

Chantier d'usage: NeoTEX

B. Audeh, M. Beigbeder, C. Largeron

Laboratoire Hubert Curien

7 juin 2017



- Bissan Audeh, post-doctorante 10 mois
 - septembre 2016–juin 2017
- Michel Beigbeder
 - École des mines de Saint-Étienne, Laboratoire Hubert Curien
- Christine Largeron
 - Université de Saint-Étienne, Laboratoire Hubert Curien
- Ayman Alazizi, stagiaire Master 2
 - avril–août 2016
- Diana Ramirez, stagiaire Master 2
 - février–juin 2017

Exploration de documents Textuels d'un domaine par un Néophyte

Recommandation/**recherche** de documents pour l'initiation d'une recherche. Le néophyte

- ne connaît pas les mots-clés du domaine
- ne connaît pas les experts du domaine
- **ne connaît pas les articles de référence**

- Concevoir, implémenter, tester un cadre de travail et des modèles de recherche orientés vers les besoins d'un néophyte
- Défis
 - ① définir les besoins d'un néophyte
 - qu'est-ce qui est pertinent pour un néophyte?
 - ② concevoir des modèles qui retrouvent les documents pertinents au sens de 1.
 - ③ tester
 - construire des vérités terrains
 - obtenir les données

- panorama des bibliothèques numériques (BN)
- état de l'art
- le système NeoTEX
- les vérités terrains
- la construction du graphe de citation
- les modèles
- les expériences

- collecter les documents
- mettre à disposition des documents
- gérer les droits
- gérer les usages
- numériser
- archiver, préserver
- *créer des méta-information*
- *rechercher*
- *recommander*
- naviguer

- Recherche sur les méta-information
 - auteur, titre, journal, date, ISSN, ISBN, etc.
 - recherche orientée vers ce que l'on connaît
- plus récemment aussi sur le résumé ou sur le texte intégral

Comparaison de quelques BN académiques (1/2): données

		données de rech.	références	citations
Google Scholar	universelle	texte intégral	références	citations
Microsoft Academic	universelle	texte intégral	références	citations
CiteseerX	informatique	texte intégral	références	citations
ACM DL	informatique	texte intégral	références	citations
dblp	informatique	méta-informations	—	—
Web of Science	universelle	méta-informations	références	citations

Vocabulaire:

- **références:** liens **sortants**
- **citations:** liens **entrants**

Comparaison de quelques BN académiques (2/2): services

		tri	présentation
Google Scholar	par champ	pert.	date
Microsoft Academic	±	pert.	date cit.
CiteseerX	par champ	pert.	date cit.
ACM DL	par champ	pert.	date cit. usage
dblp	par champ	date	
Web of Science	par champ	date cit. usage	auteur venue

liens cliquables

raffinements

accès aux contenus, versions

informations sur les auteurs

citations, références, co-citations, regroupements

panier, profil

The screenshot shows a Google Scholar search results page. The search query 'digital libraries record linkage' has returned approximately 47,700 results in 0.10 seconds. The results are displayed in a grid format with three columns: title, abstract, and links. The sidebar on the left contains filters for 'Articles', 'Ma bibliothèque', 'Date indifférente', 'Depuis 2017', 'Depuis 2016', 'Depuis 2013', 'Période spécifique...', 'Trier par pertinence', 'Trier par date', 'Toutes les langues', 'Rechercher les pages en Français', and checkboxes for 'inclure les brevets', 'inclure les citations', and 'Créer l'alerte'. A 'Mes citations' button is also present.

digital libraries record linkage

Scholar Environ 47 700 résultats (0,10 s) Mes citations

Articles Conseil : Recherchez des résultats uniquement en **Français**. Vous pouvez indiquer votre langue de recherche sur la page [Paramètres Google Scholar](#).

