

Master Intelligence stratégique, analyse des risques et territoires  
07/11/2016 – IFIS (Serris)

# *Analyse de données textuelles en pratique : logiciels de textométrie et arbres de mots*

Philippe Gambette

LIGM  
Université Paris-Est  
Marne-la-Vallée



# **Panorama des logiciels de textométrie**

# Quelques logiciels de textométrie

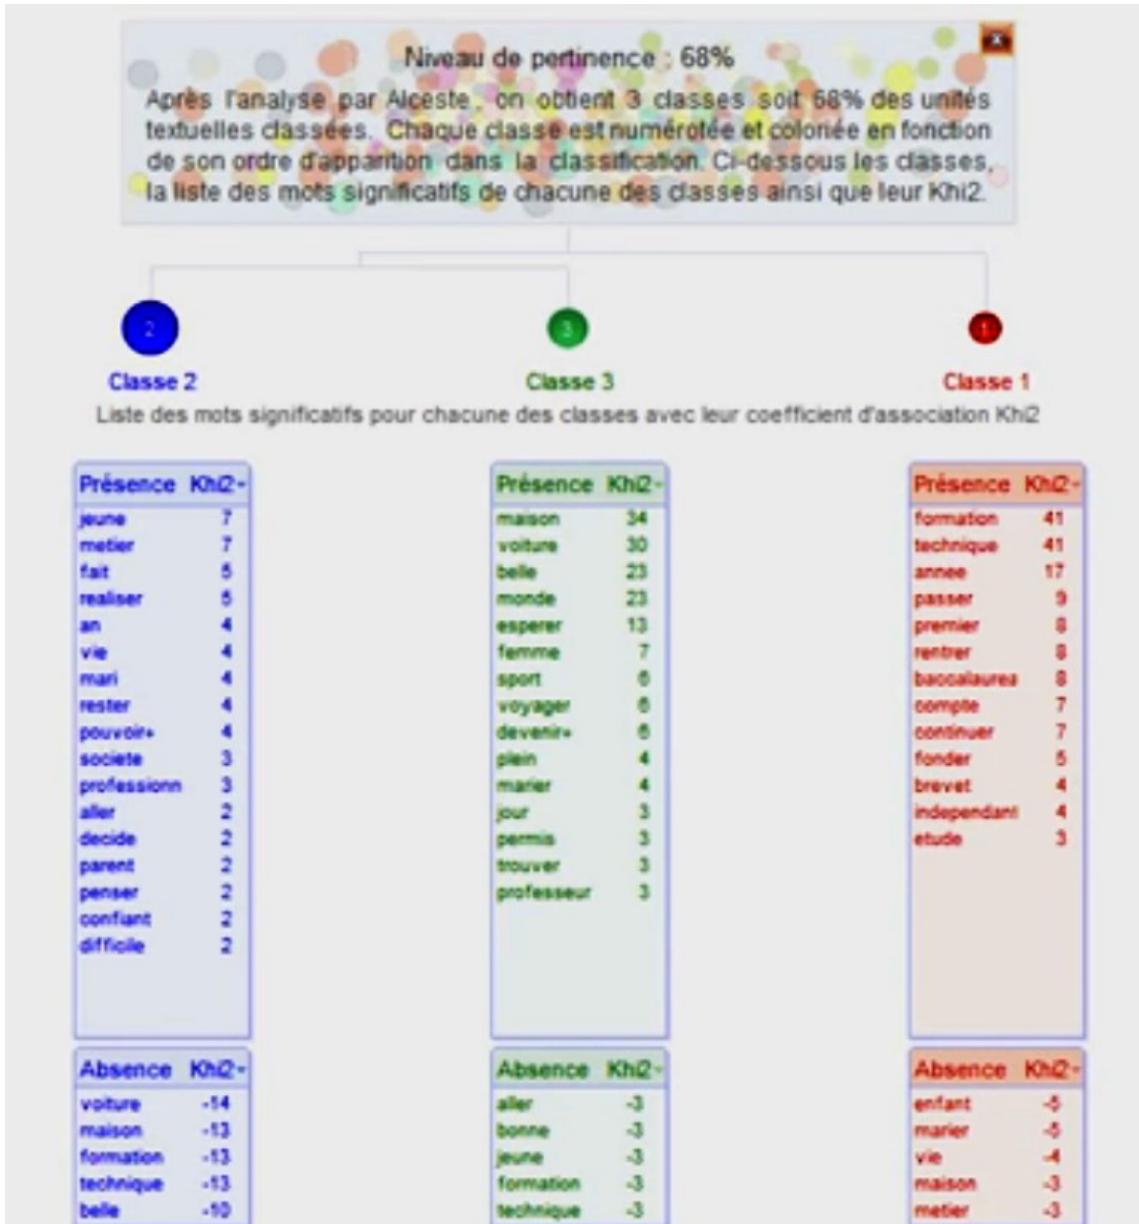
**Alceste (depuis 1983)**



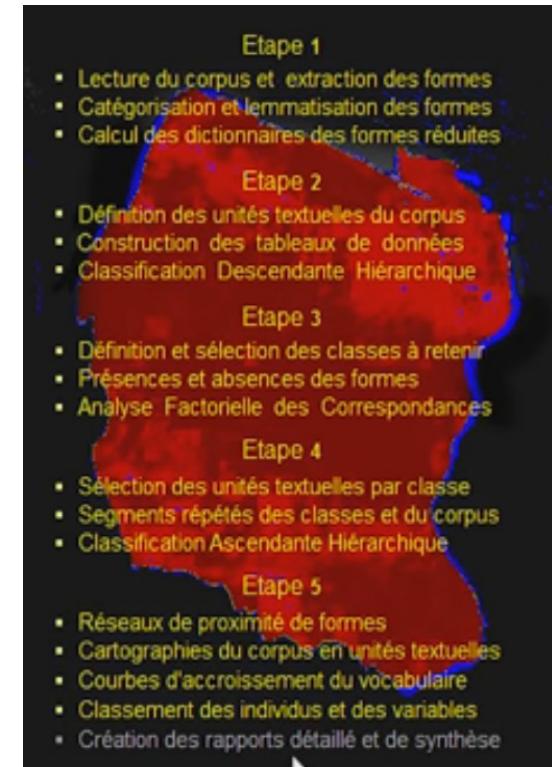
Société IMAGE

<http://www.image-zafar.com/Logiciel.html>

# La méthode Alceste



Répartition des phrases du texte en différentes classes  
→ vocabulaire de chaque classe



