

Kodex : comment organiser les résultats d'une recherche web par analyse de graphe

Benoit Gaillard, Emmanuel Navarro

5 décembre 2011

- ▶ Détection de communautés sur un graphe biparti documents-mots (Emmanuel Navarro)
- ▶ Labellisation endogène de clusters de documents (Benoît Gaillard)

[Everything](#)[Images](#)[Maps](#)[Videos](#)[News](#)[Shopping](#)[More](#)**All results**[Sites with images](#)[More search tools](#)[Japan - Wikipedia, the free encyclopedia](#)en.wikipedia.org/wiki/Japan [+7](#)

Japan Listen/dʒəˈpæn/ (**Japanese**: 日本 Nihon or Nippon; formally 日本国 About this sound Nippon-koku or Nihon-koku, literally, the State of **Japan**) is an ...

[Names of Japan](#) - [Geography of Japan](#) - [History of Japan](#) - [Culture](#)[Japan National Tourism Organization Web Site](#)www.jnto.go.jp/ [+7](#)

JNTO is involved in a broad range of activities promoting travel to **Japan** through various activities overseas as well as tourism-promoting activities in **Japan**.

[japan-guide.com - Japan Travel and Living Guide](#)www.japan-guide.com/ [+7](#)

Everything about modern and traditional **Japan** with emphasis on travel and living related information.

[Japan](#) maps.google.com[Japan Travel Information and Travel Guide - Lonely Planet](#)www.lonelyplanet.com/japan [+7](#)

Japan tourism and travel information including facts, maps, history, culture, transport and weather in **Japan**. Find popular places to visit in **Japan** - Lonely Planet.

[Japan News - Earthquake, Tsunami and Nuclear Crisis \(2011\)](#)topics.nytimes.com > [World](#) > [Countries and Territories](#) [+7](#)

Everything

Images

Maps

Videos

News

Shopping

More

[Japan - Wikipedia, the free encyclopedia](#)

en.wikipedia.org/wiki/Japan 

Japan Listen/dʒəˈpæn/ (**Japanese**: 日本 Nihon or Nippon; formally 日本国 About this sound Nippon-koku or Nihon-koku, literally, the State of **Japan**) is an ...

[Names of Japan](#) - [Geography of Japan](#) - [History of Japan](#) - [Culture](#)

[Japan National Tourism Organization Web Site](#)

www.jnto.go.jp/ 

JNTO is involved in a broad range of activities promoting travel to **Japan** through various activities overseas as well as tourism-promoting activities in **Japan**.

[japan-guide.com - Japan Travel and Living Guide](#)

www.japan-guide.com/ 

All

Site

More

▶ Liste ordonnée !

▶ Pourtant :

- Polysémie des requêtes,
- Structure dans la listes des documents.

▶ Rendre visible cette structure à l'utilisateur,

▶ Lui permettre de raffiner sa recherche.

[Japan Travel Information and Travel Guide - Lonely Planet](#)

www.lonelyplanet.com/japan 

Japan tourism and travel information including facts, maps, history, culture, transport and weather in **Japan**. Find popular places to visit in **Japan** - Lonely Planet.

[Japan News - Earthquake, Tsunami and Nuclear Crisis \(2011\)](#)

topics.nytimes.com › World › Countries and Territories 

Everything

Images

Maps

Videos

News

Shopping

More

[Japan - Wikipedia, the free encyclopedia](#)en.wikipedia.org/wiki/Japan 

Japan Listen/dʒəˈpæn/ (**Japanese**: 日本 Nihon or Nippon; formally 日本国 About this sound Nippon-koku or Nihon-koku, literally, the State of **Japan**) is an ...

[Names of Japan](#) - [Geography of Japan](#) - [History of Japan](#) - [Culture](#)[Japan National Tourism Organization Web Site](#)www.jnto.go.jp/ 

JNTO is involved in a broad range of activities promoting travel to **Japan** through various activities overseas as well as tourism-promoting activities in **Japan**.

[japan-guide.com - Japan Travel and Living Guide](#)www.japan-guide.com/ 

All

Site

More

▶ Liste ordonnée !

▶ Pourtant :

- Polysémie des requêtes,
- Structure dans la listes des documents.

- ▶ Rendre visible cette structure à l'utilisateur,
- ▶ Lui permettre de raffiner sa recherche.

[Japan travel information and travel Guide - Lonely Planet](#)www.lonelyplanet.com/japan 

Japan tourism and travel information including facts, maps, history, culture, transport and weather in **Japan**. Find popular places to visit in **Japan** - Lonely Planet.

