

CorTextT Manager : extraction d'information et analyse socio-sémantique pour les sciences humaines et sociales

CNRS TDM, Octobre 2022

Marc Barbier, Lionel VILLARD

LISIS, IFRIS, INRAe, CorTextT, ESIEE Paris

La plateforme CORTEXT

Constituer une plateforme scientifique et technique pour soutenir un **espace de recherche sur les traces et les usages numériques de la science et de l'innovation en société.**

*“L’objectif premier de la plateforme CorText est qu’un chercheur en sciences sociales – ou un autre utilisateur – puisse venir avec une **question de recherche** et partir en **profitant des fruits d’une méthode computationnelle** adaptée à sa question.”*



avec les soutiens de



La plateforme CorText : entre interfaces et infrastructures

Interface humaine

Interactions avec un membre de la PF dans le cadre d'un accompagnement technique ou méthodologique

Membres
PF

Outils

Interface logicielle

Interactions avec les interfaces logicielles développées. En utilisant une application web, un service ou un accès aux données

Résultats
Visualisations

Les interfaces

*La plateforme CorText
ressources humaines*

Les infrastructures

Données

Analyses

Matériel

Gestion, déploiement et administration des serveurs pour assurer un service constant, la sécurité des accès et des données

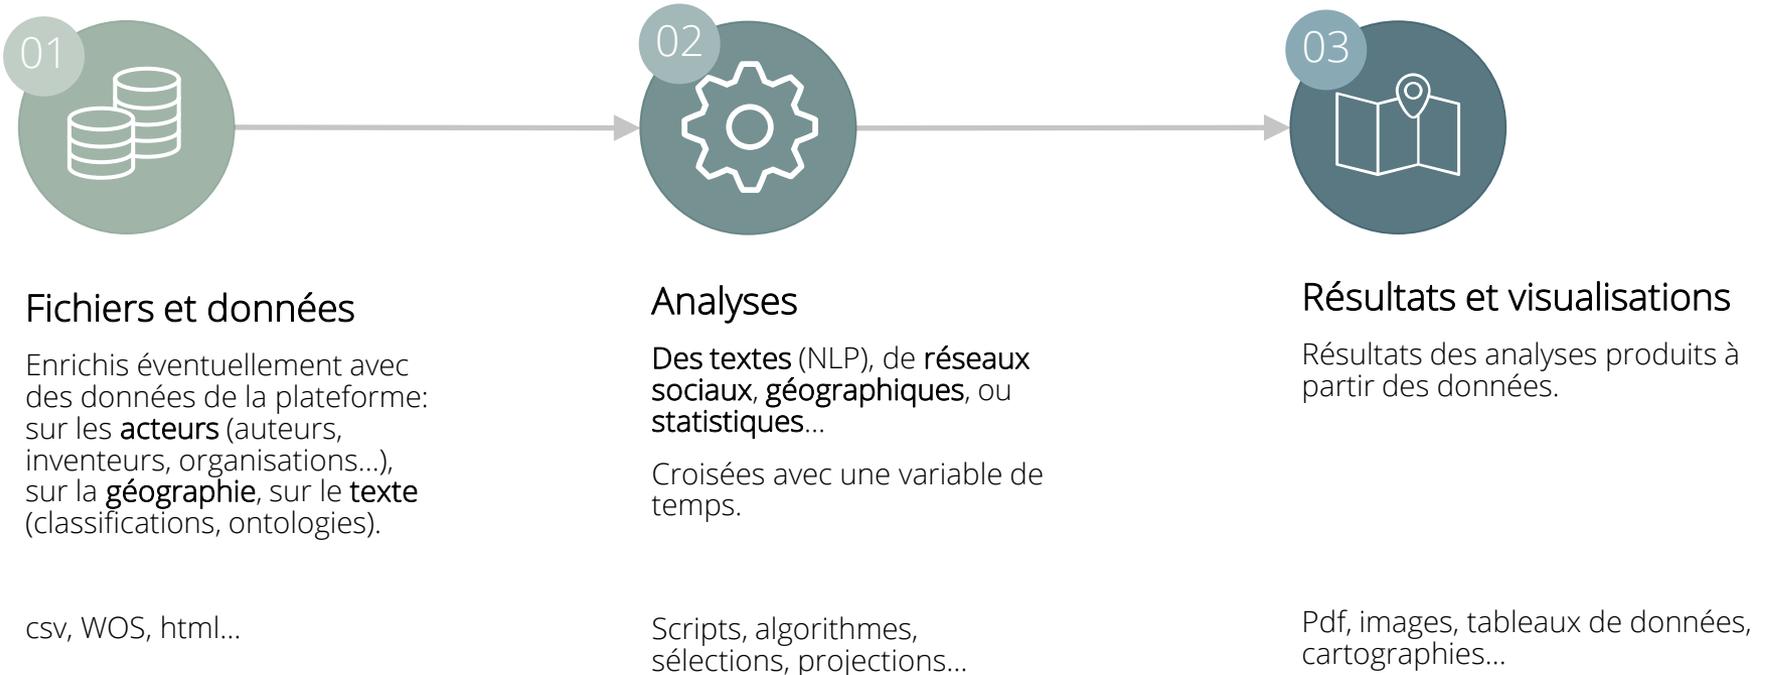
Infrastructure
Matérielle

Infrastructure
logicielle

Logiciel

Développement et maintenance des logiciels (interfaces web, méthodes, en interaction avec les outils et les usagers) et des services