# Quelques logiciels de textométrie

**Hyperbase (depuis 1989)**



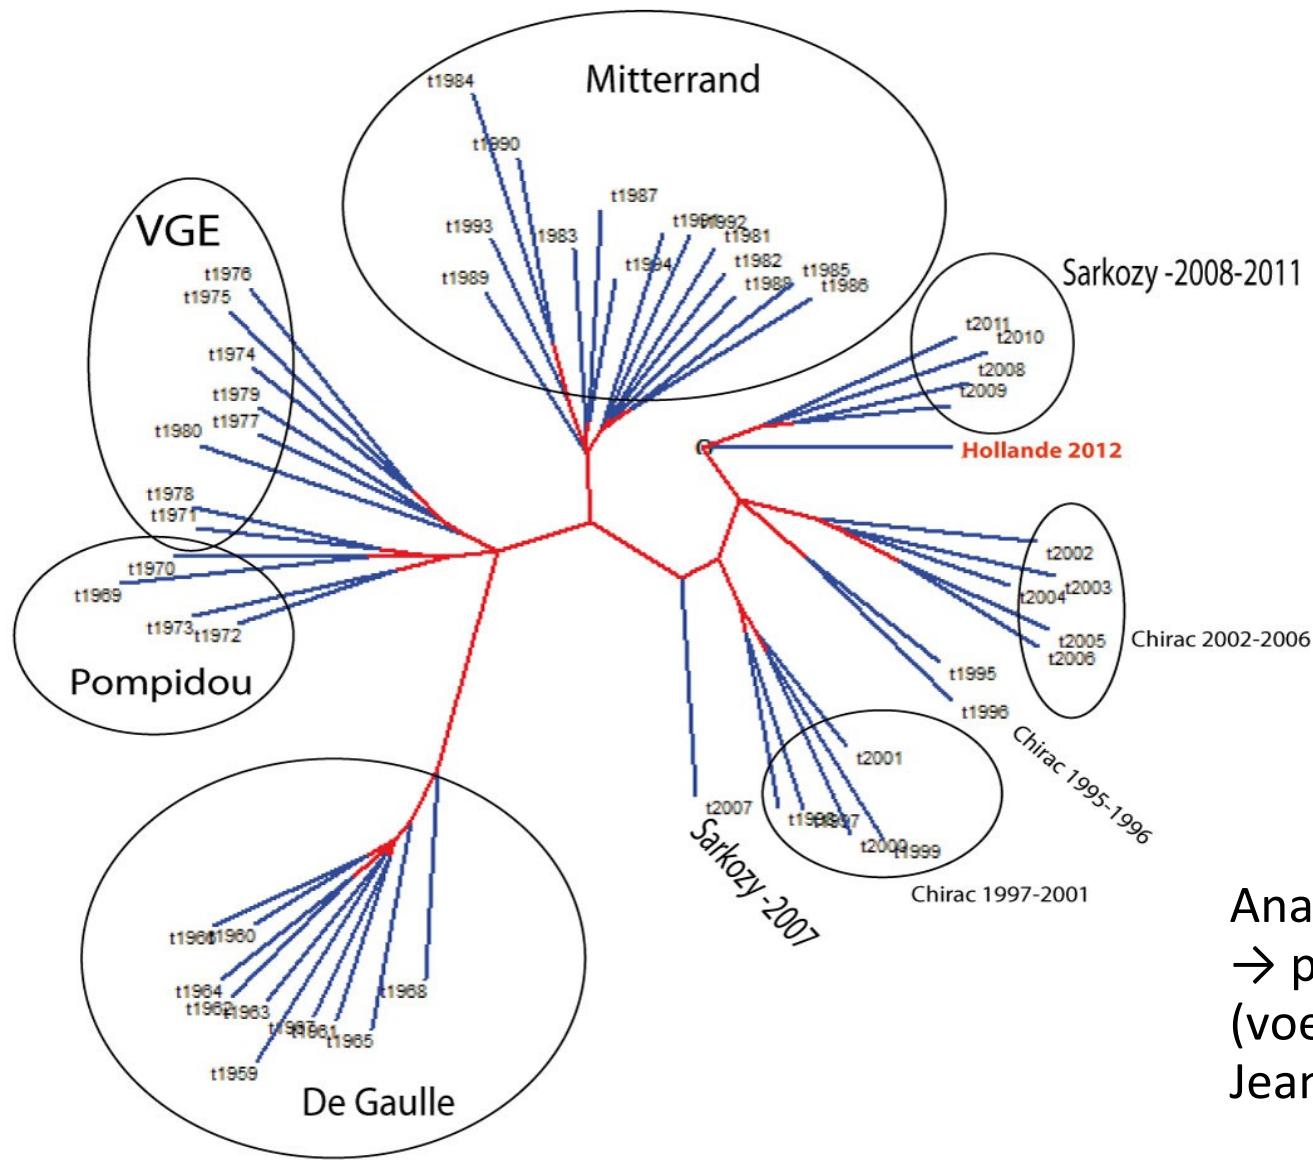
Université de Nice Sophia-Antipolis  
<http://logometrie.unice.fr>

