



USR 3550

Quelques mots sur humanités numériques et calcul intensif dans le nuage

Digital humanities & Cloud computing ?

Thierry Chanier, MSH-LRL, Université Blaise Pascal



Réunion Cloud Computing, CRRI, Cézeaux, 26 février 2013

Objectifs et contenu

- Se comprendre malgré disparités disciplines
- Développement humanités numériques en Europe, France, Clermont
- Contraintes, besoins en SHS : différencier besoins et acteurs impliqués
- Enjeux à court /moyen termes vers « big data » et « cloud computing »

Union Européenne



- Just like astronomers require a virtual observatory to study the stars and other distant objects in the galaxy,
- **researchers in the arts and humanities need a digital infrastructure** to get access to and join together the information and the knowledge that is embedded in digital content.
- The Digital Research Infrastructure for the Arts and Humanities – DARIAH – will be such an infrastructure with a European dimension.

Organisation en France pour SHS

EU



FR



Consortiums:

- IR Corpus-écrits
- IR Corpus-oraux et multimodaux
- IR Archives des ethnologues
- IR CAHIER (philo & littérature)
- ...

Clermont



Humanités numériques et MSH Clermont: exemples avec textes et images

Serveurs
MSH

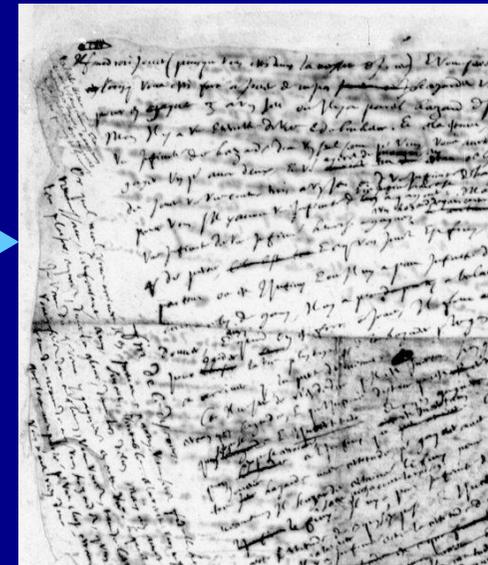


En cours de
développement

Numérisation fine et
stockage à la BNF



**Pas encore « big data »,
pas de calculs,
mais des besoins non satisfaits**



Humanités numériques et MSH Clermont: exemples corpus multimodaux, calculs

Plateforme spécifique



INTELESPACE
Plateforme géomatique

INTELESPACE : une plateforme de recherche en géomatique à la MSH

La géomatique spatiale est un axe de recherche commun à plusieurs laboratoires hébergés à la MSH de Clermont-Ferrand. Une volonté forte de développer les compétences géomatiques et de mutualiser les équipements spécifiques a émergé sous l'impulsion de la MSH et des laboratoires CERAMAC, CHEC et GEOLAB. Grâce au soutien financier de la région Auvergne, de l'Université Blaise Pascal et du CNRS, la plateforme INTELESPACE (pour « intelligence de la donnée spatiale ») est née en 2009 concrétisant cette synergie spatiale à la MSH de Clermont-Ferrand. La plateforme est animée et pilotée par Franck VAUTIER (IR CNRS) et Erwan ROUSSEL (IGE UBP).

Mission et domaines de compétences

INTELESPACE a une mission de recherche et de développement méthodologique en géomatique. Elle apporte un soutien technique et thématique sur les trois principales étapes de la recherche à dominante géomatique : l'acquisition de données géolocalisées, le traitement et la transformation des données et l'analyse spatiale et l'interprétation des données.



Principales activités

Quelques téraoctets
Calculs sur modèles
en dizaines d'heures

Serveur MSH



Repository.Mulce.org Data Bank
Mulce.org Documentation



1 téraoctet,
Données XML,
début calculs

Textes, images, audio, vidéo

**Se rapprochent « big data » ?,
et des besoins non satisfaits**



Données recherche, contraintes, et besoins en SHS (hors calcul intensif)

- Beaucoup (mais pas toutes) données collectées, structurées à la main: besoin RH qualifiées
- Formation des chercheurs sur standards
- Questions prégnantes sur éthique et droits
- Diffusion stable des données, archivage à long terme (changement formats)
- Référencement données : visibilité, moissonnage