Vision « usagers » : les trois étapes entre la question et l'exploitation des résultats (itératif)



5200 utilisateurs
 105 pays

Identification
 Données brutes
 Paramètres d'analyse
 Annotations

Données analysées
 Visualisations
 Informations

WEB
 CORTEXT MANAGER
 SERVICES WEB
 API "Cortext As A Service"
 OUTILS DE VISUALISATION & EXPLORATION



APPLICATIONS
 EXTERNES
*Divers projets utilisant
 l'API Cortext*

BASES DE DONNÉES
 SYSTEME DE FICHIERS A PLAT
STOCKAGE
*Bases MySQL & MongoDB
 20 To de données
 1 million de documents*

SCRIPTS
 WORKERS
CALCULS
*44 scripts (python, R,...)
 270 000 jobs executés
 30 unités de calcul*

MONITORING
*Statuts des services
 Santé de l'infrastructure
 Etude des usages
 Statistiques*

INFRASTRUCTURE
 346 CPU
 3,5 To de RAM
 40 To de stockage



Marc Barbier
Member of CorText platform,
Researcher at LISIS, Head of IFRIS



Antoine Schoen
Member of CorText platform,
Researcher at LISIS, Senior lecturer
at ESIEE Paris



Lionel Villard
Head of CorText platform, Researcher
at LISIS, lecturer at ESIEE Paris
[✉](#) [t](#) [in](#)



Patricia Laurens
Member of CorText platform,
Researcher at CNRS and LISIS



Philippe Breucker
IT engineer from INRAE, LISIS,
Technical Director of the CorText
Digital Platform, Web Designer and
developer.
[t](#) [in](#)



Bilel Benbouzid
Researcher, Senior lecturer at LISIS



Alexandre Hannud Abdo
Post-doctorant, LISIS



Pierre-Yves Bulot
IT Engineer Assistant, Cortext



Luis-Daniel Medina
IT Engineer, Cortext



Diego-Fernando Gómez Peña
IT Engineer, Cortext
[in](#)



Tatiana Andrea Sánchez Castaño
IT Engineer, Cortext
[in](#)



Joenio Marques da Costa
Research Software Engineer, Cortext
[t](#) [in](#) [ig](#)



Géraldine Enderli
Engineer specialised in the
production, processing and analysis
of data and survey at INRAE - LISIS,
CorText



Hajar Lagliil
Meteorological engineer/Data
scientist, Cortext

INTERACTION CHERCHEURS,
PROJETS, FORMATIONS,
VALORISATION, COMMUNICATION



5 CHERCHEURS
1 ASSISTANT INGÉNIEUR

COLLECTE DE DONNÉES,
STOCKAGE ET CALCUL



1 INGÉNIEUR

DEVELOPPEMENT D'INTERFACES,
VISUALISATIONS, FRONTEND



1 INGÉNIEUR

DEVELOPPEMENT DE SERVICES,
API, BACKEND



1 INGÉNIEUR

ARCHITECTURE
INFRASTRUCTURE, DEVOPS



1 INGÉNIEUR

METHODES D'ANALYSES,
STATISTIQUES, SCRIPTS



1 INGÉNIEUR DE RECHERCHE
2 INGÉNIEURS D'ETUDES

GESTION DES SERVEURS,
SUPPORT,
SECURITÉ



1 INGÉNIEUR SYSTÈME MI-TEMPS



Antoine Mazières
Research scientist in the Computation
Social Science team at Centre Marc
Bloch



Constance De Quatrebarbes
Fondateur Présidente - DRISS
(Digital Research in Science &
Society).
[in](#)



Chloé Duloquin
Web Designer, Graphiste, Intégratrice
web



Jean-Philippe Cointet
Associate Professor, Sciences Po
Paris, Medialab
[in](#)



Guillaume Orsal
Computer engineer, data mining, web
development and SEO
[t](#) [in](#) [ig](#)



Cristian Martinez
PhD Engineer in Computer Science,
NLP/Data Senior Consultant at
Cogniteva
[in](#)



Nicolas Turenne
Assistant professor in data science,
Beijing Normal University & Hong
Kong Baptist University United
International College
[in](#)



Tam Kien Duong
Data & design, Etalab
[in](#)



Nicolas Baya-Laffitte
STSLab, Université de Lausanne
[in](#)



Loïc Boudoulec
IT Engineer



Bertha Brenes
IT Engineer, Trainee, Cortext



Anis Arabi
Big data engineer
[in](#)



Nicolas Ricci
Web developer and data
[in](#)



