

Plan de la présentation

- Résumer par des modèles thématiques
 - Illustration sur plusieurs cas d'étude
 - Aller plus loin : cas des données temporelles
 - Conclusion et perspectives

Plan de la présentation

- Résumer par des modèles thématiques
 - Illustration sur plusieurs cas d'étude
 - Aller plus loin : cas des données temporelles
 - Conclusion et perspectives



THE HUFFINGTON POST

UNITED KINGDOM

Edition: UK [Search The Huffington Post](#) Likes: 632K Follow Follow Follow 424k

FRONT PAGE **NEWS** **POLITICS** **BUSINESS** **TECH** **YOUNG VOICES** **COMEDY** **ENTERTAINMENT** **CELEBRITY** **LIFESTYLE** **PARENTS** **BLOGS**

Politics • COP21 • Building Modern Men • What's Working • Environment • Media • Women • Impact • Entrepreneurs • Young Talent • Christmas • Smart Living

Google

Actualités Édition France Compacte

À la une

Tapie : «Le départ de Taubira est mauvais pour tout le monde»
Libération - il y a 57 minutes   

Bernard Tapie et Christiane Taubira avaient fait campagne commune aux élections européennes de 1992, partageant entre autre «le même caractère sur le départ de Taubira : "Résister, c'est se confronter à la réalité"». L'Express

Manuel Valls : «Christiane Taubira va manquer au gouvernement, mais...» Le Figaro

Voir Faitu en direct Les Echos BFM TV.COM BFM TV.COM

Visite de Rohani en France : premiers contrats pour PSA, la SNCF et Total
Le Parisien - il y a 11 minutes

INFOGRAPHIE. Zika, ce virus qui menace les bébés et débarque en Europe
L'Obs - il y a 1 heure

À son procès, Laurent Gbagbo plaide non coupable
Le Echos - il y a 1 heure

François Hollande va recevoir la famille de Jacqueline Sauvage à l'Élysée
Le Figaro - il y a 1 heure

De nouvelles menaces visent six lycées parisiens
Le Figaro - il y a 51 minutes

Recommandations »

Laurent Ruquier : "Si le Front national passe, je me tire"
leJDD.fr - il y a 5 heures

Fallait-il inviter Manuel Valls à On n'est pas couché? Deux semaines après, l'animateur de l'émission, Laurent Ruquier, répond dans une longue interview à ce qu'il a écrit. On n'est pas couché vous intéresse ? Oui | Non

Touche Pas à Mon Poste : Nabilla invitée par Cyril Hanouna, 3 ...
m6tv.fr - il y a 3 heures

Touche pas à mon poste ! vous intéresse ? Oui | Non

#journéedelalanguefrançaise

Top Direct Comptes Photos Vidéos Autres options

Suggestions · Actualiser · Tout afficher

Khalil (pilgrim) @sehnaoui Suivre Sponsored

Tom Kenter @TomKenter Suivi par Shirin Dori-Hacohen ... Suivre

Alberto Lumbreras @alberto... Suivi par Bertrand Jouve Suivre

Trouver des amis

Tendances · Modifier

#JournéeDeLaLangueFrançaise #BourdinDirect #SRFCOL #SOSPascal #BrunoFunRadio Lacazette Troyes Olivier Bourdeaut Albert Einstein Dany Laferrière

4 nouveaux résultats

NyTx @NyTxSw - 1 min #JournéeDeLaLangueFrançaise on va donc éviter tous ces horribles anglicismes qui tuent lentement notre langue.

servietsky @servietsky74 - 1 min il va falloir fermer twitter #JournéeDeLaLangueFrançaise

QUENTIN @Nitneug_ - 1 min POUAHHAHAH #JournéeDeLaLangueFrançaise

ben&jerry&ana @cgdornan - 1 min Pourquoi faire une journée pour cette langue si c'est pour la massacer avec une réforme par la suite? #JournéeDeLaLangueFrançaise