[Japan News - Earthquake, Tsunami and Nuclear Crisis \(2011\)](#)topics.nytimes.com › World › Countries and Territories 

Everything

Images

Maps

Videos

News

Shopping

More

[Japan - Wikipedia, the free encyclopedia](#)en.wikipedia.org/wiki/Japan 

Japan Listen/dʒəˈpæn/ (**Japanese**: 日本 Nihon or Nippon; formally 日本国 About this sound Nippon-koku or Nihon-koku, literally, the State of **Japan**) is an ...

[Names of Japan](#) - [Geography of Japan](#) - [History of Japan](#) - [Culture](#)[Japan National Tourism Organization Web Site](#)www.jnto.go.jp/ 

JNTO is involved in a broad range of activities promoting travel to **Japan** through various activities overseas as well as tourism-promoting activities in **Japan**.

[japan-guide.com - Japan Travel and Living Guide](#)www.japan-guide.com/ 

All

Site

More

▶ Liste ordonnée !

▶ Pourtant :

- Polysémie des requêtes,
- Structure dans la listes des documents.

▶ **Rendre visible cette structure à l'utilisateur,**

▶ Lui permettre de raffiner sa recherche.

[Japan Travel Information and Travel Guide - Lonely Planet](#)www.lonelyplanet.com/japan 

Japan tourism and travel information including facts, maps, history, culture, transport and weather in **Japan**. Find popular places to visit in **Japan** - Lonely Planet.

[Japan News - Earthquake, Tsunami and Nuclear Crisis \(2011\)](#)topics.nytimes.com › World › Countries and Territories 

Everything

Images

Maps

Videos

News

Shopping

More

[Japan - Wikipedia, the free encyclopedia](#)en.wikipedia.org/wiki/Japan 

Japan Listen/dʒəˈpæn/ (**Japanese**: 日本 Nihon or Nippon; formally 日本国 About this sound Nippon-koku or Nihon-koku, literally, the State of **Japan**) is an ...

[Names of Japan](#) - [Geography of Japan](#) - [History of Japan](#) - [Culture](#)[Japan National Tourism Organization Web Site](#)www.jnto.go.jp/ 

JNTO is involved in a broad range of activities promoting travel to **Japan** through various activities overseas as well as tourism-promoting activities in **Japan**.

[japan-guide.com - Japan Travel and Living Guide](#)www.japan-guide.com/ 

All

Site

More

- ▶ Liste ordonnée !
- ▶ Pourtant :
 - Polysémie des requêtes,
 - Structure dans la listes des documents.
- ▶ Rendre visible cette structure à l'utilisateur,
- ▶ Lui permettre de raffiner sa recherche.

[Japan Travel Information and Travel Guide - Lonely Planet](#)www.lonelyplanet.com/japan 

Japan tourism and travel information including facts, maps, history, culture, transport and weather in **Japan**. Find popular places to visit in **Japan** - Lonely Planet.

[Japan News - Earthquake, Tsunami and Nuclear Crisis \(2011\)](#)topics.nytimes.com › World › Countries and Territories 

japan

search

[options](#)

30 results for "japan"

japanese, china, asia,
history, government,

travel, guide,
sightseeing, tourism,
information,

news, business, network,
photo, sports,

airlines, flight, purchase,
japan domestic flight,
jal group,

nuclear, tsunami, crisis,
nuclear power plant,
earthquake,

[Japan - Wikipedia](#)

Find information about the history, politics, geography, economy, and culture of **Japan**.

<http://en.wikipedia.org/wiki/Japan>

[Japan National Tourism Organization](#)

Japan is situated in northeastern Asia between the North Pacific and the Sea of **Japan**. ... **Japan** consists of four major islands, surrounded by more than 4,000 ...

<http://www.jnto.go.jp/eng/>

[Japan Today](#)

Japan Today is an international news network covering news, politics, business, sports, technology, and more.

<http://www.japantoday.com/>

[VISIT JAPAN 2011](#)

It presents **Japan's** history and culture, covers events, festivities, tourism, food and shopping, and provides other kinds of helpful information. Come...

<http://www.visitjapan.jp/>

[japan-guide.com](#)

Everything about modern and traditional **Japan** with emphasis on travel and living related information.

<http://www.japan-guide.com/>

[Official Tourism Guide for Japan Travel](#)

Japan National Tourist Organization offers information on transportation, lodging, restaurants, tourist attractions, culture, history, festivals, and ...