Audrey Baneyx
Project manager Data science,
Sciences Po Paris - medialab
[in](#)



Andrei Mogoutov
BulleScience



Élise Tancoigne
Researcher, University of Geneva,
Switzerland

Champs disciplinaires mobilisés

- **Scientométrie**
- **Analyse des réseaux sociaux**
- Traitement automatique de la langue
- **Statistiques**
- **Cartographie géographique et analyse spatiale**
- **Visualisation de données**
- Les **méthodes en SHS**, notamment numériques mais pas seulement
- Développement logiciel



CorText Manager en 2021

- 1313 utilisateurs actifs, générant plus de 65000 calculs;
- provenant d'environ 550 institutions (universités, entreprises, ministères, cabinets de conseil, journaliste, services de veille...) et villes



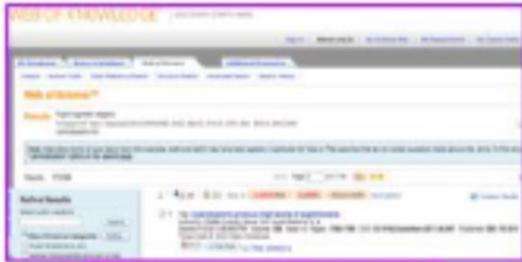
Les publications de CorText Manager

- Plus de 640 auteurs ont publié en revendiquant une utilisation de CorText Manager depuis 2016. Ces auteurs représentent moins de 10% de la communauté d'utilisateurs de CorText Manager;
- En dehors de la France : augmentations importantes en Chine, aux Philippines et au Brésil, avec la structuration de deux communautés à Wuhan et Manille.

→ <https://www.cortext.net/publications/>

Des jeux de données multiples

scientific productions



Web Of Science ISI

specific databases



rare disease database

media productions (press+web)



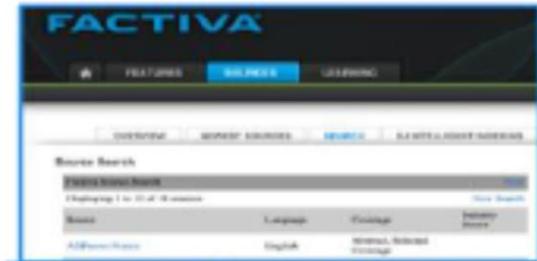
web crawler



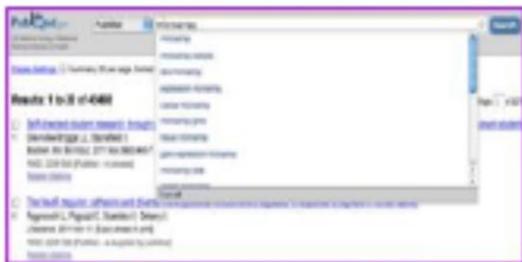
Microsoft Academic Search



projects database



Factiva, press articles archive



Medline Pubmed



clinical trials database



online forums

Ce que CorText Manager produit

Deux principaux types d'indicateurs

- Les indicateurs simples de **statistique descriptive** : stocks, rangs, fréquences

- **Indicateurs relationnels** (réseaux), avec deux sous types :

- **Natifs**: qui s'appuient sur des variables directement accessibles dans les données initiales, par exemple dans des métadonnées. Ces indicateurs ne rentrent donc pas dans le contenu des documents.

Par exemple : collaboration entre les auteurs...

- **Ajoutés** : qui s'appuient les résultats d'une analyse des contenus des documents. Les réseaux qui en sont issus sont donc dérivés d'un calcul effectué.

Par exemples : réseau des cooccurrences des mots des textes des documents, ou encore le réseau de collaboration entre les aires métropolitaines...

Aux origines de l'analyse de traces numériques : l'article scientifique



Available online at www.sciencedirect.com



Research Policy 36 (2007) 893–903



Journal

Data search strategy for science and technology emergence: A scalable and evolutionary query for nanotechnology tracking[☆]

Titre : haut niveau de synthèse sur le contenu de l'article

Andrei Mogoutov^{a,*}, Bernard Kahane^{b,c,1}

Auteurs : collaboration scientifique

^a AGUIDEL, 68 Bld de Port Royal, 75005 Paris, France

^b LATTs (Laboratoire Territoires, Techniques et Sociétés), CNRS/UMLV/ENPC, École Nationale des Ponts et Chaussées, 6-8 avenue Blaise Pascal, Cité Descartes, Champs sur Marne, 77455 Marne La Vallée Cedex 2, France

^c ISTM (Institut Supérieur de Technologie et Management), Cité Descartes, 93162 Noisy le Grand Cedex, France