Adaptive sorted neighborhood methods for efficient record linkage [PDF] nus.edu
S Yan, D Lee, MY Kan, LC Giles - ... CS joint conference on [Digital libraries](#), 2007 - dl.acm.org
Abstract Traditionally, **record linkage** algorithms have played an important role in maintaining **digital libraries**-ie, identifying matching citations or authors for consolidation in updating or integrating **digital libraries**. As such, a variety of **record linkage** algorithms have Cité 113 fois Autres articles Les 27 versions Citer Enregistrer

Effective and scalable solutions for mixed and split citation problems in digital libraries [PDF] psu.edu
D Lee, BW On, J Kang, S Park - ... of the 2nd international workshop on ..., 2005 - dl.acm.org
... Researchers also use the citation **records** in order to measure the publication's impact in the research community. ... [17] in the **record linkage** literature. ... using data mining or heuristics techniques, but do not consider the issue of scalability nor in the context of **digital libraries**. ... Cité 90 fois Autres articles Les 15 versions Citer Enregistrer

Are your citations clean? [HTML] acm.org
D Lee, J Kang, P Mitra, CL Giles, BW On - Communications of the ACM, 2007 - dl.acm.org
... about 356 known DLs had been developed through the National Science Foundation's National Science **Digital Library** program (as ... 3. Fellegi, I. and Sunter, A. A theory for **record linkage**. ... In Proceedings of the ACM Conference on **Digital Libraries** (Pittsburgh, PA, 1998), 89–98. ... Cité 78 fois Autres articles Les 19 versions Citer Enregistrer

Digital preservation: a time bomb for digital libraries [PDF] umich.edu
M Hedstrom - Computers and the Humanities, 1997 - Springer
... Most archivists and **librarians** accept the fact that we live in a hybrid environment where ... chance that we will see the mass conversion of existing archival and **library** holdings to ... A fourth area for research is the development of management tools for **digital libraries** and archives ... Cité 284 fois Autres articles Les 21 versions Citer Enregistrer

Microsoft Academic Preview Microsoft Academic 2.0

digital libraries record linkage

1-3 of 3 results for *digital libraries record linkage* (0.3 seconds) Sort by: Relevance

Date Range 2005 to 2006

Author
 Dongwon Lee
 Min-Yen Kan
 C.L. Giles
 Su Yan
 David Hawking
[See more](#)

Affiliation
 Pennsylvania State University
 National University of Singapore
 Australian National University
 Commonwealth Scientific and Industrial Research Organisation
 Veda
[See more](#)

Field Of Study
 Computer Science
 Digital library
 World Wide Web
 Record linkage
 Data mining
[See more](#)

Journal
 Program: Electronic Library and Information Systems

Adaptive sorted neighborhood methods for efficient record linkage
2007, *ACM/IEEE Joint Conference on Digital Libraries*
Su Yan (*Pennsylvania State University*), Dongwon Lee (*Pennsylvania State University*), Min-Yen Kan (*National University of Singapore*), C.L. Giles (*Pennsylvania State University*)

Traditionally, **record linkage** algorithms have played an important role in maintaining digital libraries - i.e., identifying matching citations or authors for consolidation in updating or integrating digital libraries. As such,...

Fields of Study: name resolution, **record linkage**, sliding window protocol, ...

Source Cited 113 times*

Similarity-aware indexing for real-time entity resolution
2009, *Conference on Information and Knowledge Management*
Peter Christen (*Australian National University*), Ross W. Gayler (*Veda*), David Hawking (*Commonwealth Scientific and Industrial Research Organisation*)

Entity resolution, also known as data matching or **record linkage**, is the task of identifying and matching records from several databases that refer to the same entities. Traditionally, entity resolution...

Fields of Study: name resolution, approximate string matching, **record linkage**, ...

Source Cited 21 times*

digital library

A digital library is a special library with a focused collection of digital objects that can include text, visual material, audio material, video material, stored as electronic media formats (as opposed to print, microform, or other media), along with means for organizing, storing, and retrieving the files and media contained in the library collection. Digital libraries can vary immensely in size and scope, and can be maintained by individuals, organizations, or affiliated with established physical library buildings or institutions, or with academic institutions. The digital content may be stored locally, or accessed remotely via computer networks. An electronic library is a type of information retrieval system.

Source: en.wikipedia.org
[View on Bing](#)

Subdiscipline of: World Wide Web

Subfields: Library Classification, Very Large Database, Id3, Library Catalog, Digital Asset Management, Accession Number, International Standard Bibliographic Description, Film

[Feedback](#)

CiteSeerX — Search Result... +

Documents Authors Tables

Rechercher

Donate MetaCart Sign up Log In

CiteSeer^X 10M

digital libraries record linkage Include Citations Advanced Search

Results 1 - 10 of 275 935 Next 10 →

SIMPlicity: Semantics-Sensitive Integrated Matching for Picture Libraries
by James Z. Wang, Jia Li, Gio Wiederhold - *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001
"... The need for efficient content-based image retrieval has increased tremendously in many application areas such as biomedicine, military, commerce, education, and Web image classification and searching. We present here SIMPLICITY (Semanticssensitive Integrated Matching for Picture Libraries), an Imag ..."
Abstract - Cited by 541 (35 self) - Add to MetaCart