Mulce online

Repository.Mulce.org Databank

Mulce.org Documentation

Identifiant	Type de l'objet	Description	Taille (Ko)	LETEC
1 mce-copeas-T5_contexte-all	Corpus distinguable	corpus distinguable	53000	Copéas
2 mce-copeas-T5_lobby_s101-all	Corpus distinguable	corpus distinguable	54	Copéas
3 mce-copeas-T5_s102-all	Corpus distinguable	corpus distinguable	43	Copéas
4 mce-copeas-T5_s102_end-all	Corpus distinguable	corpus distinguable	42	Copéas
5 mce-copeas-T8_lobby_s101-all	Corpus distinguable	corpus distinguable	56000	Copéas
6 mce-copeas-T8_s102_lobby-all	Corpus distinguable	corpus distinguable	59000	Copéas
7 mce-copeas-eurocall05-all	Corpus distinguable	corpus fait à partir article Eurocall 2005, rassemblement analyses	2000	Copéas
8 mce-copeas-strategies-AT6-all	Corpus distinguable	corpus fait à partir article Alsic 2008, rassemblement analyses	53000	Copéas

MULCE.ORG DOCUMENTATION

This site provides information on the Mulce repository <http://repository.mulce.org> where learning & teaching corpora are accessible. It explains the methodology used to compile these LETEC corpora (with associated analysis tools). It provides guidelines for sharing research data on online learning situations. Access information about Mulce on OLAC

This site follows the Open definition [OPEN DATA](#) and is under licence

THE MOST RECENT ARTICLES

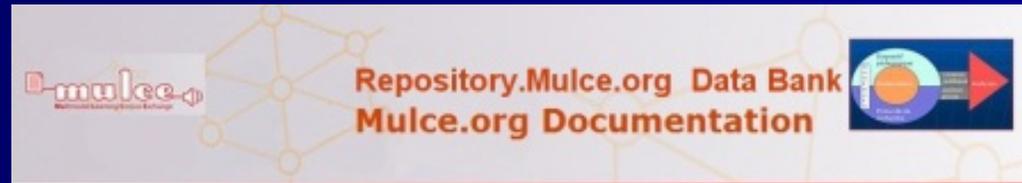
IJTEL : lessons learned in five years by the Mulce project

In order to make replication possible for interaction analysis in online learning, the French project named Mulce (2007-2010) and its team worked on requirements for