<http://www.japantravelinfo.com/>

japan

search [options](#)

30 results for "japan"

→
japanese, china, asia,
history, government,

travel, guide,
sightseeing, tourism,
information,

news, business, network,
photo, sports,

airlines, flight, purchase,
japan domestic flight,
jal group,

nuclear, tsunami, crisis,
nuclear power plant,
earthquake,

[Japan.org](#)

SENDAI, **Japan** — A strong new earthquake rattled **Japan's** northeast Monday as the government urged more people living near a tsunami-crippled nuclear ...

<http://www.japan.org/>

[Japan News - Earthquake, Tsunami and Nuclear Crisis \(2011\)](#)

World news about **Japan**, including breaking news about the March 11, 2011 earthquake and tsunami and the nuclear crisis from The New York Times.

<http://topics.nytimes.com/top/news/international/countriesandterritories/japan/index.html>

[Embassy of Japan, Addis Ababa, ETHIOPIA](#)

Japan has the experience of a relatively fast recovery from the devastation of the war and has overcome various natural disasters in the past. ...

<http://www.et.emb-japan.go.jp/>

[Japan: News & Videos about Japan - CNN.com](#)

The nuclear crisis wreaks havoc on one of **Japan's** prized exports: green tea. ... Matador's destination expert on **Japan** lays out the country's avoidable attractions ...

<http://topics.cnn.com/topics/Japan>

[Special report: Japan's throwaway nuclear workers | Reuters](#)

FUKUSHIMA, **Japan** (Reuters) - A decade and a half before it blew apart in a hydrogen blast that punctuated the worst nuclear accident since Chernobyl, ...

<http://www.reuters.com/article/2011/06/24/us-japan-nuclear-idUSTRE75N18A20110624>

- ▶ Organiser les résultats d'une recherche web
- ▶ Méthode : clustering de graphe
- ▶ Projet dans le cadre du programme Quaero¹



.. et donc :

- ▶ Comment construire un graphe? un "bigraphe" ?
- ▶ Comment fonctionne le clustering ?
- ▶ (comment donner des étiquettes aux clusters ?)
- ▶ Comment évaluer la méthode ?

1. 1er version du projet présentée à Coria2011 [?]
2. Nouvelle version en cours de développement...

1. <http://www.quaero.org/>

Construction du graphe Documents/Mots


Pour chaque document : les 50 termes de plus fort BM25

Filtres :

- ▶ $df \Rightarrow 100$
- ▶ $df_{local} \leq 90\%$
- ▶ $df_{local} > 1$

Pondération par : $tf \cdot idf_{local} = tf \cdot \log\left(\frac{1}{df_{local}}\right)$

N documents **Termes**



Note : on a un graphe **biparti** (projection possible).

Construction du graphe Documents/Mots


Pour chaque document : les 50 termes de plus fort BM25

Filtres :

- ▶ $df \Rightarrow 100$
- ▶ $df_{local} \leq 90\%$
- ▶ $df_{local} > 1$

Pondération par : $tf \cdot idf_{local} = tf \cdot \log\left(\frac{1}{df_{local}}\right)$

N documents **Termes**



Note : on a un graphe **biparti** (projection possible).

Construction du graphe Documents/Mots


Pour chaque document : les 50 termes de plus fort BM25

Filtres :

- ▶ $df \Rightarrow 100$
- ▶ $df_{local} \leq 90\%$
- ▶ $df_{local} > 1$

Pondération par : $tf \cdot idf_{local} = tf \cdot \log\left(\frac{1}{df_{local}}\right)$

N documents **Termes**



Note : on a un graphe **biparti** (projection possible).

Construction du graphe Documents/Mots


Pour chaque document : les 50 termes de plus fort BM25

Filtres :

- ▶ $df \Rightarrow 100$
- ▶ $df_{local} \leq 90\%$
- ▶ $df_{local} > 1$

Pondération par : $tf \cdot idf_{local} = tf \cdot \log\left(\frac{1}{df_{local}}\right)$

N documents **Termes**



Note : on a un graphe **biparti** (projection possible).

Construction du graphe Documents/Mots


Pour chaque document : les 50 termes de plus fort BM25

Filtres :

- ▶ $df \Rightarrow 100$
- ▶ $df_{local} \leq 90\%$
- ▶ $df_{local} > 1$

Pondération par : $tf \cdot idf_{local} = tf \cdot \log\left(\frac{1}{df_{local}}\right)$

N documents **Termes**



Note : on a un graphe **biparti** (projection possible).

Construction du graphe Documents/Mots


Pour chaque document : les 50 termes de plus fort BM25

Filtres :

- ▶ $df \Rightarrow 100$
- ▶ $df_{local} \leq 90\%$
- ▶ $df_{local} > 1$


Pondération par : $tf \cdot idf_{local} = tf \cdot \log\left(\frac{1}{df_{local}}\right)$

N documents **Termes**



Note : on a un graphe **biparti** (projection possible).

clustering du graphe?