The Digital Michelangelo Project: 3D Scanning of Large Statues
by Marc Levoy, Szymon Rusinkiewicz, Brian Curless, Matt Ginzton, Jeremy Ginsberg, Kari Pulli, David Koller, Sean Anderson, Jonathan Shade, Lucas Pereira, James Davis, Duane Fulk, 2000
"... We describe a hardware and software system for digitizing the shape and color of large fragile objects under non-laboratory conditions. Our system employs laser triangulation rangefinders, laser time-of-flight rangefinders, digital still cameras, and a suite of software for acquiring, aligning, merg ..."
Abstract - Cited by 488 (8 self) - Add to MetaCart

Dynamic topic models
by David M. Blei, John D. Lafferty - *In ICML*, 2006
"... Scientists need new tools to explore and browse large collections of scholarly literature. Thanks to organizations such as JSTOR, which scan and index the original bound archives of many journals, modern scientists can search digital libraries spanning hundreds of years. A scientist, suddenly ..."
Abstract - Cited by 656 (28 self) - Add to MetaCart

Sketchpad: A man-machine graphical communication system
by Ivan Edward Sutherland , 2003

Q simplici Tout surigner Respecter la casse Occurrence 2 sur 2

Tools

Sorted by: Relevance

Try your query at:

Alt2 Google Scholar Microsoft Academic Search

Google Scholar Microsoft Academic Search

Results ACM DL : digital li... [+/-](#)

dl.acm.org/results.cfm?query=digital+libraries+record+linkage&Go.x=0&t=1 Rechercher SIGN IN SIGN UP

ACM DL DIGITAL LIBRARY

digital libraries record linkage [SEARCH](#)

Searched for *digital libraries record linkage* [new search] [edit/save query]

[advanced search]

Searched The ACM Full-Text Collection: 468,529 records [Expand your search to The ACM Guide to Computing Literature: 2,676,172 records] [?](#)

50,328 results found Export Results: bibtex | endnote | acmref | csv

Refine by People

- Names [»](#)
- Institutions [»](#)
- Authors [»](#)
- Editors [»](#)
- Advisors [»](#)
- Reviewers [»](#)

Refine by Publications

- Publication Names [»](#)
- ACM Publications [»](#)
- All Publications [»](#)
- Content Formats [»](#)
- Publishers [»](#)

Refine by Conferences

- Sponsors [»](#)
- Events [»](#)
- Proceeding Series [»](#)

Refine by Publication Year

Published Since 1951

Upcoming Conferences

ICMR '17
June 06 - 09, 2017
Bucharest, Romania

Result 1 – 20 of 50,328

Result page: 1 2 3 4 5 6 7 8 9 10 >>
Sort by: relevance

1 [Digital liaisons: engaging with digital curation theory and practice](#)
[SIG Digital Libraries](#)
November 2013 ASIST '13: Proceedings of the 76th ASIS&T Annual Meeting: Beyond the Cloud: Rethinking Information Boundaries
Publisher: American Society for Information Science
Bibliometrics: Citation Count: 0
Downloads (6 Weeks): 38, Downloads (12 Months): 324, Downloads (Overall): 455
Full text available: [PDF](#)
As librarians and information professionals are increasingly tasked with curating and making accessible digital materials, new information professionals must enter the workforce armed with the appropriate skills. New professionals must know both the theoretical underpinnings of digital curation and how to put those theories into practice in real life applications. ...
Keywords: student research, master's students, students, undergraduate students
[result highlights]

2 [The Stanford Digital Library Project](#)
[CORPORATE The Stanford Digital Libraries Group](#)
April 1995 Communications of the ACM: Volume 38 Issue 4, April 1995
Publisher: ACM
Bibliometrics: Citation Count: 9
Downloads (6 Weeks): 30, Downloads (12 Months): 173, Downloads (Overall): 749
Full text available: [PDF](#)
The Stanford Integrated Digital Library Project will develop enabling technologies for an integrated "virtual" library to provide an array of new services and uniform access to networked information collections. The Integrated Digital Library will create a shared environment linking everything from personal information collections, to collections of conventional libraries, to ...
[result highlights]

3 [An Instrument for Merging of Bibliographic Databases](#)

Feedback

dblp: Search for "record li... +

dblp.uni-trier.de/search?q=record link Rechercher

maintained by SCHLOSS DAGSTUHL at Universität Trier home | browse | search | about

 dblp
computer science bibliography

[+] Search dblp [?]