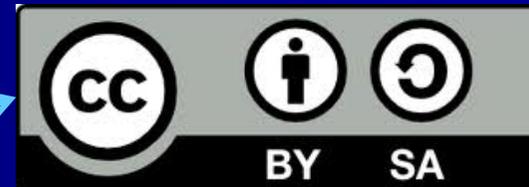


Metadata in OLAC and in CLARIN

Open access, ethics and licence



Open Data:
<http://opendefinition.org/guide/>

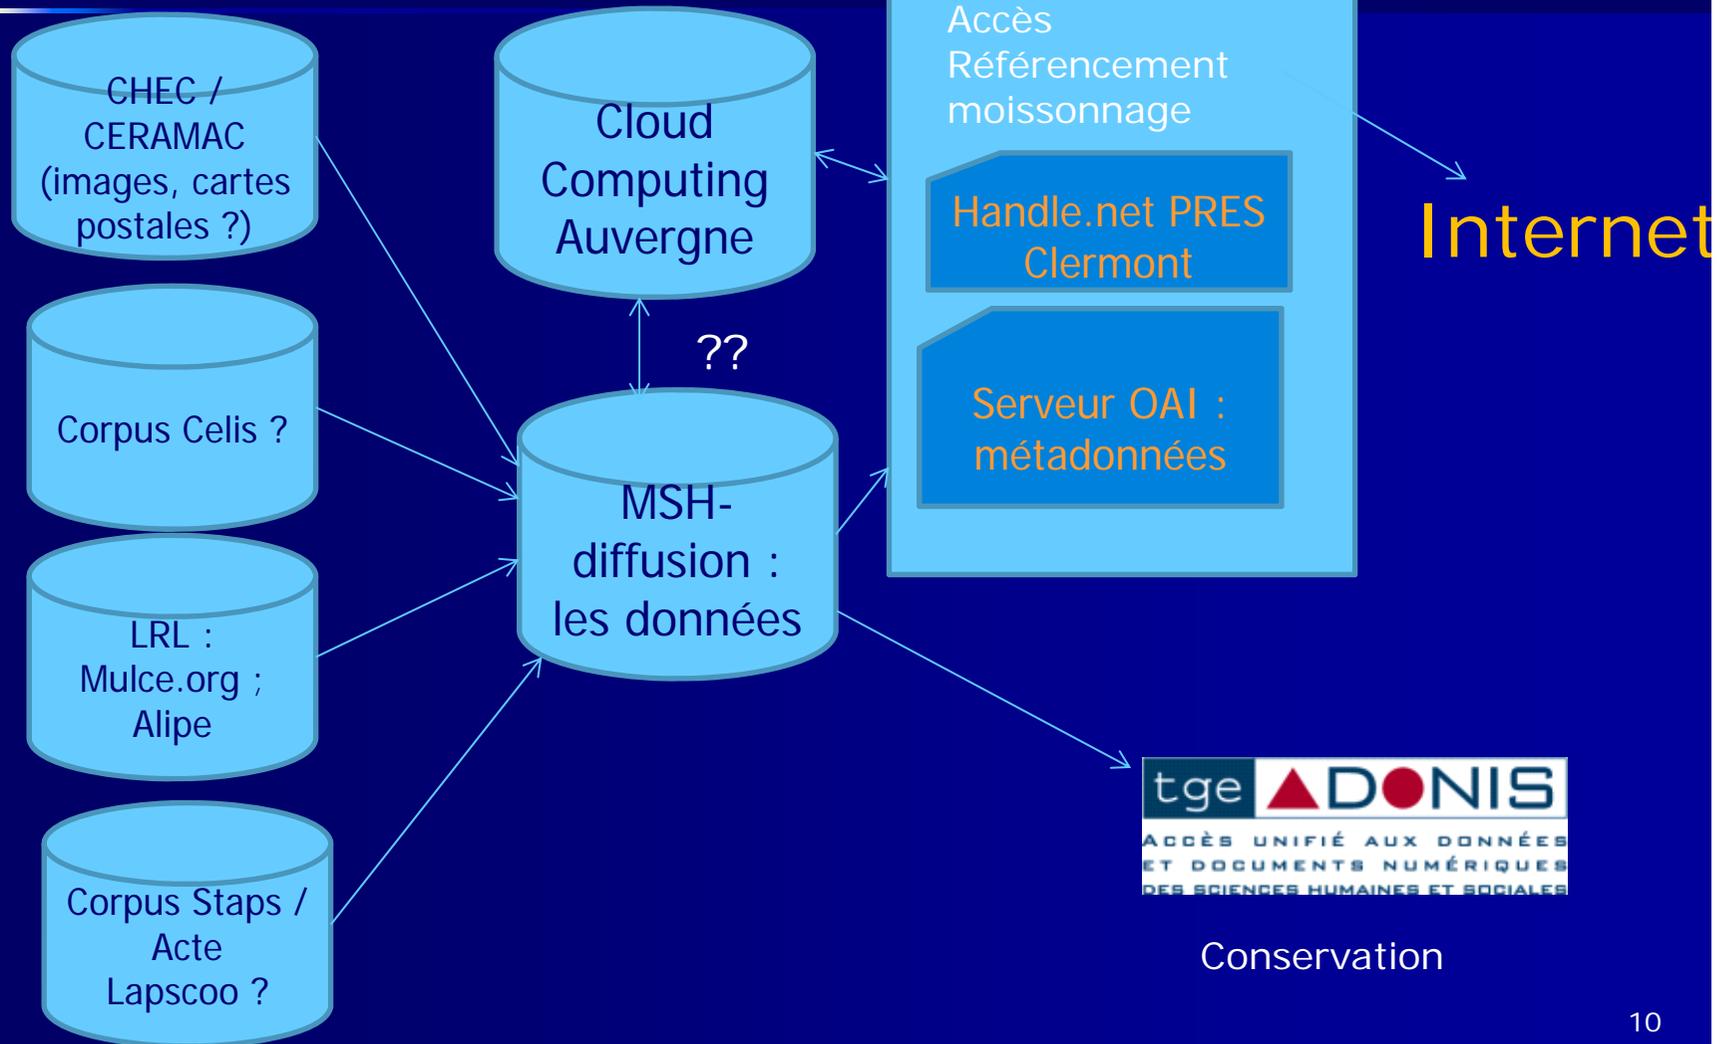
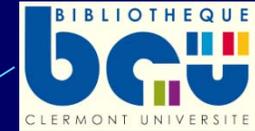