**Alceste (depuis 1983)**



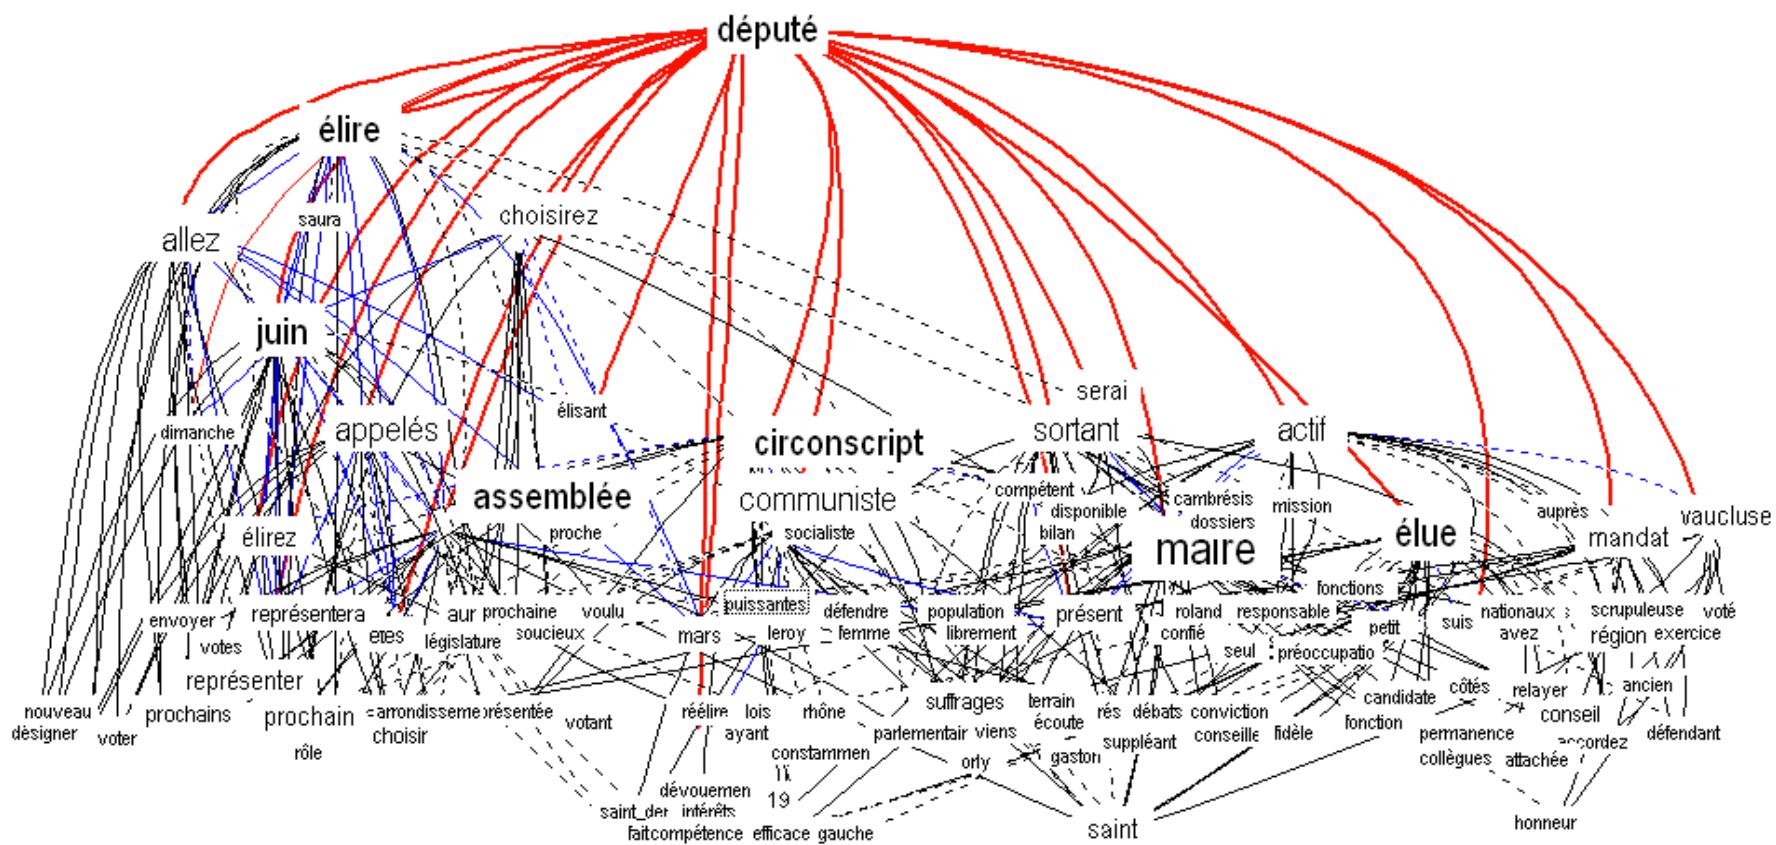
Société IMAGE  
<http://www.image-zafar.com/Logiciel.html>