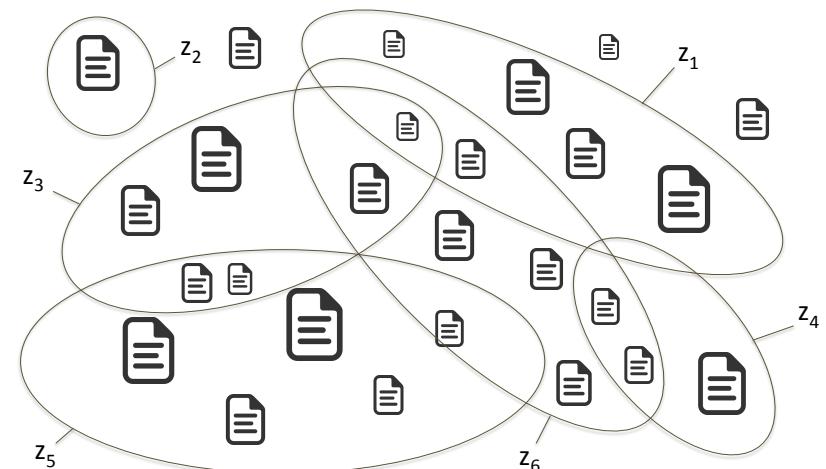
Moins gentil ligné @ParathorO - 2 min #JournéeDeLaLangueFrançaise zig

ben&jerry&ana @cgdornan - 3 min Si vous voulez honorer la langue française alors s'il vous plaît pas de "ognon" #JournéeDeLaLangueFrançaise

Apprendre les thématiques ?

- Les modèles de thématiques ont pour objectif d'organiser **automatiquement** de vastes collections de données textuelles
 - découvrir les thèmes qui « émergent »
 - indexer les documents à l'aide de ces thèmes
 - utiliser ces annotations pour résumer, naviguer, rechercher... donc mieux appréhender les données

Clustering vs. thématiques (Xie and Xing, 2013)

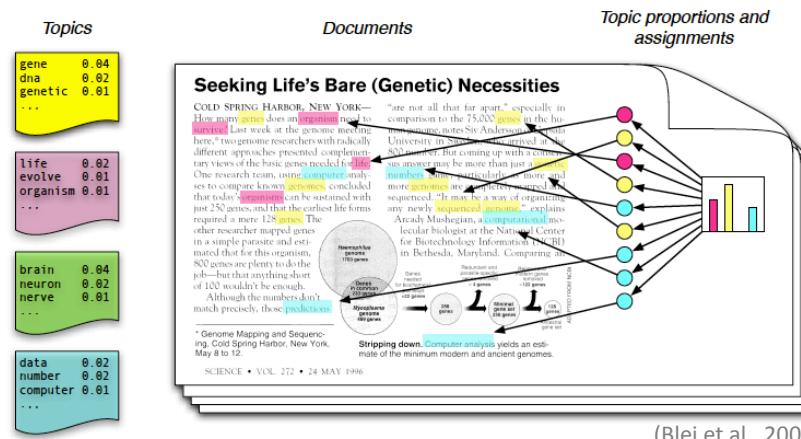


Eléments d'état de l'art

- Approches algébriques
 - LSA (Deerwester et al., 1990)
 - NMF (Paatero et Tapper, 1994)
 - apprentissage de dictionnaires (Jenatton et al., 2010)
- Approches géométriques
 - issus du TDT (Allan et al., 1998) (Pons-Porrata et al., 2003)
 - AGAPE (Velcin and Ganascia, 2007)
- Approches probabilistes
 - pLSA, LDA... (voir la suite de l'exposé)

9

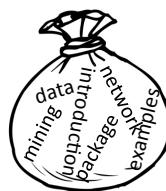
Modèle de thématiques : cas de LDA



10

Manipuler des données textuelles

- Hypothèse du sac de mots
- Etape de prétraitements :
 - suppression des « mots-outils »
 - suppression des marques de ponctuations
 - suppression des nombres
- En entrée :



Terms	Docs
data	1 1 0 0 2 0 0 0 0 0 1 2 1 1 1 0 1 0 0 0
examples	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1
introduction	0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1
mining	0 0 0 0 0 0 0 0 0 0 0 1 1 0 1 0 0 0 0 0
network	0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 1 1 1 0
package	0 0 0 1 1 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0

11

Plan de la présentation

- Résumer par des modèles thématiques
- **Illustration sur plusieurs cas d'étude**
- Aller plus loin : cas des données temporelles
- Conclusion et perspectives

Illustration avec quelques jeux de données (oui, qui ne sont pas tous libres...)