[-] powered by CompleteSearch, courtesy of Hannah Bast, University of Freiburg

> Home

[+] Publication search results [?]

found 338 matches

2017

- Shumin Han, Derong Shen, Tiezheng Nie, Yue Kou, Ge Yu:
Private Blocking Technique for Multi-party Privacy-Preserving Record Linkage. Data Science and Engineering 2(2): 187-196 (2017)
- David D. Dobrzykowski, Monideepa Tarafdar:
Linking Electronic Medical Records Use to Physicians' Performance: A Contextual Analysis. Decision Sciences 48(1): 7-38 (2017)
- April F. Mohanty, Jacob Crook, Christina A. Porucznik, Erin M. Johnson, Robert T. Rolfs, Brian C. Sauer:
Development and evaluation of a record linkage protocol for Utah's Controlled Substance Database. Health Informatics Journal 23(1): 35-43 (2017)
- Christian Geier, Klaus Lehnertz:
Which Brain Regions are Important for Seizure Dynamics in Epileptic Networks? Influence of Link Identification and EEG Recording Montage on Node Centralities. Int. J. Neural Syst. 27(1): 1-14 (2017)
- Dimitris A. Pinotsis, J. P. Geerts, L. Pinto, Thomas H. B. FitzGerald, Vladimir Litvak, Ryszard Aukstulewicz, Karl J. Friston:
Linking canonical microcircuits and neuronal activity: Dynamic causal modelling of laminar

[?] Refine list

refine by author

- Peter Christen (32)
- Vassilios S. Verykios (21)
- Dinusha Vatsalan (15)
- Vicenç Torra (11)
- Dimitrios Karapiperis (8)
- Murat Kantarcıoglu (8)
- Divesh Srivastava (7)
- Bradley Malin (7)
- Alexandros Karakasidis (6)
- Josep Domingo-Ferrer (6)
- 736 more options

refine by venue

- AMIA (17)
- JAMIA (16)
- History and Computing (11)
- BMC Med. Inf. & Decision Making (10)
- CoRR (10)
- ICDE (7)
- PAKDD (7)
- Privacy in Statistical Databases (7)

État de l'art

Retour sur les besoins du néophyte:

- il ne connaît pas les articles de référence sur le domaine
- « domaine »: recherche d'information thématique
- « de référence »: utilisation des liens
 - de citations [Salton, 1963]
 - de co-autorat, co-citations [Beel, 2016]
 - composantes relationnelles dans les calculs de score
 - recommandation: basée sur les usages
 - travail proche [Raamkumar, 2017]

- Évaluation en recherche d'information
 - disponibilité de données
 - disponibilité des logiciels des méthodes à comparer
 - ◊ en particulier pour les modèles de référence
 - mesures d'évaluation
 - campagnes d'évaluation
 - ◊ besoins d'information (requêtes) et jugements de pertinence
 - ◊ pas disponible ni pour NeoTEX, ni plus généralement pour les BN

Conclusion de l'état de l'art


Objectifs	BN	travaux académiques
Besoins des néophytes	non	non
Utilisation de données relationnelles	oui	oui
Évaluation	?	pas de collection de test

- **Contributions:**


- création de vérités terrains
- construction de modèles de référence

Système NeoTEX

Modèle de RI



Système NeoTEX



- nœuds
 - les documents ISTEK
 - les documents cités par les documents ISTEK
- arcs: lien (citations, références)
- **Contribution:** unification des nœuds
 - documents citants (ISTEK): identifiant ISTEK, métainformations
 - documents cités: métainformations bruitées


- degré entrant: S_I
- degré sortant: S_O
- PageRank: S_{PR}
- en perspective: d'autres mesures de centralité

- liste L des 1000 premiers documents classés selon leur score de contenu (S_c)
- les listes reclassées selon tel ou tel score (S_I , S_O ou S_{PR})
- les listes agrégées
- **Contribution:** les listes basées sur l'apprentissage automatique