# Hyperbase



Analyse arborée  
→ proximité des textes  
(voeux présidentiels,  
Jean-Marc Leblanc)

# Hyperbase

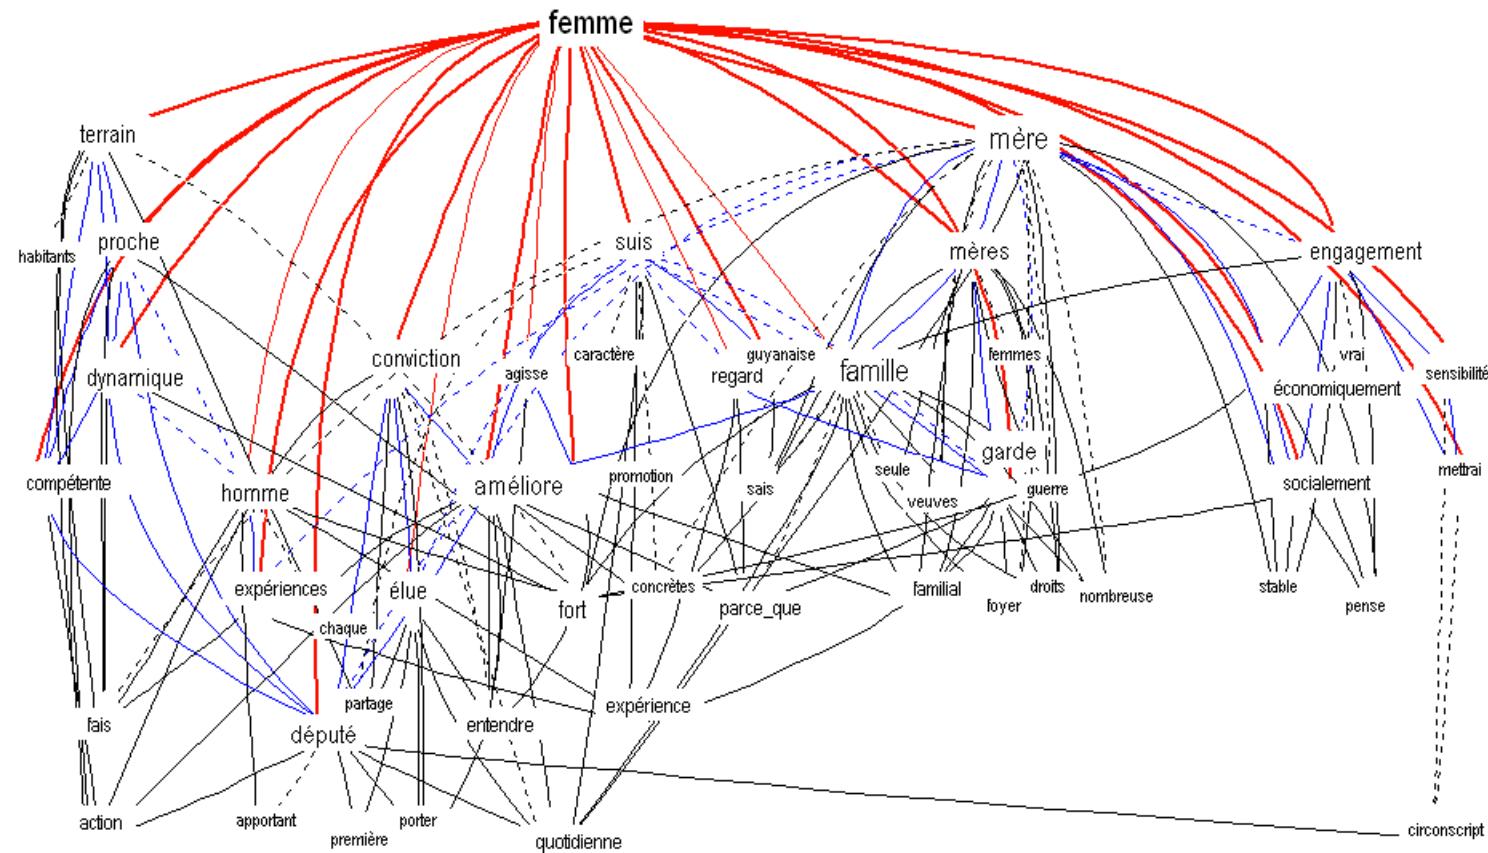


Réseau de cooccurrents d'un mot

→ graphique des co-occurrences directs et indirects du mot-pôle « député » dans l'ensemble du corpus de Professions de foi

Magali Guaresi (2014) L'approche co-occurrencelle, un bond qualitatif ? L'environnement lexical du lemme « député » dans les Professions de foi des candidates à la députation (1958 – 2002)  
<https://corela.revues.org/3586?lang=fr>

# Hyperbase



Réseau de cooccurrents d'un mot

→ graphique des co-occurrences directs et indirects du mot-pôle « femme » dans le corpus des Professions de foi de candidates

Magali Guaresi (2014) L'approche co-occurentielle, un bond qualitatif ? L'environnement lexical du lemme « député » dans les Professions de foi des candidates à la députation (1958 – 2002)

<https://corela.revues.org/3586?lang=fr>

# Quelques logiciels de textométrie

Hyperbase (depuis 1989)



Université de Nice Sophia-Antipolis  
<http://logometrie.unice.fr>

Lexico (depuis 1990)



Université Sorbonne nouvelle  
<http://lexi-co.com/>

Alceste (depuis 1983)



Société IMAGE  
<http://www.image-zafar.com/Logiciel.html>

# Lexico

Lexico3 - [Section - Délimiteurs : § - vue n°1]

Fichier Traitement Fenêtre

Lexico 3

Navigation | Rapport | Dictionnaire | Segments répétés

Repile 1

| Lg | Segment                            | Frq |
|----|------------------------------------|-----|
| 2  | la constitution                    | 40  |
| 2  | la contre                          | 39  |
| 3  | la convention a                    | 15  |
| 2  | la convention                      | 187 |
| 2  | la cour                            | 11  |