For usage:
licence



For participants:
Informed
consent form
+
Anonymization
process

MSH-PRES

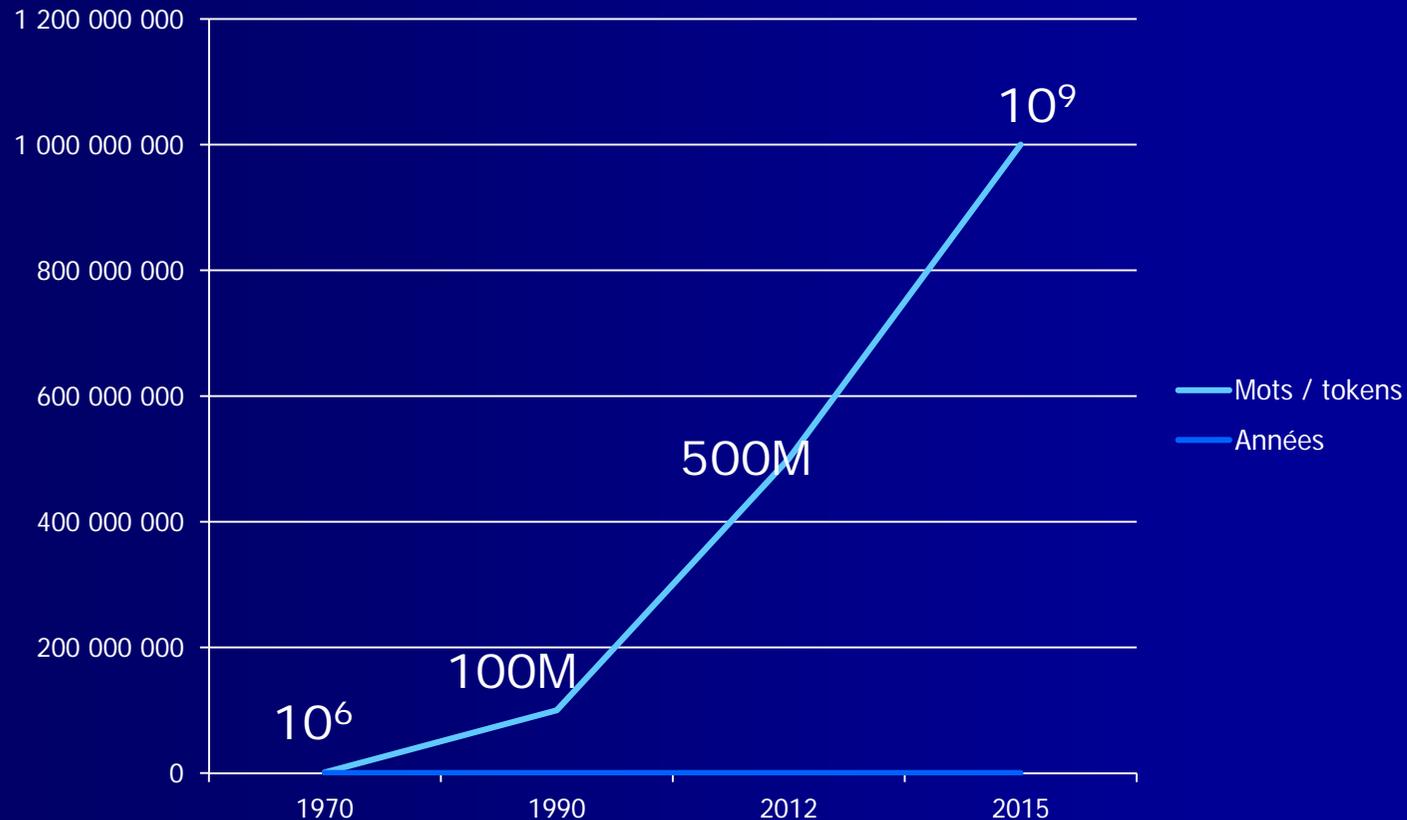


Exemple corpus de référence sur langue

PRÉVOIR DÉVELOPPEMENT PROCHE CLOUD COMPUTING SHS

Repères internationaux en corpus de langue

Nombre de mots / tokens



EN :
Brown
Corpus

EN :
British
BNC

NL et DE :
National
Corpora

Corpus sur hollandais

SoNaR - Facts and figures

- Spoken Dutch Corpus
9-million-word corpus, incl. audio, collected between 1998 and 2003
- Need for reference corpus of contemporary written Dutch
- With funding from the Dutch-Flemish STEVIN program
 - D-Coi (pilot) project – 2005-2006
corpus design, protocols, procedures, etc.
54-million-word corpus
 - SoNaR project – 2008-2012
500-million-word corpus