- Articles scientifiques
 - 20 Newsgroups
 - Série Harry Potter
- } en collaboration avec
P. Poncelet, M. Roche
et J.A. Lossio (LIRMM)
- en collaboration avec C. Gravier (LHC)

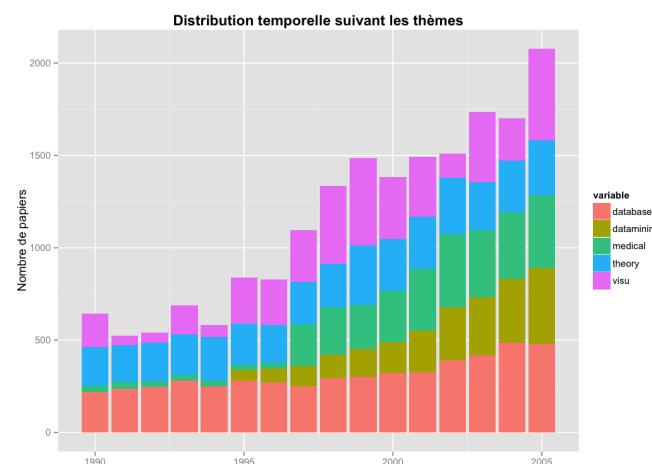
13

Articles scientifiques

- + de 18000 titres et/ou résumés d'articles publiés entre 1990 et 2005 (Tang et al., 2012)
 - base de données : ICDE, VLDB, SIGMOD...
 - data mining (après 1994) : KDD, ICDM...
 - visualisation : CVPR, InfoViz, ICCV...
 - informatique théorique : FOCS, SODA...
 - informatique médicale : JAMIA, AIME...

14

Evolution des thématiques



15

Thématiques extraites par LDA (vocabulaire de 5000 mots)

Ida 0 : data - query - queries - database - performance - xml - system - processing - systems - relational - paper - efficient - databases - algorithms - memory - techniques - access - results - storage - time - optimization - present - index - distributed - show - structure - operations - approach - model - join...

Ida 1 : algorithm - problem - time - algorithms - graph - show - number - problems - approximation - graphs - bound - lower - bounds - complexity - set - optimal - case - polynomial - random - log - constant - linear - results - size - result - network - general - present - tree - model...

Ida 2 : image - images - method - surface - motion - model - object - algorithm - visualization - paper - volume - approach - data - rendering - objects - shape - points - present - models - flow - results - methods - technique - segmentation - reconstruction - surfaces - recognition - point - tracking - structure...

Ida 3 : data - mining - algorithm - clustering - learning - paper - approach - classification - results - method - algorithms - methods - problem - patterns - large - set - model - sets - analysis - show - number - time - models - present - search - performance - detection - association - pattern - efficient...

Ida 4 : data - information - system - systems - research - database - paper - web - visualization - user - model - application - management - knowledge - applications - design - users - databases - medical - analysis - integration - semantic - support - technology - development - network - environment - issues - language - process...

16

Thématiques extraites par LDA (vocabulaire de 5000 ngrams, n>1)

Ida 0 : volume rendering - case study - research paper - vector fields - decision support - information technology - visualization techniques - a case study - volume data - vector field...

Ida 1 : data mining - time series - experimental results - knowledge discovery - machine learning - nearest neighbor - support vector - feature selection - decision tree - association rule...

Ida 2 : lower bound - lower bounds - polynomial time - approximation algorithms - extended abstract - approximation algorithm - running time - upper bound - competitive ratio - high probability...

Ida 3 : database systems - query processing - database system - query optimization - xml data - data management - query language - database management - management systems - relational database...

Ida 4 : experimental results - object recognition - computer vision - image sequences - optical flow - extended abstract - image segmentation - pattern matching - real images – motion estimation (...) a new approach...

17

20 NewsGroups

- 20 000 textes répartis dans 20 catégories
<http://qwone.com/~jason/20Newsgroups/>

comp.graphics	rec.autos	sci.crypt
comp.os.ms-windows.misc	rec.motorcycles	sci.electronics
comp.sys.ibm.pc.hardware	rec.sport.baseball	sci.med
comp.sys.mac.hardware	rec.sport.hockey	sci.space
comp.windows.x		
misc.forsale	talk.politics.misc	talk.religion.misc
	talk.politics.guns	alt.atheism
	talk.politics.mideast	soc.religion.christian

18

From: ahlenius@rtsg.mot.com (Mark Ahlenius)
Subject: converting color gif to X pixmap

I have looked through the FAQ sections and have not seen a answer for this.