Le problème : repérer les structures mésoscopiques porteuses de sens.

graphes lexicaux : *concepts*,
graphes de documents : *thèmes*,
graphes sociaux : *communautés, familles, clubs, etc...*

communauté \simeq cluster :

*Sous-ensemble de sommets
“plus fortement” connectés entre eux qu’au reste du graphe.*


mais pas de définition formelle générale.

- ▶ énormément de méthodes proposées depuis 2003 (après découverte des propriétés communes des grands graphes de terrain)
- ▶ héritier des problèmes de *clustering* (data mining) et de *partitionnement de graphes* (informatique),
- ▶ apprentissage non supervisé.

Article fondateur : [?]

Une méthode parmi (beaucoup) d'autres : Walktrap


- 1 Calcul d'une similarité entre sommets,
- 2 Clustering hiérarchique,
- 3 Coupe du dendrogramme (optimisation de la modularité).



Comment calculer une distance/similarité pertinente entre les sommets d'un graphe ?


- ▶ dans graphe uni-parti,
- ▶ puis dans un graphe biparti.

Comment mesurer une similarité entre sommets ?



Quel est la similarité entre A et B (par exemple) ?

Comment mesurer une similarité entre sommets ?




Distance géodésique : nombre d'arêtes du **plus court chemin**.

MAIS les graphes sont des *Petits Mondes* : $d_T(A, B) \simeq 4$

La mesure n'est pas discriminatoire.

Comment mesurer une similarité entre sommets ?




On peut utiliser les vecteurs d'adjacence ? (modèle "vectoriel")

$$A = [1, 1, 1, 1, 1, 1, 1, 1, 0, 0, 0, 0, 0, 0, 0]$$

$$B = [0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1]$$

Comment mesurer une similarité entre sommets ?




On peut utiliser les vecteurs d'adjacence ? (modèle "vectoriel")

$$A = [1, 1, 1, 1, 1, 1, 1, 1, 0, 0, 0, 0, 0, 0, 0]$$


$$B = [0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1]$$

Comment mesurer une similarité entre sommets ?



Tout le graphe a changé... sauf $d(A, B)$!!
Vecteurs d'adjacence = **information locale**
ignore la **topologie** du graphe !


Comment mesurer une similarité entre sommets ?




Tout le graphe a changé... sauf $d(A, B)$!!
Vecteurs d'adjacence = **information locale**
ignore la **topologie** du graphe !

Chaque sommet est représenté par la **distribution de probabilité** résultant d'une **marche aléatoire courte** partant de ce sommet.


[?]




$$t = 0, \quad C(u, t) = [0, 0, 0, 1.0, 0, 0, 0, 0, 0]$$



$$t = 1, \quad C(u, t) = [0.2, 0.2, 0.2, 0.2, 0.2, 0, 0, 0, 0, 0]$$




$$t = 2, \quad C(u, t) = [0.2, 0.16, 0.14, 0.21, 0.11, 0.08, 0.03, 0.07, 0]$$



$$t = 3, \quad C(u, t) = [0.15, 0.15, 0.14, 0.17, 0.13, 0.08, 0.06, 0.07, 0.02]$$

Et sur un graphe biparti ?




$$\begin{cases} C(u, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(u, t+1) = [0, 0, 0, 0, x, x, x, x, x, x] \\ \begin{cases} C(u \in \text{termes}, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(v \in \text{documents}, t) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases} \end{cases}$$

Problème de périodicité :

- ▶ pas de convergence !
- ▶ Comment comparer *termes* et *documents* ?

Et sur un graphe biparti ?




$$\begin{cases} C(u, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(u, t+1) = [0, 0, 0, 0, x, x, x, x, x, x] \\ \begin{cases} C(u \in \text{termes}, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(v \in \text{documents}, t) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases} \end{cases}$$

Problème de périodicité :

- ▶ pas de convergence !
- ▶ Comment comparer *termes* et *documents* ?

Et sur un graphe biparti ?




$$\begin{cases} C(u, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(u, t+1) = [0, 0, 0, 0, x, x, x, x, x, x] \\ \begin{cases} C(u \in \text{termes}, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(v \in \text{documents}, t) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases} \end{cases}$$

Problème de périodicité :

- ▶ pas de convergence !
- ▶ Comment comparer *termes* et *documents* ?

Et sur un graphe biparti ?




$$\begin{cases} C(u, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(u, t+1) = [0, 0, 0, 0, x, x, x, x, x, x] \\ C(u \in \text{termes}, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(v \in \text{documents}, t) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases}$$

Problème de périodicité :

- ▶ pas de convergence !
- ▶ Comment comparer *termes* et *documents* ?