Corpus sur allemand

Korpora

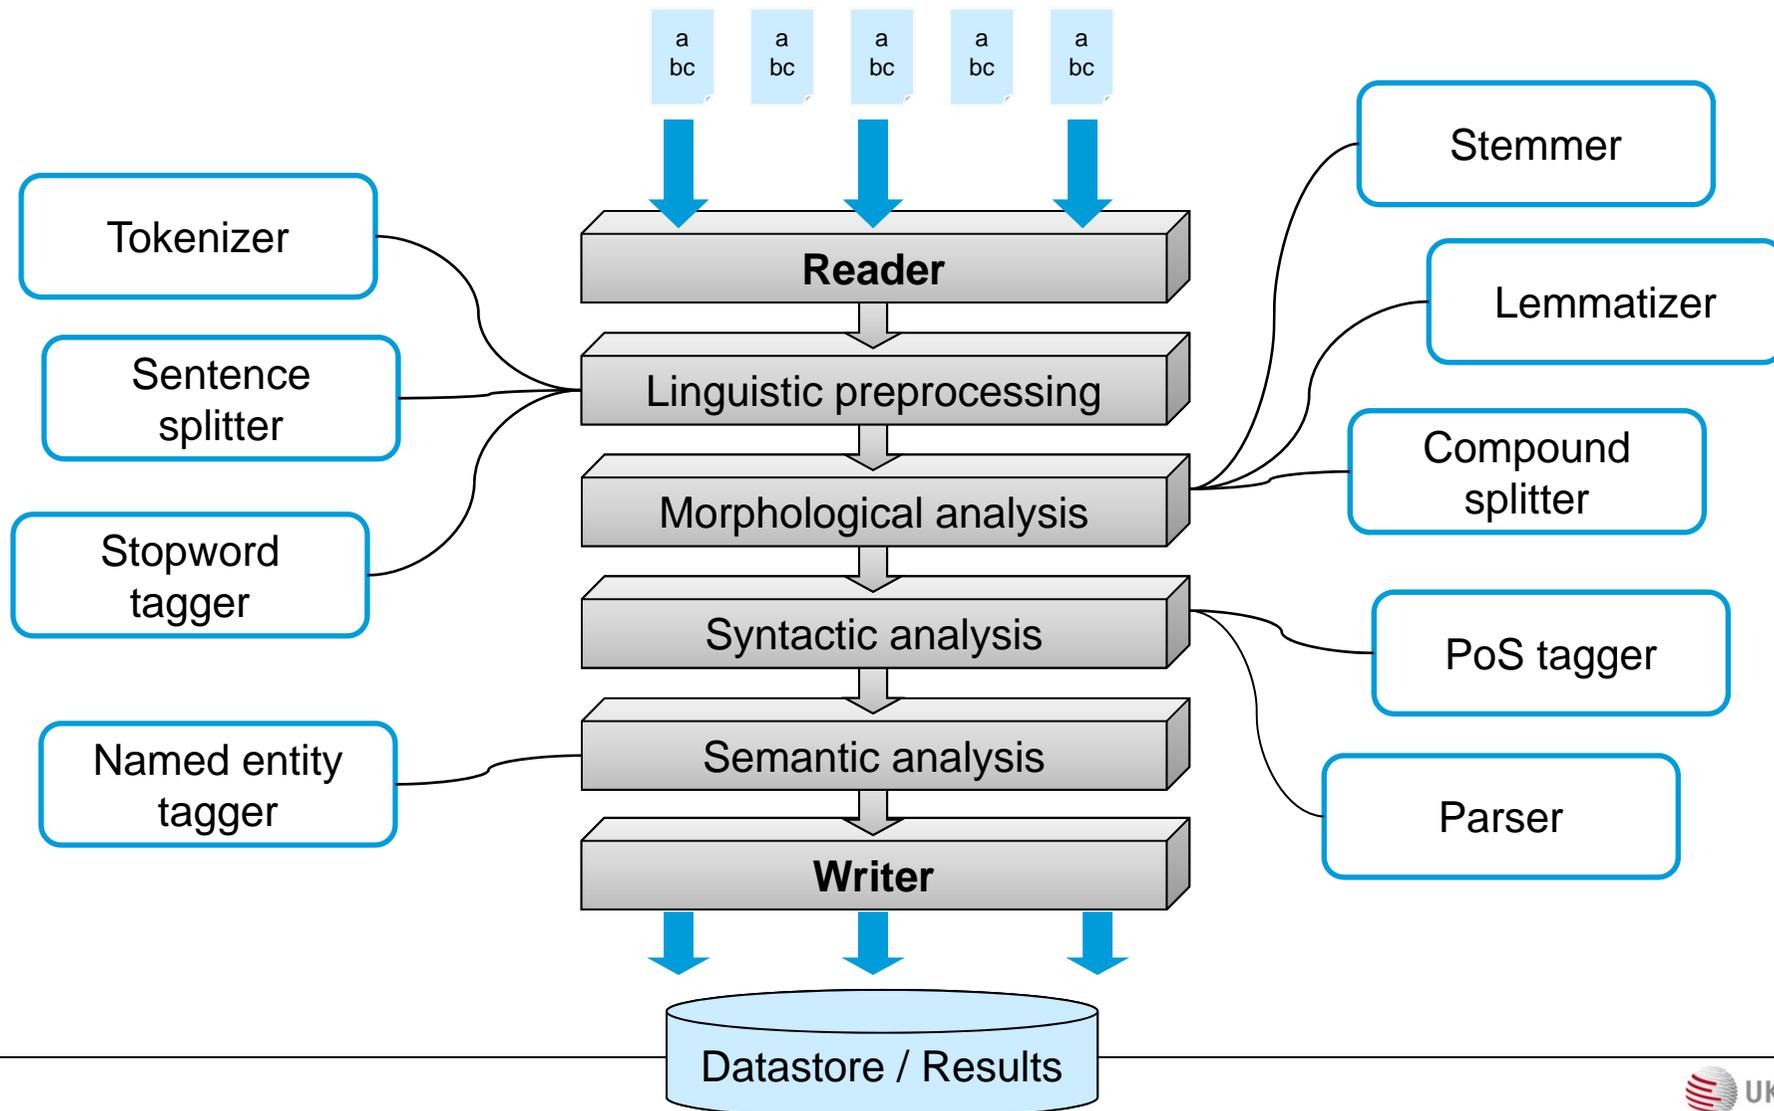


- **DWDS – Kernkorpus des 20./21. Jh.**
 - 100 Millionen laufende Wörter (etwa 80.000 Dokumente)
 - ausgewogene Verteilung über Zeit und Textsorten (Schöne Literatur, Gebrauchsliteratur, Journalistische Prosa, Wissenschaftstexte)