I have an X/Motif application that I have written. I have a couple of gif files (or pict) that I have scanned in with a color scanner. Now I would like to be able to convert the gif files into a format that could be read into my application and displayed on the background of its main window. Preferably with pixmaps, or perhaps as an XImage.

I have found functions in the pbmplus program suite to convert gif to xbm, but that is monochrome, and I really do need color.

I have looked at xv, which reads in gif, and writes out several formats, but have not found a way to write out a file which can be read in as a pixmap.

Is there an easy way to do this?

catégorie :
comp.windows.x

19

From: leech@cs.unc.edu (Jon Leech)
Subject: Space FAQ 15/15 - Orbital and Planetary Launch Services

Archive-name: space/launchers
Last-modified: \$Date: 93/04/01 14:39:11 \$

ORBITAL AND PLANETARY LAUNCH SERVICES

catégorie :
sci.space

The following data comes from _International Reference Guide to Space Launch Systems_ by Steven J. Isakowitz, 1991 edition.

Notes:

- * Unless otherwise specified, LEO and polar payloads are for a 100 nm orbit.
- * Reliability data includes launches through Dec, 1990. Reliability for a family of vehicles includes launches by types no longer built when applicable
- * Prices are in millions of 1990 \$US and are subject to change.
- * Only operational vehicle families are included. Individual vehicles which have not yet flown are marked by an asterisk (*) If a vehicle had first launch after publication of my data, it may still be marked with an asterisk.

20

Vehicle (nation)	Payload kg (lbs)	Reliability	Price	Launch Site (Lat. & Long.)
	LEO	Polar	GTO	

Ariane (ESA)	35/40	87.5%	Kourou	
AR40	4,900	3,900	1,900	1/1 \$65m (10,800) (8,580) (4,190)
AR42P	6,100	4,800	2,600	1/1 \$67m (13,400) (10,600) (5,730)
AR44P	6,900	5,500	3,000	0/0 ? \$70m (15,200) (12,100) (6,610)
AR42L	7,400	5,900	3,200	0/0 ? \$90m (16,300) (13,000) (7,050)
AR44LP	8,300	6,600	3,700	6/6 \$95m (18,300) (14,500) (8,160)
AR44L	9,600	7,700	4,200	3/4 \$115m (21,100) (16,900) (9,260)
* AR5	18,000	???	6,800	0/0 \$105m (39,600) (15,000) [300nm]

catégorie :
sci.space
(suite)

21

Thématiques extraites par LDA (vocabulaire de 10000 mots)

Extrait des 20 thématiques demandées :

Ida 5 : window - file - program - server - set - motif - widget - application - problem - entry - display - code - sun - error - xterm - manager - running - work - subject - open - make - line - openwindows - number - size - x11r5 - function - run - version - client...

Ida 6 : image - file - jpeg - images - format - color - files - gif - program - display - version - bit - printer - convert - quality - programs - software - screen - formats - xv - good - colors - print - graphics - free - article - windows - postscript - tiff - fonts...

Ida 18 : god - jesus - church - bible - christ - christian - people - christians - sin - lord - faith - love - life - man - paul - word - law - time - article - good - heaven - hell - father - christianity - john - homosexuality - spirit - scripture - holy - things...

Ida 19 : space - nasa - launch - earth - article - orbit - shuttle - moon - mission - system - satellite - solar - time - spacecraft - data - years - lunar - station - flight - sky - cost - mars - project - venus - high - pat - surface - planet - program - henry...

22

Et dans Harry Potter

extrait sur
20 thématiques :

Maisons de sorcellerie

house 0.04657586
gryffindor 0.04424846
points 0.03416309
slytherin 0.03261149
hundred 0.02252612
hat 0.02175032
will 0.02097452
cup 0.01554393
hufflepuff 0.01399234
taken 0.01321654

Quidditch

wood 0.04386071
quidditch 0.03491612
team 0.02060479
quaffle 0.01702696
snitch 0.01613250
game 0.01523804
catch 0.01344912
play 0.01255466
flint 0.01255466
seeker 0.01166021

Famille Weasley

weasley 0.04050274
percy 0.03038466
fred 0.02869831
george 0.02448244
twins 0.01942340
year 0.01858022

Professeurs de Poudlard

professor 0.141749006
mcgonagall 0.074869763
dumbledore 0.035060689
quirrell 0.022321786
flitwick 0.015952334
turban 0.011175245
reached 0.007990520
teacher 0.007990520
dumbledore's 0.007194338
talking 0.007194338

4, Private Drive

uncle 0.065995844
dudley 0.062179040
vernon 0.057271720
aunt 0.035461411
petunia 0.031099349
letter 0.018013164
dudley's 0.012560586
room 0.012015328
cupboard 0.012015328

Mais aussi...