Et sur un graphe biparti ?




$$\begin{cases} C(u, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(u, t+1) = [0, 0, 0, 0, x, x, x, x, x, x] \\ C(u \in \text{termes}, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(v \in \text{documents}, t) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases}$$

Problème de périodicité :

- ▶ pas de convergence !
- ▶ Comment comparer *termes* et *documents* ?

Et sur un graphe biparti ?




$$\begin{cases} C(u, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(u, t+1) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases}$$
$$\begin{cases} C(u \in \text{termes}, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(v \in \text{documents}, t) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases}$$

Problème de périodicité :

► pas de convergence !

► Comment comparer *termes* et *documents* ?

Et sur un graphe biparti ?



$$\begin{cases} C(u, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(u, t+1) = [0, 0, 0, 0, x, x, x, x, x, x] \\ \begin{cases} C(u \in \text{termes}, t) = [x, x, x, x, 0, 0, 0, 0, 0, 0] \\ C(v \in \text{documents}, t) = [0, 0, 0, 0, x, x, x, x, x, x] \end{cases} \end{cases}$$

Problème de périodicité :

- ▶ pas de convergence !
- ▶ **Comment comparer *termes* et *documents* ?**

Une solution simple...

- ▶ Balades de longueur $2t$ pour les *termes*
⇔ **balades de longueur t** sur un **graphe projeté pondéré**
- ▶ Balades de longueur $2t + 1$ pour les *documents*
⇔ **barycentre des coordonnées de leurs voisins** (\in *termes*)

Evaluation (1/2)

hypothèse : A partir d'un ensemble de documents restitués par un moteur de recherche pour une requête, Kodex est capable de construire un cluster contenant un maximum de documents pertinents.

Evaluation :

Rappel/Précision du "meilleur" des clusters,
par rapport au Rappel/Précision de la liste ordonnée.

Quelle est la qualité du meilleur cluster par rapport au même nombre de documents dans la liste ordonnée?

Evaluation (2/2)

Collection : Quaero-P2, **2.6 millions de pages Web** (.fr), aspirées par Exalead,
25 topics : requête textuelle et un texte explicitant le besoin en information.
Besoins réels (logs de requêtes chez Exalead), ex :

- ▶ Hypertyroïdie
- ▶ *On cherche les conséquences et traitements (médicaments, opération, ...) de l'hypertyroïdie. Les documents ne traitant que des causes de la maladie ne sont pas pertinents.*

SRI utilisé : Terrier²

Run	R	P	F_1
Kodex	0,4461	0,4728	0,3210
Terrier	0,3295	0,3709	0,2628
Gain de Kodex <i>versus</i> Terrier	35 %*	27 %	22 %*

Table: Moyenne de R , P et F_1 pour Terrier et Kodex, calculée sur 25 topics. Une astérisque indique que l'amélioration est statistiquement significative selon le test t de Student païré et bilatéral avec $p < 0,05$

2. <http://terrier.org/>

travail présenté = 1er version du Kodex,

Plusieurs limites :

- ▶ labélisation (termes des clusters) non suffisante et non évalué,
- ▶ pas de **recouvrement** entre les clusters,
- ▶ évaluation : ne nous dit vraiment pas si le découpage est pertinent.

Etiquetage endogène de grappes de documents

- ▶ Problématique : identifier le meilleur cluster
- ▶ Travaux connexes : questions en suspens
- ▶ Approche proposée :
 - Facteur Descriptif, Facteur Discriminant et Eloquence
 - Ressource endogène pour labels externes
- ▶ Expériences
- ▶ Conclusion

Des résultats regroupés par thématiques : *clusters*

[options](#)

30 results for "japan"

japanese, china, asia,
history, government,

travel, guide,
sightseeing, tourism,
information,

news, business, network,
photo, sports,

airlines, flight, purchase,
japan domestic flight,
jal group,

nuclear, tsunami, crisis,
nuclear power plant,
earthquake,

[Japan - Wikipedia](#)

Find information about the history, politics, geography, economy, and culture of **Japan**.

<http://en.wikipedia.org/wiki/Japan>

[Japan National Tourism Organization](#)

Japan is situated in northeastern Asia between the North Pacific and the Sea of **Japan**. ... **Japan** consists of four major islands, surrounded by more than 4,000 ...

<http://www.jnto.go.jp/eng/>

[Japan Today](#)

Japan Today is an international news network covering news, politics, business, sports, technology, and more.

