2	

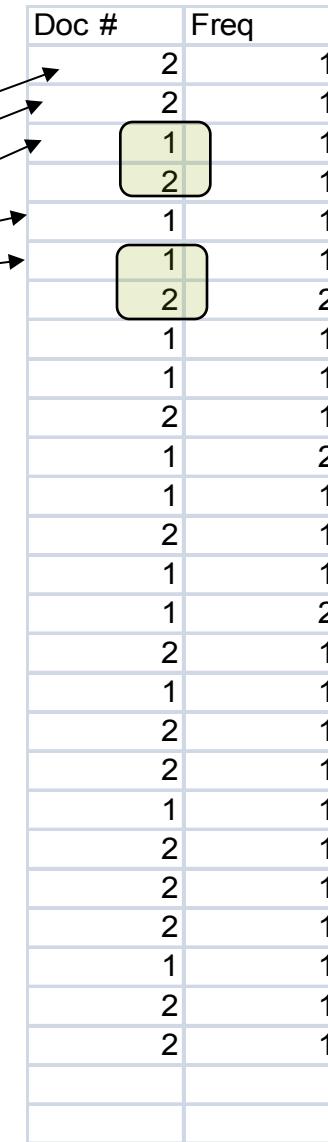
d1:
So let it be with
Caesar. The noble
Brutus hath told you
Caesar was ambitious

d2:
I did enact Julius
Caesar I was killed
 ' the Capitol;
Brutus killed me.



Caesar, brutus

Term	N docs	Tot Freq	Ptr
ambitious	1	1	1
be	1	1	2
brutus	2	2	3
capitol	1	1	5
caesar	2	3	6
did	1	1	
enact	1	1	
hath	1	1	
I	1	2	
i'	1	1	
it	1	1	
julius	1	1	
killed	1	2	
let	1	1	
me	1	1	
noble	1	1	
so	1	1	
the	2	2	
told	1	1	
you	1	1	
was	2	2	
with	1	1	



d1:
So let it be with
Caesar. The noble
Brutus hath told you
Caesar was ambitious

d2:
I did enact Julius
Caesar I was killed
 i the Capitol;
Brutus killed me.

d3:
I did enact Julius
Caesar I was killed
I the Capitol;
I did ~~enact~~⁴⁵ Julius
I did enact Julius
Caesar I was killed
I did ~~enact~~⁴⁶ Julius
Caesar I was killed
I the Capitol;
Brutus killed me
I did enact Julius
Caesar I was killed
I the Capitol;
Brutus ~~killed~~⁴⁸ me
I did enact Julius
Caesar I was killed
I the Capitol;
Brutus ~~killed~~⁴⁹ me
I did enact Julius
Caesar I was killed
I the Capitol;
Brutus killed me
I did enact Julius

- Facteurs utilisés par la majorité des modèles
 - Fréquence du terme dans le document (**tf**), sa fréquence dans la collection (**idf**), sa position dans le texte(p), taille du document (**dl**) ...

$$Score(D) = fonction(tf, idf, dl)$$

- Plusieurs modèles théoriques pour formaliser cette fonction
- Elle peut être apprise (apprentissage automatique, approche utilisée par la majorité des moteurs de recherche)

- Théorie des ensembles :
 - Boolean model (± 1950)
- Algèbre
 - Vector space model (± 1970)
 - Spreading activation model (± 1989)
 - LSI (Latent semantic Indexing) (± 1994)
- Probabilité
 - Probabilistic model (± 1976)
 - Inference network model (± 1992)
 - Language model (± 1998)
 - DFR (Divergence from Randomness model) (± 2002)