Adresses : institutions et géographie des auteurs

Available online 23 April 2007

Date de publication : dimension temporelle

Abstract

Nanotechnology, like other emerging technologies that increasingly characterize the dynamic of our era, makes specific demands on datamining to track and interpret efficiently what is happening, through publications and other scientific output. We here propose and describe a strategy based on an automated lexical modular methodology to overcome rapidly evolving content and classification problems, which may otherwise accommodate poor quality of data and expert bias, with potential dire consequences for interpretation, decision and strategy. The proposed methodology is based on an initial nanostrig enriched and screened by eight subfields, automatically identified and defined through the journal inter-citation network density displayed in the initial core nanodataset. Relevant keywords linked to each subfield are then tested for their specificity and relevance before being sequentially incorporated to build a modular query. We then, as a first test, compare the database constructed using this methodology for years 2003 and 2005 with those obtained by other approaches previously used to cover and explore the nanotechnology dynamic. Finally, using the inherent transparency, portability and replicability of our methodology, we offer, in order to help our initial query evolve and develop, a set of evaluation processes for tests by researchers in the nano field, other scientometric teams and intelligence experts involved in decision-making processes.

Résumé : contenu de l'article

© 2007 Elsevier B.V. All rights reserved.

Keywords: Datamining; Nanotechnology; Emergent technologies

Mots clefs des auteurs (vision synthétique de l'article par l'auteur) :
notions, concepts, méthodes

Aux origines de l'analyse de traces numériques : l'article scientifique

References

Cambrosio A, Keating P, Lewison G, Mercier S, Mogoutov A., in press, Mapping the emergence and development of translational cancer research; European Journal of Cancer.

Huang, Z., Chen, H., Yip, A., Ng, G., Guo, F., Chen, Z.K., Roco, M.C., 2003. Longitudinal patent analysis for nanoscale science and engineering: country, institution and technology field. Journal of Nanoparticle Research 5, 333–363.

Noyons E.C.M., Buter B.K., Van Raan A.F.J., Schmoch U., Heinze T., Hinze S., Rangnow R., 2003, Mapping Excellence in Science and Technology across Europe, Nanoscience and Nanotechnology, Draft report of project EC-PPN CT-2002-0001 to the European Commission.

Sampat, B.N., 2005, Examining patent examination: An analysis of examiner and applicant generated prior art., Working Paper, Columbia University.

Zitt, M. and Bassecoulard, E., in press, “Delineating Complex Scientific Fields by A Hybrid Lexical-Citation Method: An Application to Nanosciences “Information Processing and Management”.

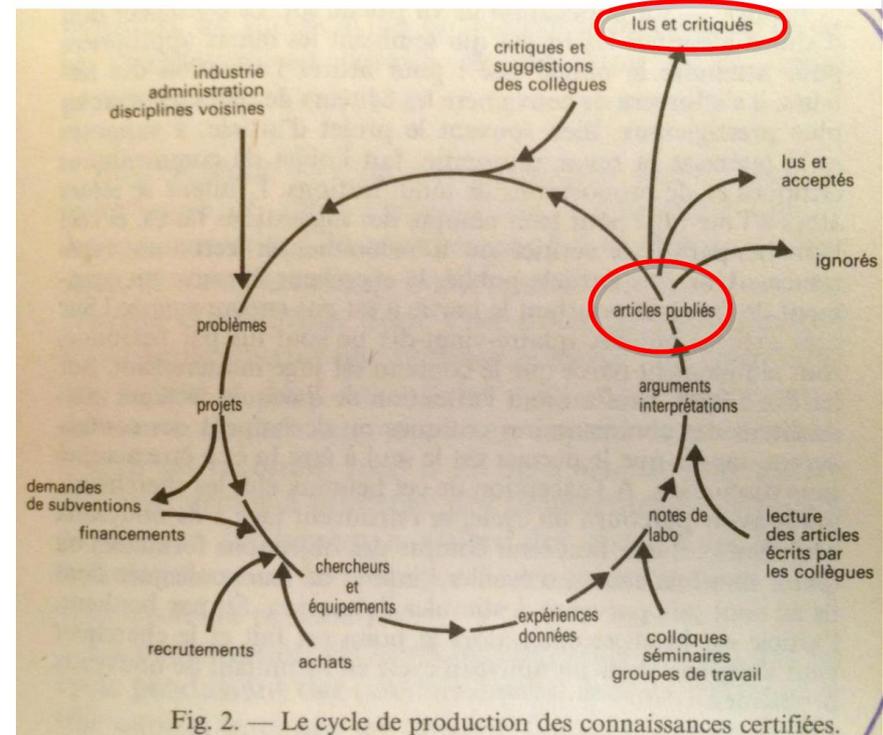
Citations et références de l'article : sources scientifiques de l'article

Activité de recherche et traces numériques

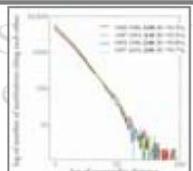
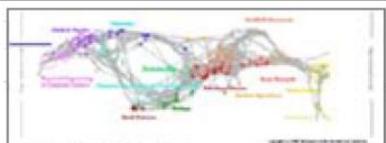
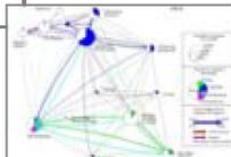
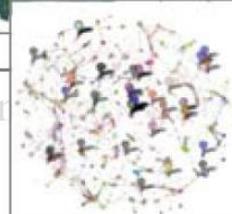
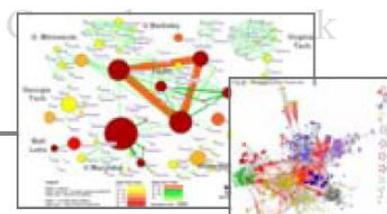
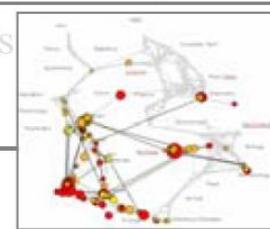
A ce titre, un **article scientifique** est considéré comme un indicateur important de la production de la recherche scientifique (mais pas le seul).