<http://www.japantoday.com/>

[VISIT JAPAN 2011](#)

It presents **Japan's** history and culture, covers events, festivities, tourism, food and shopping, and provides other kinds of helpful information. Come...

<http://www.visitjapan.jp/>

[japan-guide.com](#)

Everything about modern and traditional **Japan** with emphasis on travel and living related information.

<http://www.japan-guide.com/>

[Official Tourism Guide for Japan Travel](#)

Japan National Tourist Organization offers information on transportation, lodging, restaurants, tourist attractions, culture, history, festivals, and ...

<http://www.japantravelinfo.com/>

Identifier ces thématiques sans explorer les clusters

search

[options](#)

30 results for "japan"

japanese, china, asia,
history, government,

travel, guide,
sightseeing, tourism,
information,

news, business, network,
photo, sports,

airlines, flight, purchase,
japan domestic flight,
jail group,

nuclear, tsunami, crisis,
nuclear power plant,
earthquake,

[Japan.org](#)

SENDAI, **Japan** — A strong new earthquake rattled **Japan's** northeast Monday as the government urged more people living near a tsunami-crippled nuclear ...

<http://www.japan.org/>

[Japan News - Earthquake, Tsunami and Nuclear Crisis \(2011\)](#)

World news about **Japan**, including breaking news about the March 11, 2011 earthquake and tsunami and the nuclear crisis from The New York Times.

<http://topics.nytimes.com/top/news/international/countriesandterritories/japan/index.html>

[Embassy of Japan, Addis Ababa, ETHIOPIA](#)

Japan has the experience of a relatively fast recovery from the devastation of the war and has overcome various natural disasters in the past. ...

<http://www.et.emb-japan.go.jp/>

[Japan: News & Videos about Japan - CNN.com](#)

The nuclear crisis wreaks havoc on one of **Japan's** prized exports: green tea. ... Matador's destination expert on **Japan** lays out the country's avoidable attractions ...

<http://topics.cnn.com/topics/Japan>

[Special report: Japan's throwaway nuclear workers | Reuters](#)

FUKUSHIMA, **Japan** (Reuters) - A decade and a half before it blew apart in a hydrogen blast that punctuated the worst nuclear accident since Chernobyl, ...

<http://www.reuters.com/article/2011/06/24/us-japan-nuclear-idUSTRE75N18A20110624>

Quelques mots pour décrire un ensemble de documents :

- ▶ Décrire de quoi parlent les documents du cluster
- ▶ Distinguer les documents du cluster des autres résultats
- ▶ Etre compréhensibles par l'utilisateur

Ni trop général, ni trop spécifique :

- ▶ Mots **les plus fréquents** : peu informatifs car trop communs. [?],[?]

Exemple de mots fréquents

"forum", "2008"

- ▶ Les plus **informatifs** (important au sens RI) : termes spécialisés trop spécifiques ([?]).

Exemple de termes trop spécialisés

- *"iode 131"* pour *"nucléaire"*
- *"Chelem"* apparaît 25 fois dans un article sur Agassi, vs tennis 13.
- *"tag, text, linguist, lexicon, corpus, tagger, word, syntax, grammar."* pour *"natural language processing"* [?]

Informer du thème général ou d'un aspect de ce thème [?] :

Descriptive or Discriminative power [?]

- ▶ *Descriptive power* : plus fréquent dans cluster que dans collection totale
- ▶ *Discriminative power* : plus fréquent dans cluster que dans les résultats de la requête (extended log-likelihood, [?])

Informatifs généraux peuvent être externes aux documents

Labels provenant de ressources externes :

- ▶ [?] : Wikipédia
- ▶ [?] : Wordnet
- ▶ [?] : Dictionnaire

- ▶ Ressources *exogènes* (Wordnet, Wikipedia, dictionnaire) : questions de qualité et de couverture.
- ▶ Labels externes **moins spécialisés** : **hyperonymes** ou catégories générales dans des ressources externes, mais sélection de candidats sans critère explicite d'**Eloquence** :

Exemple :

[?] : "*judges*" = Information Mutuelle, scores de RI.