Références bibliographiques

- Ouvrages en ligne
 - Christopher D. Manning, Prabhakar Raghavan, and Hinrich Schütze. Introduction to Information Retrieval. 2008 <http://nlp.stanford.edu/IR-book/information-retrieval.html>)
 - Baeza-Yates, R. and Ribeiro-Neto, B. (2011). Modern Information Retrieval - the concepts and technology behind search.
 - Ricardo Baeza-Yates and Berthier Ribeiro-Neto. Modern Information Retrieval. Addison-Wesley, 1999
 - Van Rijsbergen (1977) Information Retrieval, Butterworths
 - Frakes and Baeza-Yates, eds. (1992) Information Retrieval: Data Structures & Algorithms, Prentice Hall
 - Witten, Moffat and Bell (1994) Managing Gigabytes plus software, Van Nostrand-Reinhold
 - Baeza-Yates and Ribeiro-Neto, eds. (1999) Modern Information Retrieval Addison-Wesley ([site miroir](#))
 - Recherche d'information : état des lieux et perspectives (M. Boughanem et J. Savoy)

Conférences et Journaux

• Conférences

- ACM SIGIR : Special interest group on Information Retrieval
- CIKM : Conference on Information and Knowledge Management
- ECIR : European Conference on Information Retrieval Research, University of Sunderland, U.K.
- WSDM: International conference on Web Search and Data Mining
- RIAO (OAIR): Coupling approaches, coupling media and coupling languages for information retrieval
- CORIA : Conférence Francophone en Recherche d'Information et Applications

• Journaux

- JASIST : Journal of the American Society for Information Science and Technology
- IP&M : Information Processing & Management
- IJODL : International Journal on Digital Libraries
- JDOC : Journal of Documentation
- JIR : Journal of Information Retrieval
- ACM-TOIS : Transactions on Information Systems

Ref. bibliographiques

- Frontiers, challenges, and opportunities for information retrieval: Report from SWIRL 2012 the second strategic workshop on information retrieval in Lorne
- Recommended reading for IR research students A.Moffat J.Zobel D. Hawking (2005)
- <http://sigir.org/resources/>