- **DWDS – Erweitertes Korpus**
 - 1,5 Milliarden laufende Wörter (etwa 5 Millionen Dokumente): Zeitungstexte seit den 90er Jahren
 - Texte namhafter Zeitungen: Die Zeit, Süddeutsche Zeitung etc.
 - Belletristik des 21. Jh.



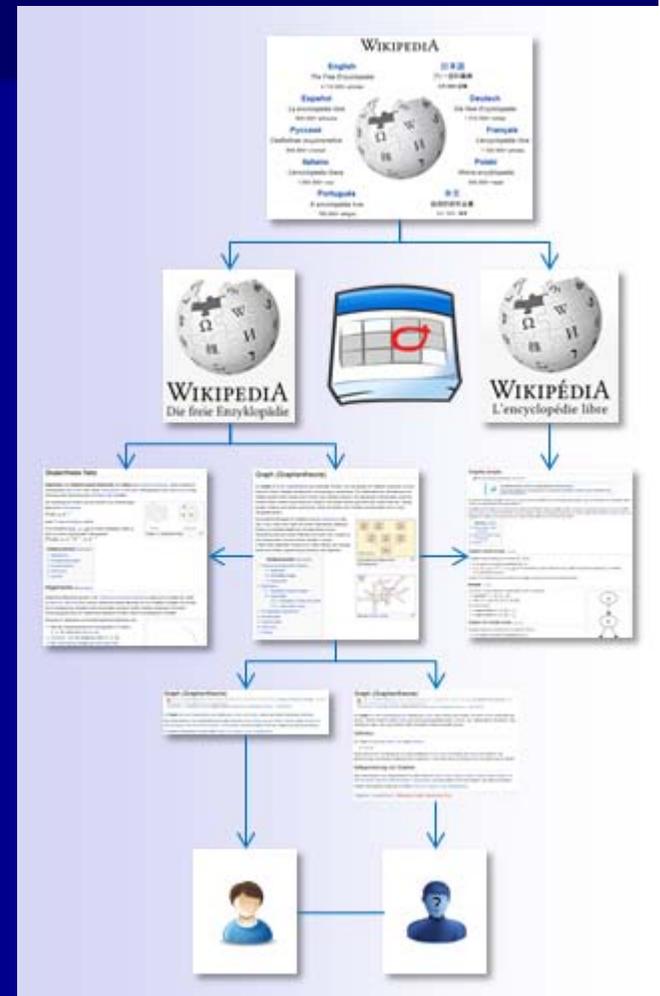
Calculs pour passer des données aux analyses