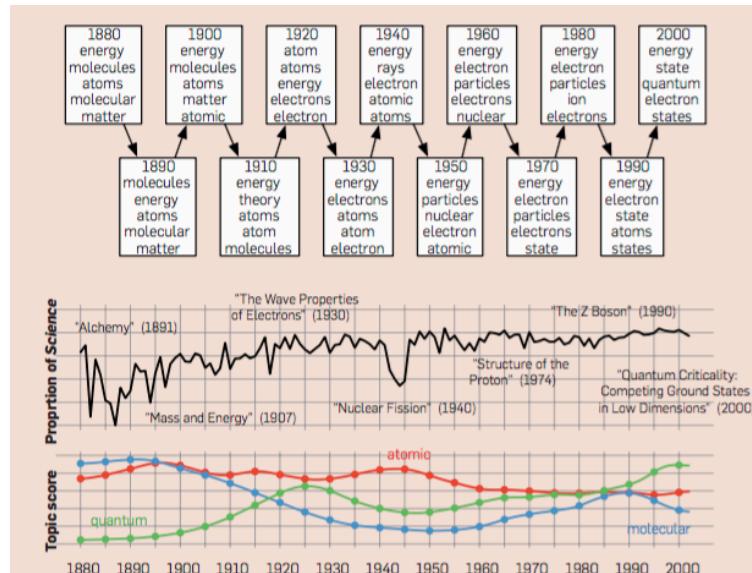
looked 0.03222237	hagrid 0.06322251
like 0.02515218	yeh 0.06136366
eyes 0.02122431	ter 0.04835173
long 0.02122431	yer 0.03719865
little 0.01886758	said 0.02170826
black 0.01886758	dragon 0.01861018
see 0.01877648	fer 0.01799056
something 0.01862983	gringotts 0.01737095
think 0.01804323	got 0.01675133
now 0.01730997	don 0.01613172
going 0.01716332	
well 0.01511021	
harry 0.07567148	
one 0.03453437	door 0.03846168
first 0.02718846	open 0.02367537
time 0.01739391	cloak 0.02121098
much 0.01616959	looking 0.01874660
next 0.01543500	two 0.01874660
never 0.01494527	floor 0.01677509
day 0.01298636	forward 0.01677509

23

24

Plan de la présentation

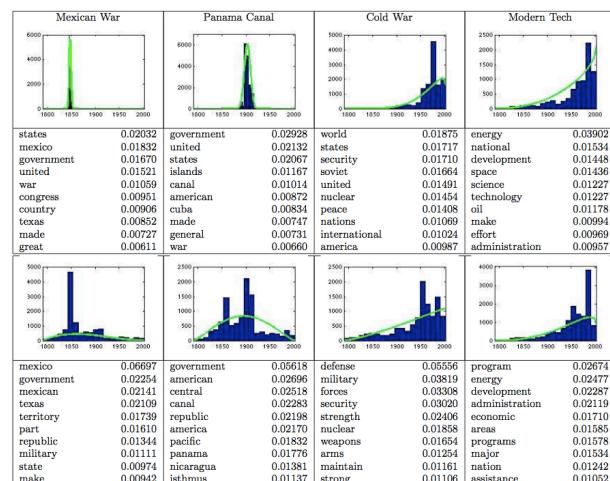
- Résumer par des modèles thématiques
 - Illustration sur plusieurs cas d'étude
 - **Aller plus loin : cas des données temporelles**
 - Conclusion et perspectives



données tirées de *Science* entre 1880 et 2002 (Blei, 2012)