Les « **connaissances certifiées** » sont des connaissances qui ont été soumises à la critique des collègues et qui ont résisté à leurs objections (Callon, 1993).

Dés 1962, Derek de Solla Price identifie des lois générales caractérisant l'activité des scientifiques en appliquant aux articles scientifiques des **analyses quantitatives** (documents pour comprendre des dynamiques scientifiques et sociales).



Dimensions d'analyse et échelles

| | <i>Micro/Individual (1-100 records)</i> | <i>Meso/Local (101-10,000 records)</i> | <i>Macro/Global (10,000 < records)</i> |
|---------------------------------------|---|--|---|
| Statistical Analysis/Profiling | Individual person and their expertise profiles | Larger labs, centers, universities, research domains, or states | All of NS... SA, all of sci...  |
| Temporal Analysis (When) | Funding portfolio of one individual | ...ic bursts of PNAS | 113 Years of P Research  |
| Geospatial Analysis (Where) | Career trajectory of one individual | ...mapping a s... intellectual l... | PNAS ...  |
| Topical Analysis (What) |  |  | VxOrd/Topic r... NIH funding  |
| Network Analysis (With Whom?) | NSI... work of one  | ...k  | NIH's... cy  |



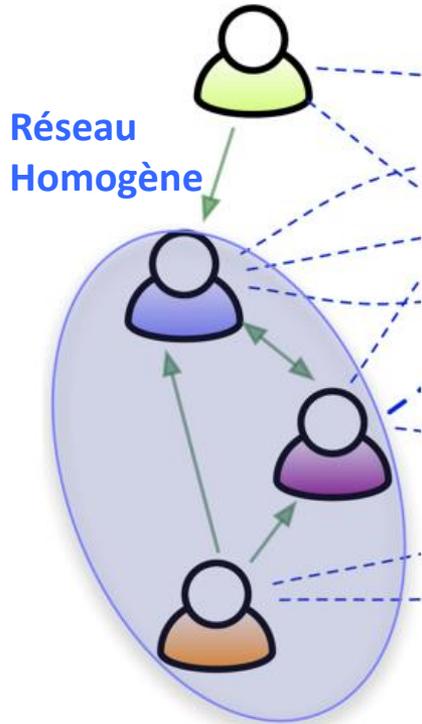
Les axes de travail fréquent

- **Emergence et cartographie** de domaine de recherche et d'innovation (bioénergie, nanotechnologie, biodiversité)
- **Controverses** et « hot topics » (pesticides, biologie de synthèse, sécurité alimentaire mondiale)
- Analyse du **web et des média-sociaux** pour caractériser les phénomènes de la Science et de l'Innovation en Société

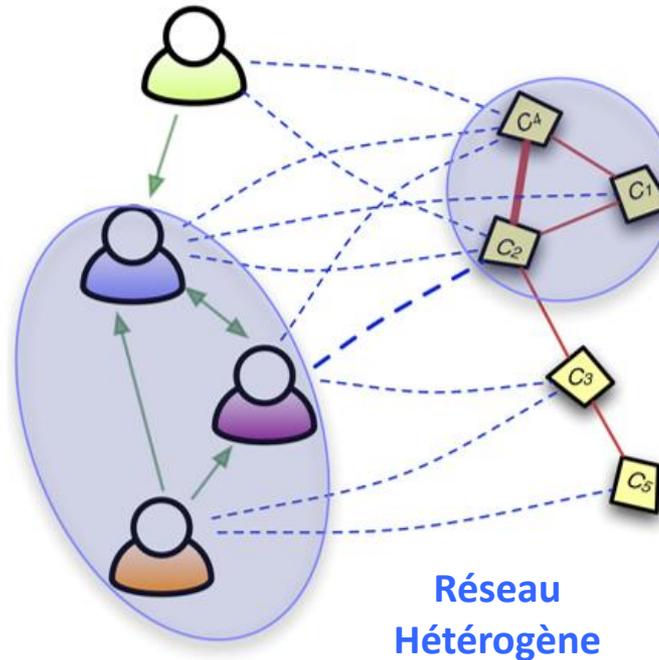
- Modes d'usages :
 - **Cartographie socio-sémantique et relationnelle** des productions de la recherche (publications, brevets, projets) dans une production académique
 - **Appui à la démarche qualitative** : utiliser la carte comme un support efficace pour faire parler les acteurs;
 - **Revue de la littérature** : certains auteurs utilisent CorText Manager pour circonscrire et situer leurs travaux (parcours doctoral, dans un papier).