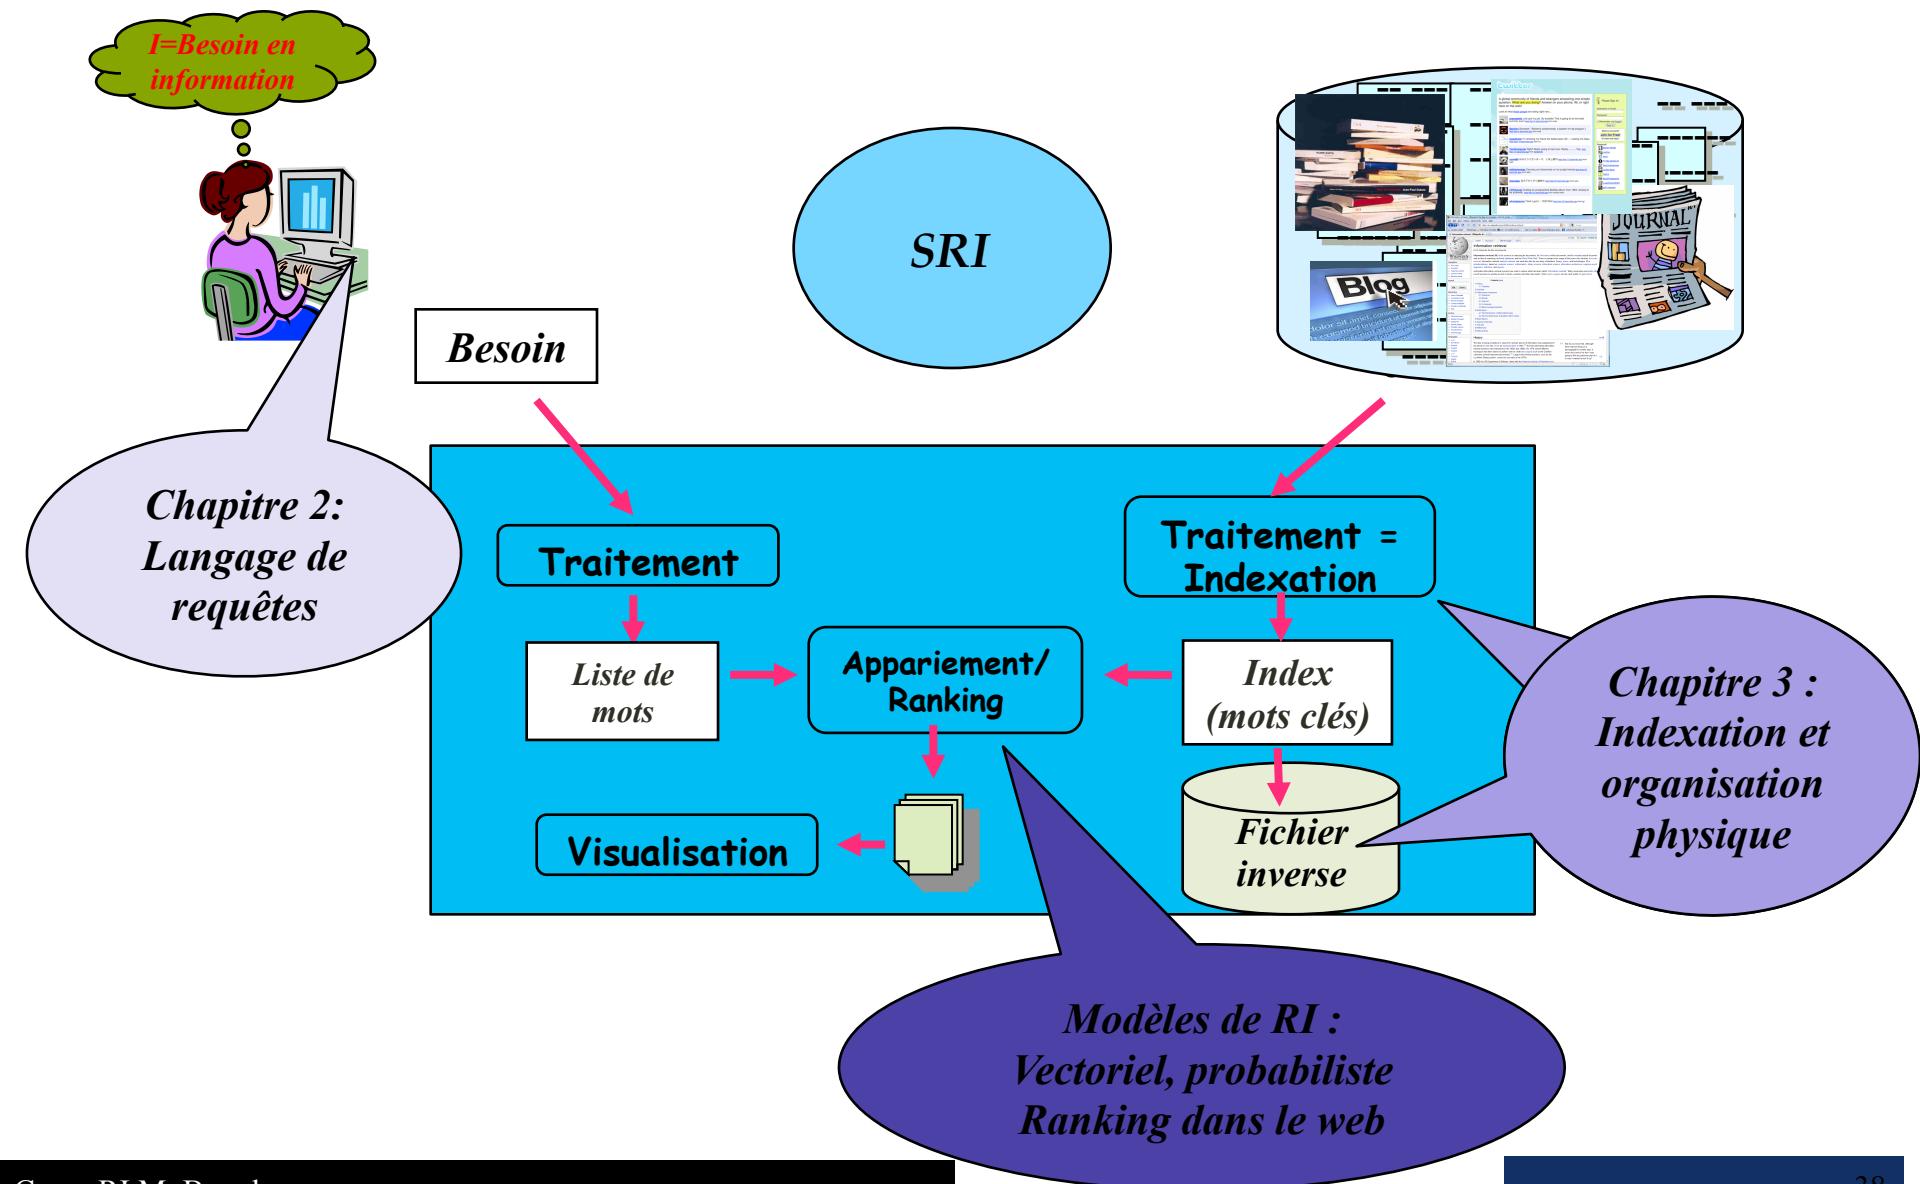


Museum

Report on the first stage of an investigation
onto the comparative efficiency of indexing
systems

Cyril W. Cleverdon
The College of Aeronautics, Cranfield, England, 1960

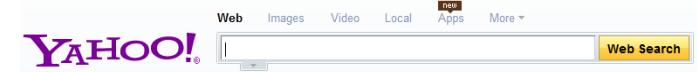
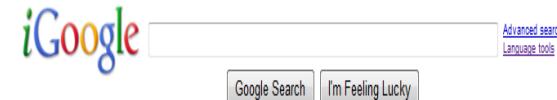
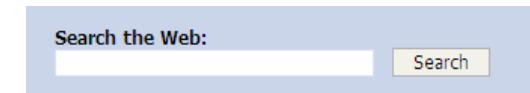
Organisation de la suite du cours



Chapitre 2 : Langage d'interrogation

Du besoin en information à la requête

- Besoin peut être
 - Ponctuel(adhoc)/ Récurrent (filtrage, recommandation)
- Expression des besoins (Langage de requêtes)
 - Texte libre, Liste de mots clés
 - Avec / sans opérateurs booléens (AND, OR, NOT)
 - Images (...)
 - Aucun : navigation dans une liste de concepts (Yahoo,...)
- Requête est le résultat
 - de l'expression des besoins ?
 - ou du processus de représentation des besoins ?
- Ces deux notions sont souvent confondues



- Paradoxe de la RI
 - Une requête «idéale» doit comporter toutes les informations que l'utilisateur recherche → la similarité serait maximale
 - Or, l'utilisateur recherche une information qu'il ne connaît pas à priori, il ne peut donc pas l'exprimer (décrire) de manière précise (idéale)
 - Ce phénomène est qualifié par Belkin ASK “Anomalous State of Knowledge”

Suggestion de requêtes

The screenshot shows a Google search page. In the search bar, the letters "ense" are typed. Below the search bar, a dropdown menu displays several search suggestions:

- enseeiht
- ensemble c'est tout
- enseirb
- enseignement supérieur

At the bottom right of the suggestions box is a blue link labeled "En savoir plus". Below the suggestions box, there is a gray placeholder text: "Appuyez sur Entrée pour lancer la recherche.".

Recherches associées à enseeiht

enseeiht classement	bde enseeiht
moodle enseeiht	rcmail enseeiht
enseeiht stage	intranet enseeiht
adresse enseeiht	enseeiht classement 2011

At the bottom of the page, there is a decorative footer featuring the word "Gooooooooooooogle" in a stylized font, followed by a right-pointing arrow. Below this, a horizontal navigation bar shows page numbers from 1 to 10, and a blue link labeled "Suivant".