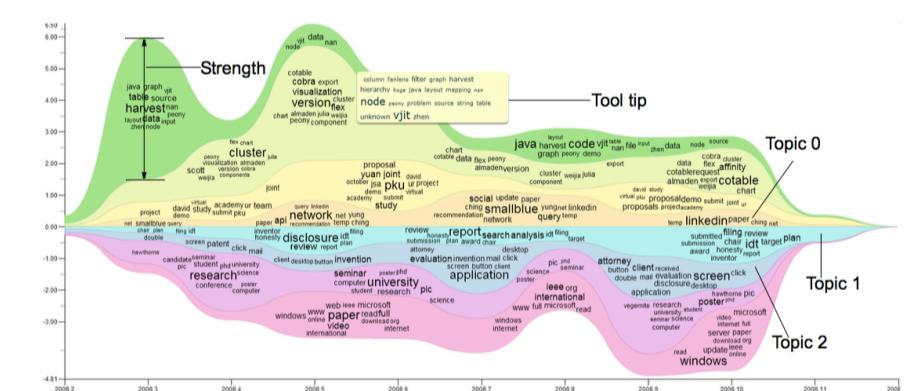
26

Résultats sur le discours de l'union



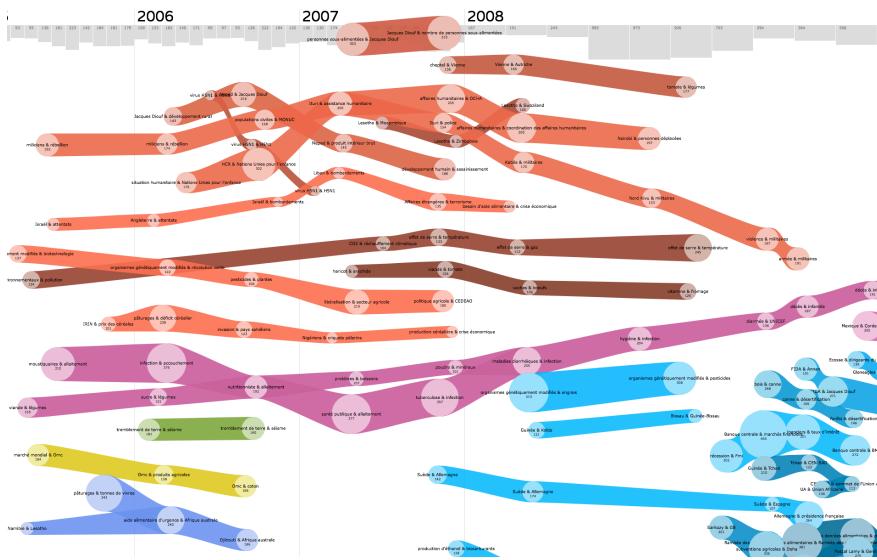
27

Dynamique des thématiques



TIARA (Liu et al., 2009) (Wei et al., 2010)

28



Projet Pulseweb : <http://pulseweb.cortex.net>

Plan de la présentation

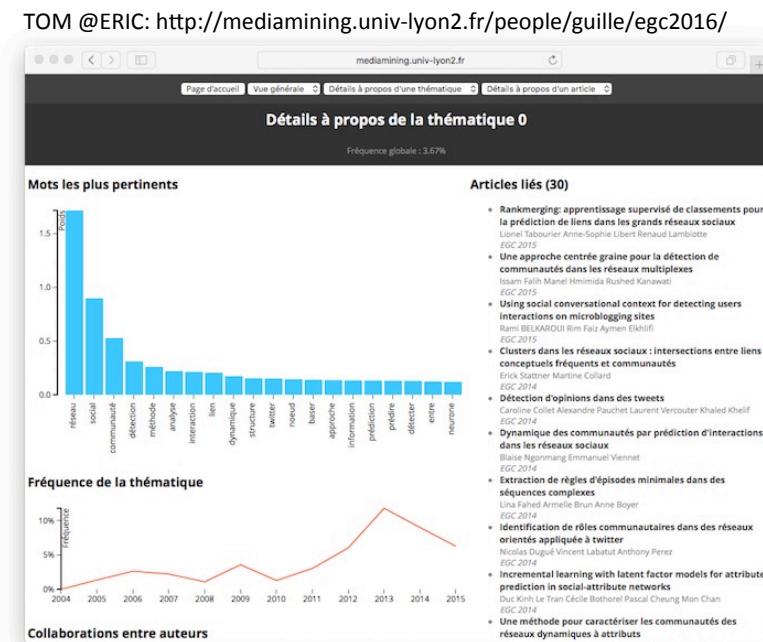
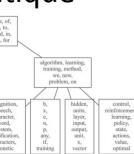
- Résumer par des modèles thématiques
 - Illustration sur plusieurs cas d'étude
 - Aller plus loin : cas des données temporelles
 - **Conclusion et perspectives**