→ <https://docs.cortext.net/trainings/cortext-metsem-2022/04-exemples-papiers/>

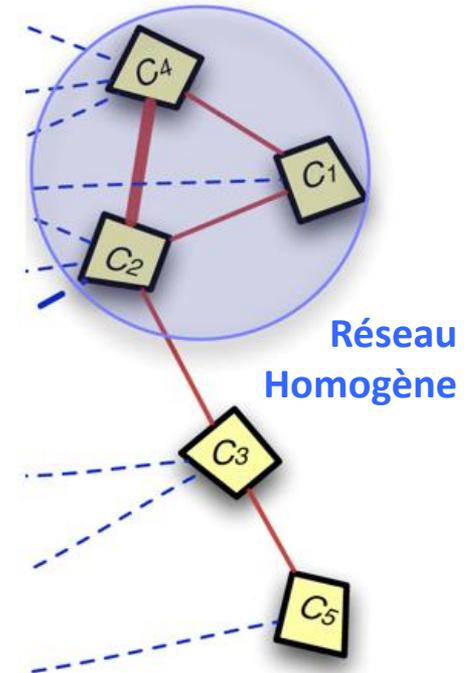
Combiner relations directes et indirectes : réseau hétérogène



Des humains ont des relations:
graphe sociologique



Des humains et des termes ont des relations:
graphe hétérogènes (socio-sémantiques)