Contributions

- les besoins d'information et les requêtes
 - issues de 25 thèses en Informatique soutenues en 2006
 - requêtes construites manuellement à partir des titres, résumés, et mots-clés des thèses
- les vérités terrains (les jugements de pertinence)
 - **thèses** la section « références » des 25 thèses
 - **manuel** jugement d'un expert
 - **réputation** nombre de citations en 2016
 - **thèses** \cup **réputation**

- Construction du graphe
- Les modèles, en particulier ceux qui utilisent de l'apprentissage
- Les expériences et leurs résultats



Construction du graphe: les données

Extrait des données téléchargées au format Json:

```
{  
    "corpusName": "elsevier",  
    "author": ...  
    "title": "Nuclear antigens in the HeLa cell cycle" ...  
    "refBibs": [  
        "title": "Multiplicaiton and division in Mammalian Cells",  
        ...  
    ]  
}  
...  
{  
    ...  
    "title": "Multiplication and Division in Mammalian Cells",  
    ...  
}  
...
```

7 316 816 titres citants

117 946 803 titres cités

125 263 619 titres

Volume de données: 9,6 Gio (1950–2005, titre de plus de 6

- 0 000 000 100 0 source world christian trends demographic futures for chris
- 1 000 000 clinical perspectives 593 adults with cystic fibrosis meeting the
- 2 000 000 miles of fluid evaluation in city bus automatic transmission
- ... [...]
- 3 486 0956 a study of the conditions and mechanisms of the diphenylamine reacti
- ... [...]
- 108 310 1956 a study of the conditions and mechanism of the diphenylamine reactio
- ... [...]
- 108 313 1956 a study of the mechanism of the diphenylamine reaction for the color
- ... [...]
- 46 852 687 zzzv and aaaa2 v a decade later he spoke of ashmole as my honoured friend


Le but: reconnaître les titres qui se ressemblent

- une première étape, de complexité linéaire ($O(n)$)
 - normaliser
 - c'est-à-dire remplacer les caractères non alphanumériques par des espaces, conversions en minuscules, compactage des espaces
- une deuxième étape, de complexité pseudo-linéaire ($O(n \log n)$)
 - pour trouver les dupliсats exacts
 - résultat: 46 852 688 titres normalisés uniques
- une troisième étape, de complexité quadratique ($O(n^2)$)
 - comparer chaque paire selon une similarité (Jaccard, Levenshtein, etc.)
 - temps à raison de 20–30 μs la comparaison: **un millénaire**
- et choisir un seuil de similarité

Histogramme similarité de Jaccard: échantillon aléatoire


Histogramme de similarité de Jaccard sur un échantillon de 1 milliard de paires tirées au hasard

850 millions entre 0 et 1/100, et 100 millions entre 1/100 et 2/100




Histogramme similarité de Jaccard ≥ 0.1 : échantillon aléatoire

Zoom de l'histogramme de similarité de Jaccard avec $s \geq 1/10$



Histogramme similarité de Jaccard ≥ 0.3 : échantillon aléatoire

Zoom de l'histogramme de similarité de Jaccard avec $s \geq 3/10$



Le *hashage sensible à la localité*: *Locality sensitive hashing*

[1998-ACM Th. of computing-Indyk Motwani]

[1999-VLDB-Gionis Indyk Motwani]


- prendre r « extraits » des objets à comparer
- si ces r « extraits » sont les mêmes (*hashage classique*) pour deux objets, c'est un indice qu'ils sont peut-être proches et il faudra les comparer
- le faire b fois (*bande*)
- les « extraits » doivent être choisis en cohérence avec une mesure de similarité
- pour la similarité de Jaccard: le *hashage par minimum (Min Hashing)*

[1998-ACM Th. of computing-Broder Charikar Frieze Mitzenmacher]

- probabilité que deux objets de similarité x partagent leurs r « extraits » dans au moins une des b bandes:


$$1 - (1 - x^r)^b$$

Choix du nombre de bandes b et de lignes par bande r




Histogramme similarité de Jaccard: échantillon LSH

Histogramme de similarité de Jaccard sur les paires sélectionnées par le *hashage sensible à la localité*.




Histogramme similarité de Jaccard: interpolation de l'échantillon LSH

Histogramme de similarité de Jaccard sur l'interpolation à partir des paires sélectionnées par le *hashage sensible à la localité*.