Pipeline Architecture



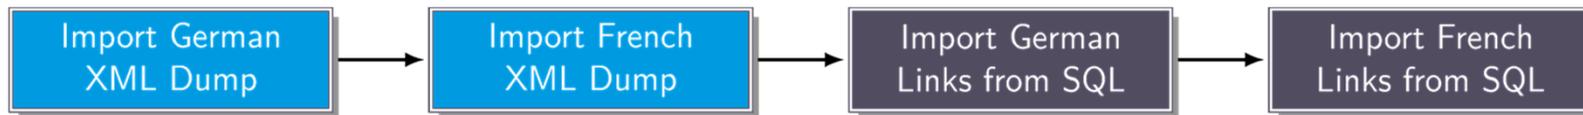
Exemple proche « big data »

- Extraction automatique et traitement Wikipedia
- **1 seul article** (peintre Monet) en deux langues : FR et DE



(Goethe-Universität Frankfurt
Rüdiger Gleim, Alexander Mehler)

Import XML Dumps into the Database



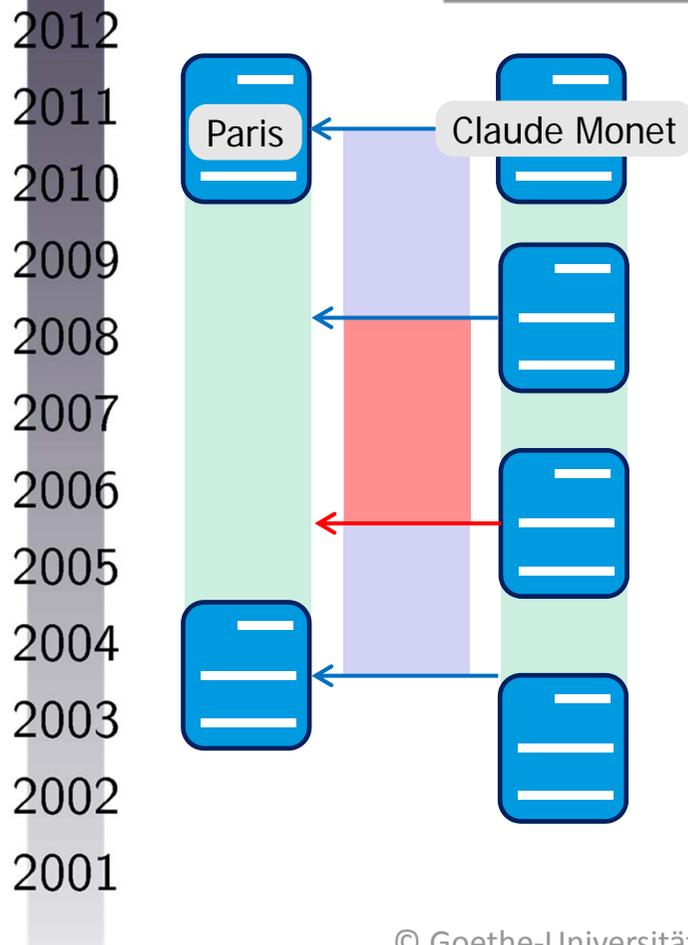
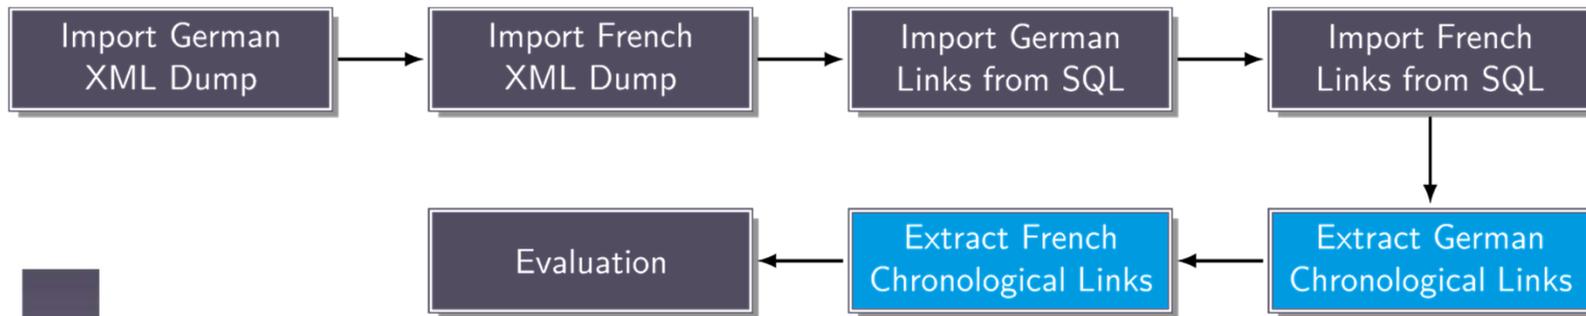
Attribute	Value (German)	Value (French)
Date of Dump	2012-12-15	2012-12-13
Pages	4 283 757	5 505 082
Revisions	101 959 908	82 296 570
XML Dump Size (7z compressed)	14,09 GB	10,01 GB
XML Dump Size	2 050,28 GB	1 319,77 GB
Text Compression Rate	2,928 %	4,187 %
Diff Compressed Revisions	92,881 %	87,367 %
Threads for Import (Text Compression)	24	24
Import Time	30,5 h	21,0 h
Average Time/Page	25,635 ms	13,76 ms