Des termes sont associés dans des phrases:
graphe textuel

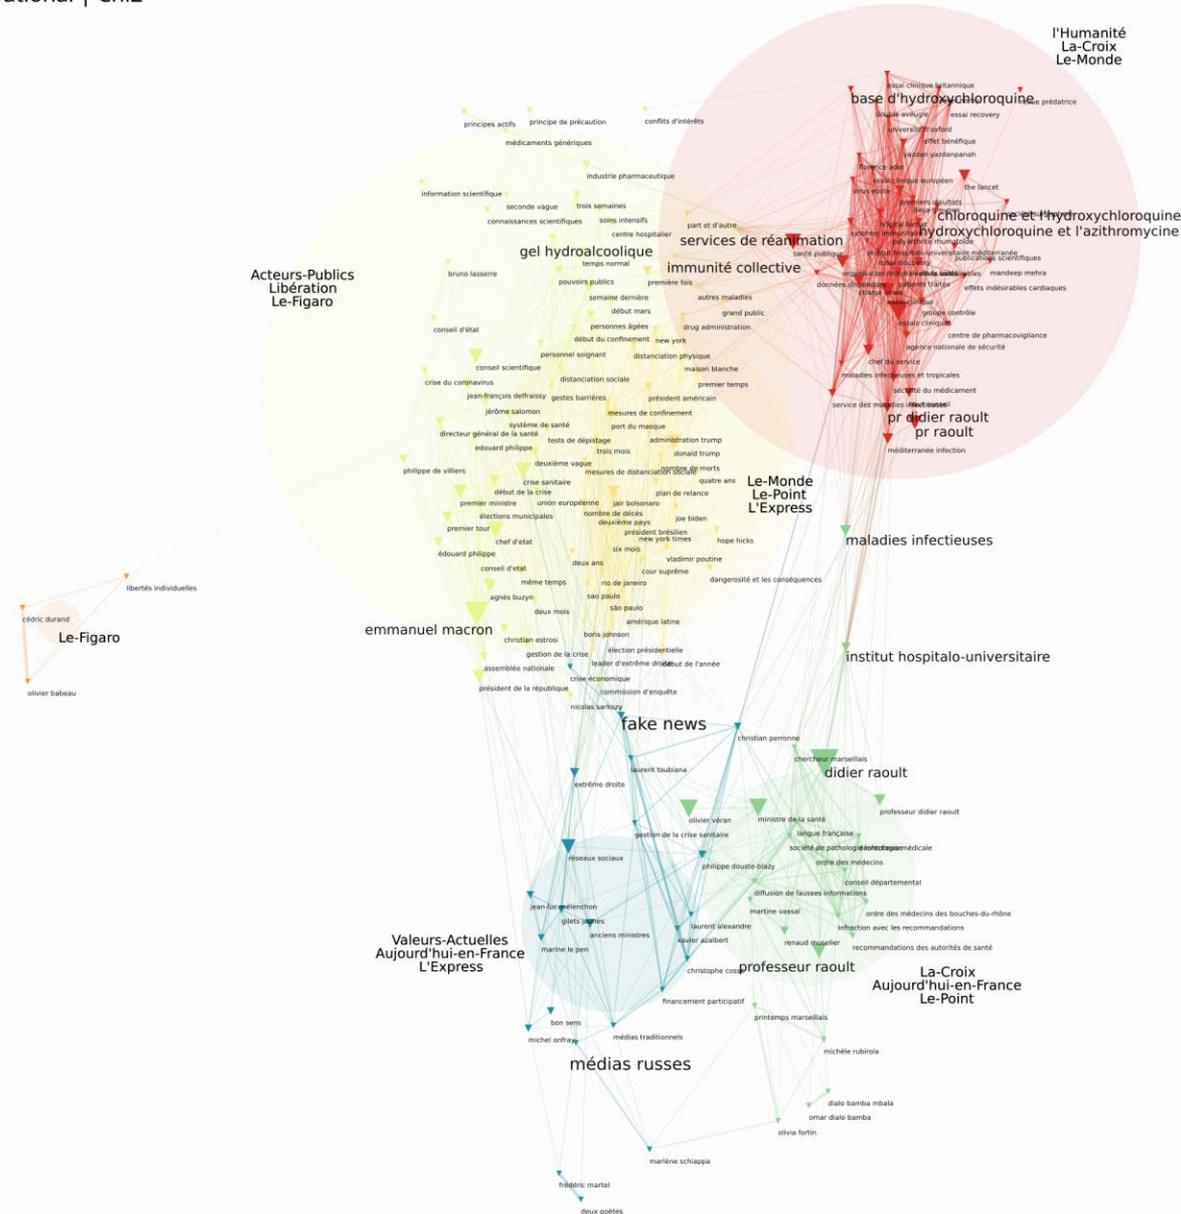
Les mesures de proximités disponibles

| proximity measures | type of network | normalisation | special properties |
|--------------------|--|---------------|---|
| raw | interaction network (e.g. social network) | no | - |
| χ^2 | homogeneous & heterogeneous | yes | normalization tend to create links toward higher degree nodes |
| MI | homogeneous & heterogeneous | yes | Inspired from information theory |
| Cramer | homogeneous & heterogeneous | yes | - |
| cosine | homogeneous network (eg. semantic) | yes | Classical measure (originating from scientometrics) |
| distributional | homogeneous network (eg. semantic) | yes | very robust measure (coming from computational linguistics) |
| cosine_het | affiliation network (eg. users sharing the same hashtags) | yes | two fields are required but the final network is homogeneous |
| dot_product_het | affiliation network (eg. users sharing the same hashtags) | no | two fields are required but the final network is homogeneous |

Visualisations et les trois niveaux de lecture

Lecture macroscopique

Chloroquine | French national newspapers | January 2020 - November 2020
Distributional | Chi2