Histogramme similarité de Jaccard ≥ 0.1 : interpolation de l'échantillon LSH

Histogramme de similarité de Jaccard sur l'interpolation à partir des paires sélectionnées par le *hashage sensible à la localité*.



Histogramme similarité de Jaccard ≥ 0.4 : interpolation de l'échantillon LSH

Histogramme de similarité de Jaccard sur l'interpolation à partir des paires sélectionnées par le *hashage sensible à la localité*.



- seuillage: ne sont conservées parmi les paires candidates que celles de similarité supérieure au seuil choisi (0,85 dans notre expérience)
- recherche des composantes connexes pour obtenir une partition ce qui peut amener à mettre dans un même sous-ensemble deux éléments qui ont une similarité de Jaccard inférieure au seuil choisi.

Effectif	taille de la composante connexe
3 522 922	2
1 236 552	3
576 094	4
309 439	5
181 799	6
114 913	7
76 098	8
52 425	9
37 719	10
...	...

Effectif	taille de la composante connexe
...	...
1	647
1	709
1	728
1	818
1	880
1	933
1	981
1	1 394
1	2 077

Un extrait d'une composante connexe

Dd8c: 0951 protein measurement with the folin phenol reagent
D12f7914: i951 protein measurement with the folin phenol reagent
D153df04: i protein measurement with the folin phenol reagent
D1e9c0d4: protein measurement with the folin protein phenol reagent
D1e9d686: protein protein measurement with the folin phenol reagent
D405429: a protein measurement with the folin phenol reagent
D12fac0d: i a all protein measurement with the folin phenol reagent
D154347c: i rotein measurement with the folin phenol reagent
D159a4b0: j protein measurement with the folin phenol reagent
D171334d: l protein measurement with the folin phenol reagent
D1e99d7a: protein in measurement with the folin phenol reagent
D1e9bdec: protein measuremennt with the folin phenol reagent
D1e9be32: protein measurement reagent with the folin phenol reagent
D1e9bed8: protein measurement with ent with the folin phenol reagent
D1e9bfdb: protein measurement with the folin in phenol reagent
D1e9bfdc: protein measurement with the folini phenol reagent
D1e9bfe0: protein measurement with the folinn phenol reagent
D1e9bfee: protein measurement with the folin phenenol reagent
D1e9c002: protein measurement with the folin phenol phenol reagent
D1e9c02a: protein measurement with the folin phenol reagent
D1e9c085: protein measurement with the folin phenol reagent protein measurement with the folin phenol reagent
D1e9c0f5: protein measurement with the foli phenol reagent
D1e9c13d: protein measurement with the protein folin phenol reagent



Pour 47 millions de titres sans duplicates exacts

construction des 6-grammes

3,8 Gio 56 Gio 15 min

hashage des 6-grammes

56 Gio 31 Gio 14 min

tri

31 Gio 31 Gio 16 min mémoire centrale: ...

hashage par minimum et hashage sensible à la localité

31 Gio 7 Gio 30 min mémoire centrale: 18 Gio

Recherche des candidats: même hash dans la même bande (tri)

7 Gio 7 Gio 5 min


Calcul des similarités de Jaccard des paires candidates, seuillage

7 Gio 4 Gio 7 h 26 min


Calcul des composantes connexes

4 Gio 0,2 Gio 6 min

Système NeoTex



Modèles (1)



Apprentissage supervisé

Objectif

Prédire si un document d est pertinent pour une requête q

$$\hat{E}(q,d) \in \{0,1\}$$

Formalisation du modèle

- Étape 1: Apprentissage

A partir d'un ensemble de couples (q, d) , où chaque couple est décrit par les scores

- $S_c(q, d)$: score de pertinence (ISTEX API)
- $S_i(d)$: in-degree du document d
- $S_O(d)$: out-degree du document d
- $S_{PR}(d)$: pagerank du document d

et par le vérité terrain

- $E(q, d) \in \{0, 1\}$

construire un model pour prédire

$$\rightarrow \hat{E}(q, d) \in \{0, 1\}$$

Formalisation du modèle



- Étape 2: Utilisation du modèle

Pour une nouvelle requête, prédire la pertinence d'un document pour lequel on dispose des scores

- Trois méthodes d'apprentissage :
 - Arbres de décision (AD)
 - Random Forest (RF)
 - SVM


Modèles (2)

Apprentissage Supervisé (étape 1)