| 2  | la crête                           | 11  |
| 2  | la danse                           | 12  |
| 2  | la dernière                        | 15  |
| 2  | la disette                         | 10  |
| 2  | la famine                          | 14  |
| 2  | la fête                            | 12  |
| 2  | la fin                             | 22  |
| 2  | la force                           | 16  |
| 2  | la foudre                          | 13  |
| 2  | la garce                           | 10  |
| 2  | la gloire                          | 17  |
| 6  | la grande colère du "père "duch... | 54  |
| 3  | la grande colère                   | 55  |
| 6  | la grande joie du "père "duchesne  | 36  |
| 4  | la grande joie du                  | 37  |
| 2  | la grande                          | 113 |
| 3  | la guerre civile                   | 32  |
| 2  | la guerre                          | 99  |
| 2  | la guillotine                      | 32  |
| 2  | la journée                         | 17  |
| 2  | la justice                         | 13  |
| 2  | la langue                          | 10  |
| 4  | la liberté et l                    | 12  |
| 3  | la liberté et                      | 14  |
| 2  | la liberté                         | 202 |
| 2  | la linotte                         | 34  |
| 2  | la loi                             | 38  |
| 3  | la louve autrichienne              | 19  |
| 2  | la louve                           | 21  |
| 2  | la main                            | 80  |
| 2  | la même                            | 19  |
| 2  | la misère                          | 20  |
| 2  | la moitié                          | 13  |
| 2  | la montagne                        | 22  |
| 2  | la mort                            | 43  |