- ▶ Critère explicite d'**Eloquence** : **E**
- ▶ Candidats informatifs : *Pertinence* à 2 dimensions :
 - Facteur *Descriptif* : **I**
 - Facteur *Discriminant* : **D**
- ▶ **Ressource endogène** pour étiquettes (labels) externes

Liste de candidats

Valeur de chaque candidat :

$$V = \alpha.I + \beta.D + \gamma.E$$

Sélection des N candidats de plus haute valeur

Principe simple :


- ▶ $fratio(t, d) = \frac{Freq(t,d)}{Freq(t,Col)} = \frac{tf(t,d)}{dlen} / \frac{CTF(t)}{ColLen}$
- ▶ tf : term frequency, CTF : Collection term frequency, $ColLen$: Longueur de la Collection, DF Document Frequency

Application en Recherche d'Information :

- ▶ $tfidf(t, d) = tf(t, d) \cdot \log\left(\frac{N_{docs}}{DF(t)}\right)$
- ▶ $tfidfplus(t, d) = tf(t, d) \cdot \log\left(\frac{ColLen}{CTF(t)}\right)$
- ▶ $\times \frac{1}{len(d)}$, longueur du document d
- ▶ bm25 (okapi)...


Facteur Descriptif d'un terme
pour un cluster :

$$\blacktriangleright I(w) = \frac{\text{Freq}(w, \text{cluster})}{\text{Freq}(w, \text{collection})}$$




Facteur Descriptif d'un terme
pour un cluster :

$$\blacktriangleright I(w) = \frac{\text{Freq}(w, \text{cluster})}{\text{Freq}(w, \text{collection})}$$




Facteur Descriptif d'un terme pour un cluster :

$$\blacktriangleright I(w) = \frac{\text{Freq}(w, \text{cluster})}{\text{Freq}(w, \text{collection})}$$



Facteur Descriptif d'un terme
pour un cluster :

$$\blacktriangleright I(w) = \frac{\text{Freq}(w, \text{cluster})}{\text{Freq}(w, \text{collection})}$$




Facteur Descriptif d'un terme pour un cluster :

$$\blacktriangleright I(w) = \frac{\text{Freq}(w, \text{cluster})}{\text{Freq}(w, \text{collection})}$$

Facteur Discriminant d'un terme pour un cluster :

$$\blacktriangleright D(w) = \frac{\text{Freq}(w, \text{cluster})}{\text{Freq}(w, \text{results})}$$



- ▶ Approches classiques : hyperonymes
- ▶ Hyperonymes : voisins de plus fort degré dans un graphe de synonymie [?]
- ▶ Fréquence dans le corpus (lien avec l'apprentissage du vocabulaire) :
 - $E(w) = \text{Freq}(w, \text{collection})$

Occurrences un texte sur une manifestation d'agriculteurs :

- ▶ ours=5 ; candidat=1
- ▶ politique=0 ; écologie=0

Trouver des Unités Lexicales :

- ▶ Proches sémantiquement
- ▶ Ressources exogènes : dictionnaires, Wordnet, Wikipedia. couverture lexicale, imprécisions.


Objectif : décrire la thématique du cluster

- ▶ Moins strict que "le même sens" : Même contexte thématique
- ▶ Collocations "dans un même texte"

Ressource endogène : Graphe de co-textualité

$G = (V, E)$, graphe pondéré :

- ▶ V : les UL de l'index : couverture lexicale parfaite
- ▶ E : arêtes pondérées par la cotextualité de leurs extrémités
- ▶ $E(A, B) = \log\left(\frac{P(A|B)}{P(B)}\right)$



Interprétation du poids des arêtes :

Tests : Collection de 10 textes dont l'article Wikipédia Agassi.

Trouver B dans un document est un bon indice de la présence de A.

- ▶ $P(A) = \frac{N_{doc}(A)}{N_{doc}}$ $P(tennis) = \frac{1}{10}$
- ▶ $P(A|B) = \frac{N_{doc}(A.B)}{N_{doc}(B)}$ $P(tennis|Sampras) = \frac{1}{1}$
- ▶ $E(A, B) = E(B, A)$ $E(tennis, Sampras) = 10$
- ▶ $E(A, B) =$ information mutuelle ponctuelle (Pointwise Mutual Information, PMI)

On trouve les candidats par marches aléatoires sur le graphe de co-textualité :
Les descripteurs externes sont des proxèmes des mots des clusters :

- ▶ Proxèmes : $w \rightarrow \{w_i\}$ (prox)
- ▶ Pertinence : $P(w_i) = P(w) \cdot Prox(w \rightarrow w_i)$
- ▶ Pertinence : un facteur Descriptif : $I(w)$, un facteur Discriminant : $D(w)$

Récapitulation :

Valeur d'un candidat w :

$$V(w) = \alpha.I + \beta.D + \gamma.E$$

Valeur d'un candidat w :

$$V(w) = \alpha.I + \beta.D + \gamma.E$$

Facteur descriptif :

$$I(w) = \sum_{o \in cluster} tfidf(o, cluster, collection).Prox(o \rightarrow w)$$