Models (2)

Apprentissage Supervisé (étape 2)



Modèles (2)

Apprentissage Supervisé (étape 2)



Option 1: Filterage Booléen

(q,d)	S_c	S_I	S_O	S_{PR}
(q_1, d_1)	0.85	32	566	0.323
(q_1, d_2)	0.79	23	65	0.8736
(q_1, d_3)	0.70	67	98	0.937
...
(q_1, d_{1000})	0.24	806	300	0.762

Résultat final

Rank	Doc
1	d_1
2	d_3
3	d_{900}
...	...
30	d_{50}

Top 30 où
 $\hat{E}_M=1$

Modèle
entraîné avec
 E_M


Chantier d'usage: NeoTEX

Booléan

7

Modèles (2)


Apprentissage Supervisé (étape 2)




Option 2: Reclassement par probabilité

(q,d)	S_c	S_I	S_O	S_{PR}
(q1, d_1)	0.85	32	566	0.323
(q1, d_2)	0.79	23	65	0.8736
(q1, d_3)	0.70	67	98	0.937
...
...
...
...
(q1, d_{1000})	0.24	806	300	0.762


Arbre de décision entraîné avec E_M



Evaluation



Trec_eval




Evaluation

- Data
 - Métadonnées d'ISTEX de 1950 à 2005 (18 millions docs)
 - Requêtes: 25 sujets de thèse (Informatique 2006)
- Apprentissage supervisé
 - Modèles testés
 - Arbre de décision
 - SVM
 - Forêts aléatoires
 - Échantillons
 - 20 requêtes d'apprentissage
 - 5 requêtes de test
 - Validation croisée (5-fold)

Résultats

F-measure	Thèses	MAN	Réputation
L_C	1,71	17,40	4,40
L_R	-	0,76	5,30
L_I	1,93	6,65	37,73
L_O	1,07	2,56	28,40
L_P	2,36	6,65	36,00
L_{C+I}	2,79	23,52	30,27
L_{C+O}	1,50	18,92	24,27
L_{C+PR}	2,36	23,52	28,67
$L_{C+I+O+PR}$	2,57	23,52	35,33
$AD_P_E_M$	1,71	17,40	4,40
$AD_P_E_T$	1,71	17,40	4,40
$AD_P_E_R$	2,36	22,76	23,60
$AD_P_E_{TUR}$	2,36	22,76	23,73
$RF_B_E_R$			28,27
$RF_B_E_{TUR}$			28,27

Résultats



Pistes d'amélioration par rapport au problème d'échantillons déséquilibrés :

- procédure de rééquilibrage des classes
- introduire des coûts d'erreur (pénaliser le faux négatif)

Conclusion

- NeoTex pour ISTEK : de nouvelles fonctionnalités pour l'utilisateur
 - Graphe de citations: permet d'associer à chaque document: nombre de références, de citations et pagerank **grâce à la collection intégrant les références et à Grobid**
 - Fournir à un utilisateur des listes d'articles de référence selon plusieurs points de vue

Conclusion

- NeoTex pour ISTEK : l'articulation de la collection ISTEK avec DBLP pour produire de nouveaux attributs prédictifs
 - Impact factor:
 - calcul basé sur le graphe, comparaison avec WOS -> forte corrélation
 - Popularité des auteurs (DBLP):
 - Nb de publis, co-auteurs, ancienneté
 - Multi-disciplinarité:
 - Catégories WOS d'ISTEK
 - Autres ressources (to do ISTEK2 cf Gully)
 - *Spécialisation/vulgarisation (to do: collaboration ISTEK2 cf Cuxac)*
 - *Ressource sémantique*
 - *Topic Model, LDA*

Perspectives

- Evaluation du système NeoTex
 - Choix du domaine
 - Actuellement: Informatique
 - En cours: Science de la vie
- Graphe
 - Construction et évaluation du graphe
 - choix des paramètres pour le LSH
 - appliquer la méthode sur toute la collection ISTEK (< une semaine)
 - lier avec les identifiants ISTEK (ISTEX2: cf. CILLEX)
 - visualiser le graphe de voisinage (références/citations) d'un document donné pour permettre une recherche itérative par l'utilisateur (NeoTex2?)
 - construire le graphe d'auteurs (très difficile-ISTEX2)
 - Lier à d'autres collections: par exemple dblp, ACM pour l'informatique

Merci

Questions?