9 <Aucune>

50  
100  
150  
200  
250  
300  
350  
400  
450  
500  
550  
600

Segments répétés et carte des sections

Section :

Occurrence :

la grande douleur du "père "duchesne au sujet de la mort de "marat assassiné à coups de couteau par une garce du "calvados , dont l ' évêque "fauchet était le directeur . ses bons avis aux braves "sans - culottes pour qu ' ils se tiennent sur leurs gardes , attendu qu ' il y a dans "paris plusieurs milliers de tondus de la "vendée qui ont la patte graissée pour égorger tous les bons citoyens . <edito=1>§

C:\Program Files\Lexico 3\Duchn.par

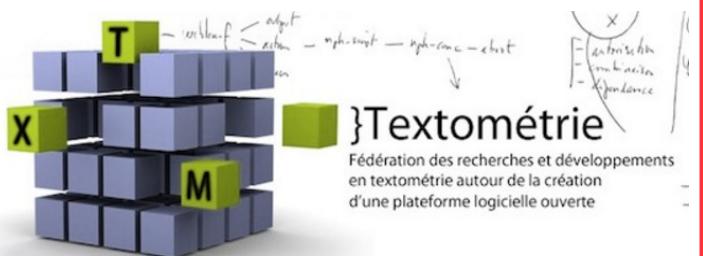