Valeur d'un candidat w :

$$V(w) = \alpha.I + \beta.D + \gamma.E$$

Facteur descriptif :

$$I(w) = \sum_{o \in \text{cluster}} \text{tfidf}(o, \text{cluster}, \text{collection}).\text{Prox}(o \rightarrow w)$$

Facteur discriminant :

$$D(w) = \sum_{o \in \text{cluster}} \text{tfidf}(o, \text{cluster}, \text{results}).\text{Prox}(o \rightarrow w)$$

Valeur d'un candidat w :

$$V(w) = \alpha.I + \beta.D + \gamma.E$$

Facteur descriptif :

$$I(w) = \sum_{o \in \text{cluster}} \text{tfidf}(o, \text{cluster}, \text{collection}).\text{Prox}(o \rightarrow w)$$

Facteur discriminant :

$$D(w) = \sum_{o \in \text{cluster}} \text{tfidf}(o, \text{cluster}, \text{results}).\text{Prox}(o \rightarrow w)$$

Eloquence :

$$E(w) = \log(\text{CTF}(w))$$

- ▶ Pertinence mesurée sur la base d'un index document ↔ "mot"
- ▶ Unité Lexicale pour l'indexation :
 - Racine (Porter Stemmer)
 - Troncature
 - Lemmatiser (Treetagger)
 - Syntagmes
- ▶ Optimisations : Prétraitements vs. traitements en ligne

- ▶ But : ergonomie
- ▶ Evaluation de la clusterisation = R,P,F du **meilleur cluster** (cf. première partie)
- ▶ -> Evaluer le **cluster choisi** par l'utilisateur sur la base des labels
- ▶ Littérature : Comparer les résultats du système à des thématiques groupées et étiquetées manuellement

- ▶ $V = \alpha.I + \beta.D + \gamma.E$: importance relative de chacune des 3 dimensions
 - α pour le facteur descriptif
 - β pour le facteur discriminant
 - γ pour l'éloquence)
- ▶ $\log\left(\frac{P(A|B)}{P(B)}\right)$: valeurs négatives. Seuil ou proxémie avec des liens inhibiteurs ?
- ▶ Pertinence : tfidf, bm25, information...
- ▶ Eloquence : meilleurs critères, corrélation degré/fréquence

Travail en cours : pas encore de résultats.

Nouveautés :

- ▶ Paramètre Eloquence
- ▶ Graphe de co-textualité

Bientôt des expériences

 Carmel, D., Roitman, H., and Zwerdling, N. (2009).

Enhancing cluster labeling using wikipedia.

In Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval, SIGIR '09, pages 139–146, New York, NY, USA. ACM.

 de Winter, W. and de Rijke, M. (2007).

Identifying facets in query-biased sets of blog posts.

In Proceedings Int. Conf. on Weblogs and Social Media (ICWSM-2007), pages 251–254.

 Fukumoto, F. and Suzuki, Y. (2011).

Cluster labeling based on concepts in machine-readable dictionaries.

In Proceedings of the 5th International Joint Conference on Natural Language Processing, pages 1371–1375, Chiang Mai, Thailand.

 Gaume, B. (2004).

Balades aléatoires dans les petits mondes lexicaux.

13 Information Interaction Intelligence, 4(2).

 Geraci, F., Pellegrini, M., Maggini, M., and Sebastiani, F. (2007).

Cluster generation and labeling for web snippets : A fast, accurate hierarchical solution.

Internet Mathematics, 3(4) :413–443.



Girvan, M. and Newman, M. E. J. (2002).

Community structure in social and biological networks.

Proceedings of the National Academy of Sciences of the United States of America, 99(12) :7821–7826.



Navarro, E., Chudy, Y., Gaume, B., Cabanac, G., and Pinel-Sauvagnat, K. (2011).

Kodex ou comment organiser les résultats d'une recherche d'information par détection de communautés sur un graphe biparti ?

In CORIA'11, Avignon, pages 25–40. ARIA.



Popescul, A. and Ungar, L. H. (2000).

Automatic labeling of document clusters.



Treeratpituk, P. and Callan, J. (2006).

Automatically labeling hierarchical clusters.

In Fortes, J. A. B. and Macintosh, A., editors, DG.O, volume 151 of ACM International Conference Proceeding Series, pages 167–176. Digital Government Research Center.



Tseng, Y.-H., Lin, C.-J., Chen, H.-H., and Lin, Y.-I. (2006).

Toward generic title generation for clustered documents.

In Ng, H., Leong, M.-K., Kan, M.-Y., and Ji, D., editors, Information Retrieval Technology, volume 4182 of Lecture Notes in Computer Science, pages 145–157. Springer Berlin / Heidelberg.