2 To

Temps
calcul

```
1 // Get Instance of WikipediaRoot. Initialize Database if necessary
2 WikipediaRoot root = new WikipediaRoot_impl();
3 // Specify XML Files to import
4 File deXMLFile = new File("dewiki-20121215-pages-meta-history.xml.7z");
5 File frXMLFile = new File("frwiki-20121213-pages-meta-history.xml.7z");
6 // Import german (de) Wikipedia from specified file using up to 24 threads
7 Wikipedia deWiki = root.importWikipedia("de", "2012-12-15", deXMLFile, 24);
8 // Import french (fr) Wikipedia from specified file using up to 24 threads
9 Wikipedia frWiki = root.importWikipedia("fr", "2012-12-13", deXMLFile, 24);
```

Extract Chronological Links



**Calculs sur liens
(pas encore étiquetage linguistique)**

Attribute	Value (German)	Value (French)
Elapsed Time	22,98 h	38,90 h
Average Time/Page	19,31 ms	25,44 ms
Threads for Parsing	30	30
Imported Links	111 815 686	210 468 542
Extracted Links	94 161 457	99 404 533

Retour sur France et Clermont

- 2013-..., France : projet constitution corpus de référence du français contemporain (consortiums IR-corpus)
- 2013-2014, Clermont : groupe travail sous-corpus avec labos distants, dépôts données et calculs dans nuage

CORPUS *Infrastructure de Recherche*

LE WIKI DE LA LISTE CORPUS-ECRITS-NOUVCOM

Projet corpus Nouv-com

Rassemblement de corpus évolutifs. Plusieurs membres / équipes de notre groupe de travail disposent déjà de corpus rase (clavardage, forums, twitter, etc.). Il s'agit de sélectionner tout ou partie de ces corpus déjà organisés en XML, et contenant de rassembler en une banque de corpus accessible à tous. Chaque corpus sera documenté suivant des standards (OLAC, CLARIN) serveur mis à disposition sur un serveur national (cf. ci-dessous), faisant tourner un protocole OAI-PMH. Des membres de ce projet envisagent d'adopter cette banque au corpus global. Les membres du projet étudieront la façon dont des analyses / annotations faire l'objet de projet de recherche financés par ailleurs - ANR, etc., la banque servant alors de point d'appui dans le montage d TEI-nouv-com afin de voir comment à l'horizon 2013-14, les corpus de la banque pourraient être avoir une version TEI. Vous vous à disposition du projet vos corpus ou, si vous n'en avez pas, désirez participer à l'avancement du projet.

- Coordinateur : à déterminer
 - Personnes amenant des corpus : Gudrun Ledegen, Thierry Charlier, Benoît Sagot, Virginie Zampa, Achille Falaise, Georges Antz
 - Autres participants : Tita Kyriacopoulou, Rachel Panckhurst
 - Total : 9 personnes ; UR différentes : 8 (3 IDF, 3 Grenoble, 1 Rennes, 1 Clermont-Fd, 1 Montpellier)
 - Lieu potentiel de réunion : Grenoble et IdF de France (IDF)
 - Réunions et déplacements : 2 réunions en présentiel (dont 1 couplée avec celle du projet TEI-nouv-com, le jour suivant) ; 2- lieu dans Adobe Connect.
- Note : Benoît et Gudrun ont écrit une réserve sur le fait de participer aux travaux du groupe (en dehors des réunions). Rachel n'écrit