Quelques questions intéressantes

- Trouver le « meilleur » nombre de thématiques
HDP (Teh et al., 2004)
 - Résumer l'information portée par une thématique
Topic labeling (Mei et al., 2007)
 - Trouver une structure entre les thématiques
hLDA (Griffiths et al., 2004) CTM (Blei et al., 2006)
 - Combiner les thématiques avec d'autres informations : auteur, opinion, structure, etc.
Author-Topic (Rosen-Zvi et al., 2006)
Topic-Opinion (Dermouche et al., 2014) (et tant d'autres...)
 - Liens avec le « plongement de mots » (Das et al., 2015)

```

graph TD
    TL[Topic labeling] --> TS[Topic structure]
    TL --> TD[Topic distribution]
    TS --> T[Topics]
    TS --> TH[Hierarchical topic modeling]
    TD --> LD[Latent Dirichlet Allocation]
    T --> TM[Topic modeling]
    T --> TH2[Hierarchical topic modeling]
    TM --> TM2[Topic modeling]
    TM --> TH3[Hierarchical topic modeling]
    TH2 --> HDP[Hierarchical Dirichlet Process]
    TH3 --> HLDA[Hierarchical Latent Dirichlet Allocation]
    LD --> LD2[Latent Dirichlet Allocation]
    LD2 --> LD3[Hierarchical Latent Dirichlet Allocation]
  
```



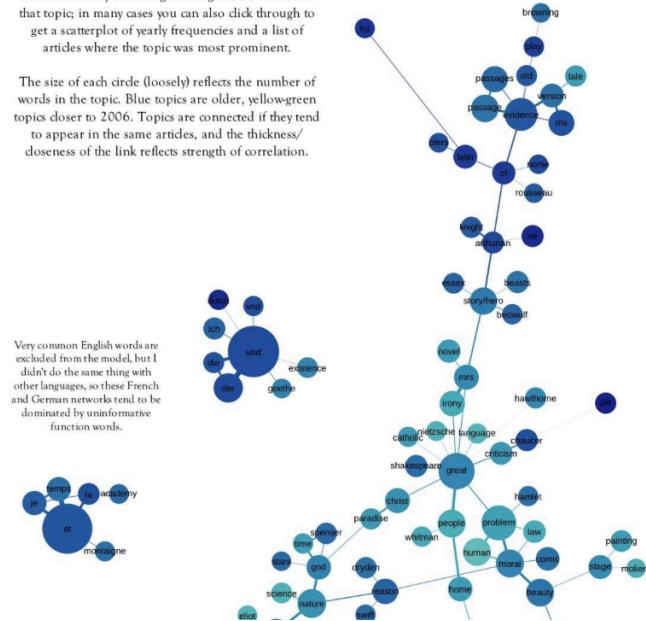
Références orientées DH

- Blei, D.M., A.Y. Ng and M. I. Jordan (2003). Latent dirichlet allocation. *Journal of Machine Learning Research*, 3: pp. 993–1022.
- Burton M. (2013). The Joy of Topic Modeling: A bag of words. <http://mcburton.net/blog/joy-of-tm>
- Goldstone A. and T. Underwood (2012). What Can Topic Models of PMLA Teach Us About the History of Literary Scholarship? <http://journalofdigitalhumanities.org/2-1/what-can-topic-models-of-pmla-teach-us-by-ted-underwood-and-andrew-goldstone>
- Graham S. et al. (2012). Getting Started with Topic Modeling and MALLET. Online lesson. <http://programminghistorian.org/lessons/topic-modeling-and-mallet>
- Weingart, S. (2012). Topic Modeling for Humanists: A Guided Tour. <http://www.scottbot.net/HIAL/?p=19113>

33

Underwood's model of PMLA 1924-2006.
Mouse over any circle to get a longer list of words in that topic; in many cases you can also click through to get a scatterplot of yearly frequencies and a list of articles where the topic was most prominent.

The size of each circle (loosely) reflects the number of words in the topic. Blue topics are older, yellow-green topics closer to 2006. Topics are connected if they tend to appear in the same articles, and the thickness/doseness of the link reflects strength of correlation.



The window may have to be full width for click-through to work.

<http://journalofdigitalhumanities.org/2-1/what-can-topic-models-of-pmla-teach-us-by-ted-underwood-and-andrew-goldstone>

34