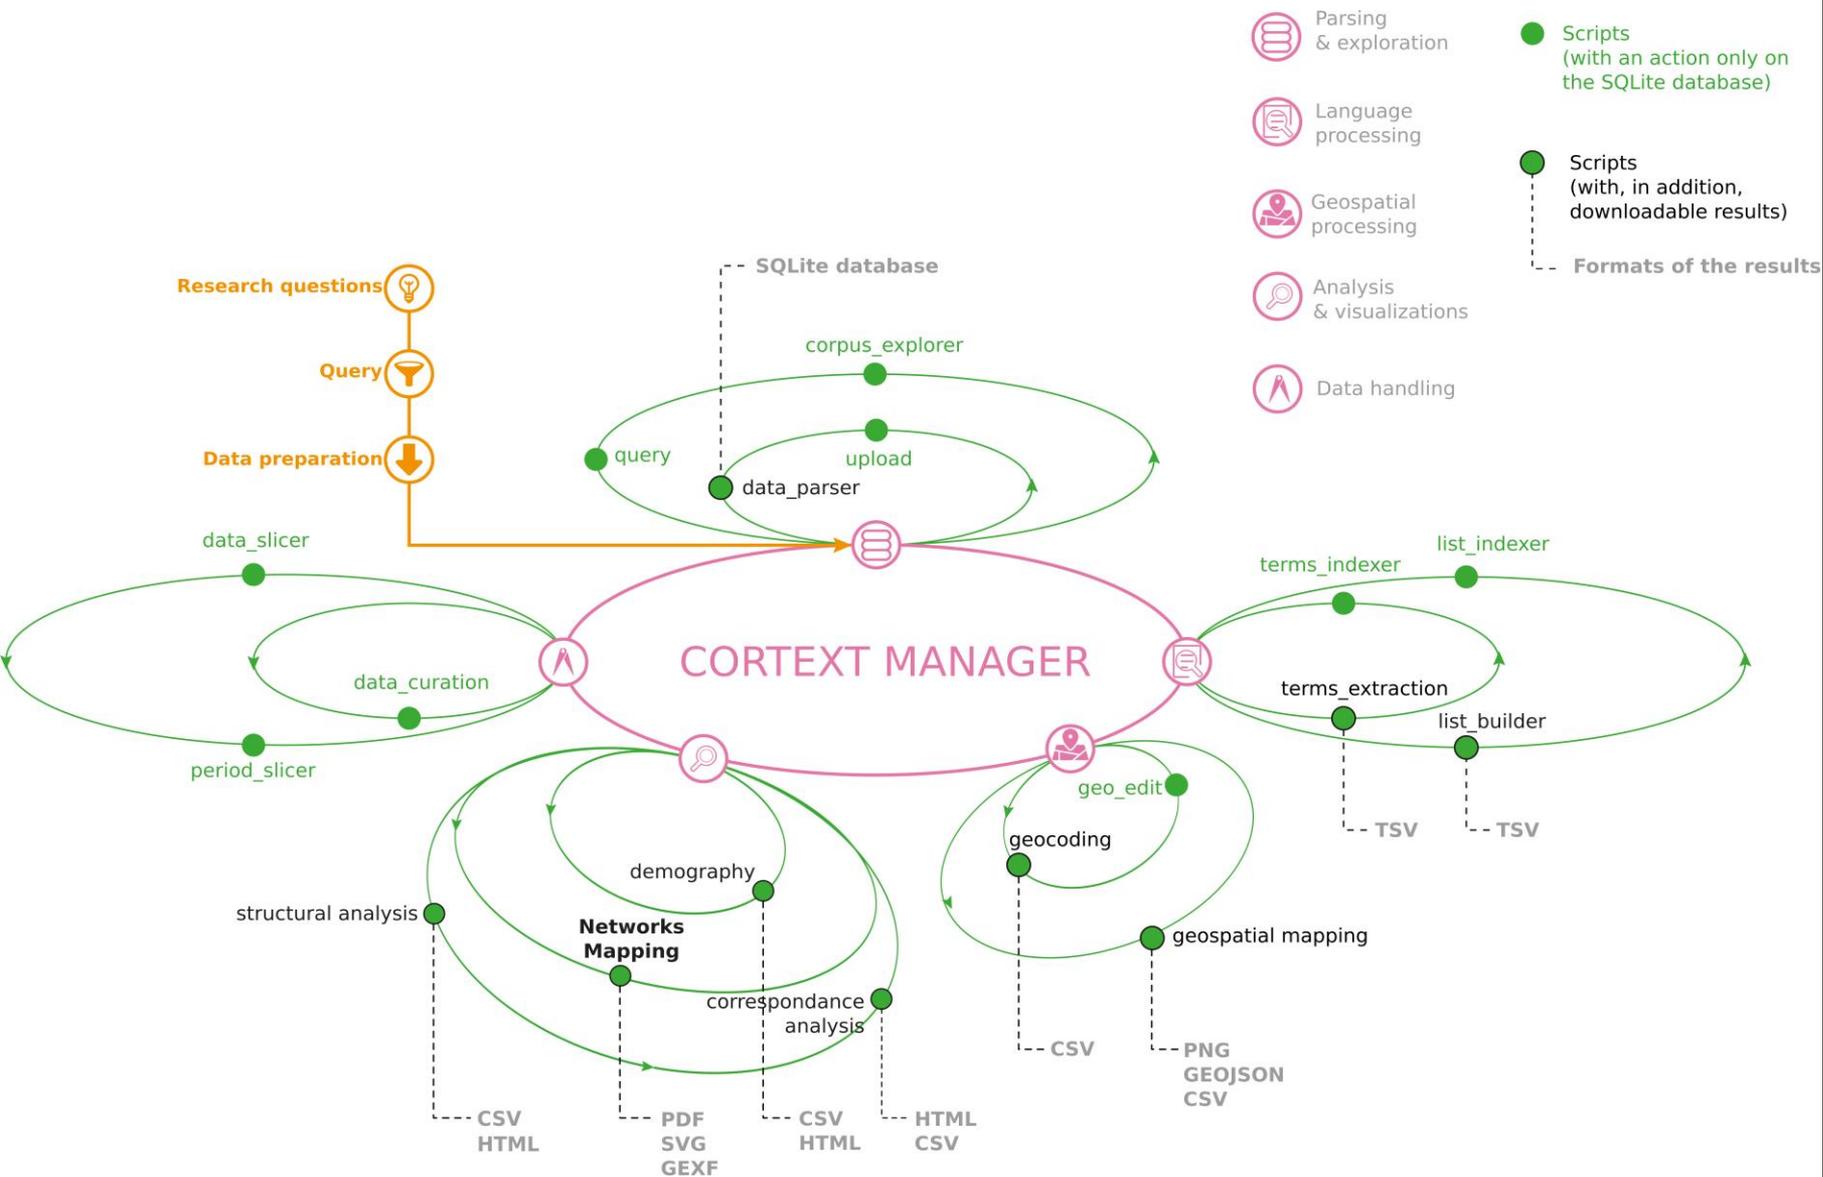


Nombre de clusters
(espaces sémantiques)

Exemples de métriques

- Nombre de clusters
- Densité du réseau
- Réseau centralisé ou distribué
- ...

CorText Manager galaxy



Aller plus loin

 @CorText_team

→ <https://docs.cortext.net/trainings/cortext-cnrs-tdm-2022/>

Et

→ <https://managerv2.cortext.net/project/161250003210>