# Quelques logiciels de textométrie

## Hyperbase (depuis 1989)



Université de Nice Sophia-Antipolis  
<http://logometrie.unice.fr>

## TXM (depuis 2008)



ENS Lyon  
<http://textometrie.ens-lyon.fr/>

## Lexico (depuis 1990)

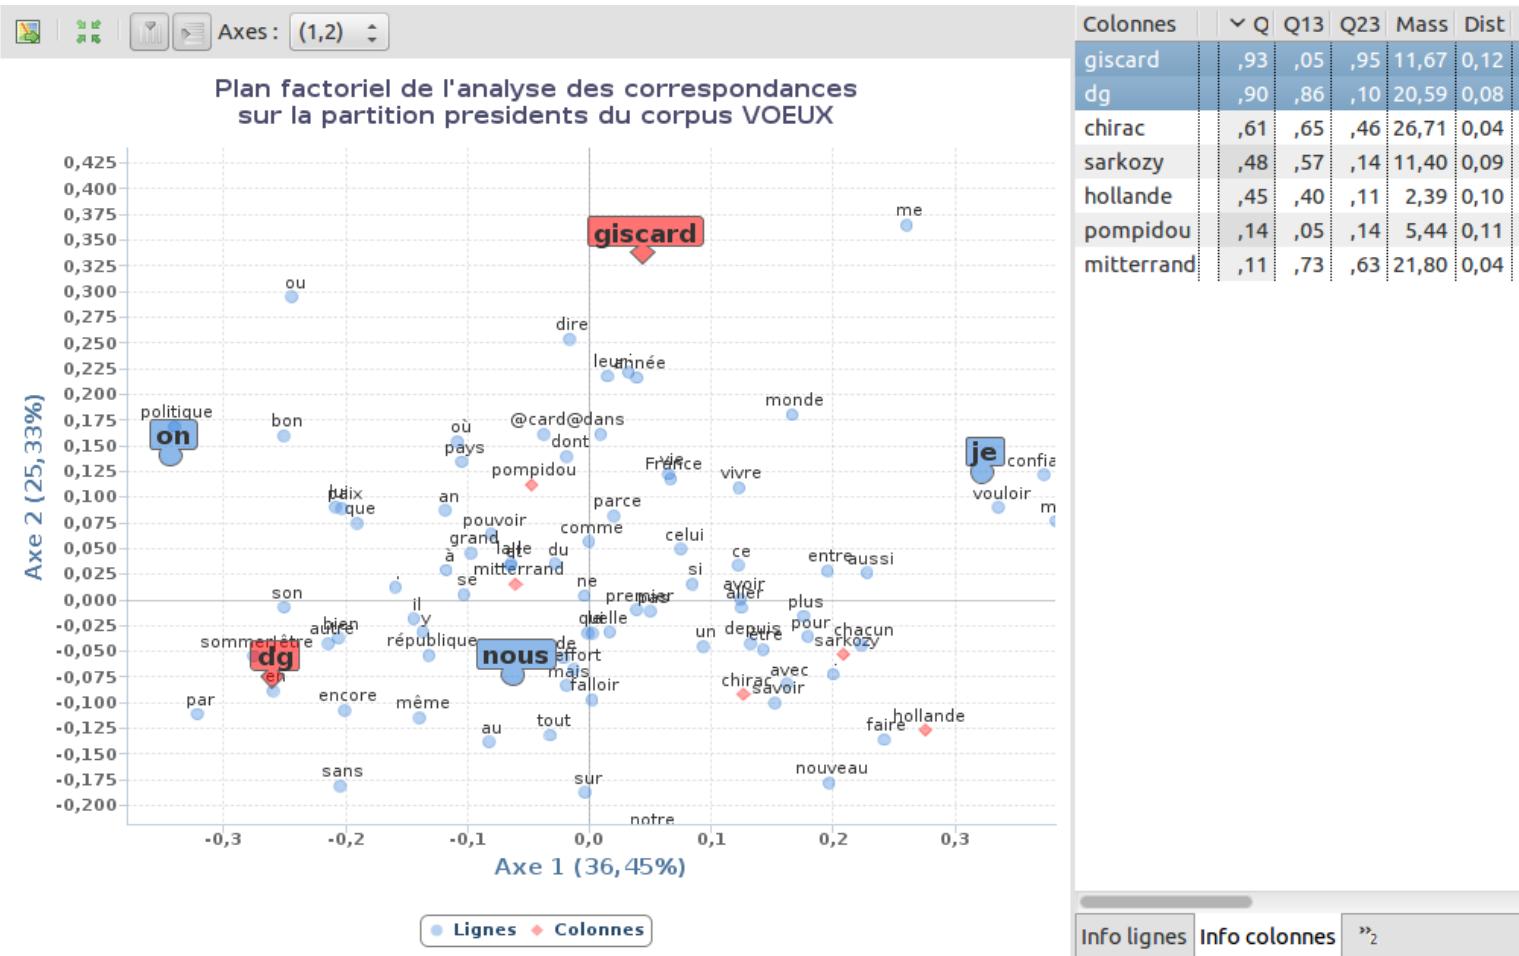


Université Sorbonne nouvelle  
<http://lexi-co.com/>

## Alceste (depuis 1983)



Société IMAGE  
<http://www.image-zafar.com/Logiciel.html>



## Analyse factorielle des correspondances

→ Affichage des points lignes (mots) et des points colonnes (discours) pour les discours de voeux présidentiels

# Quelques logiciels de textométrie

## Hyperbase (depuis 1989)



Université de Nice Sophia-Antipolis  
<http://logometrie.unice.fr>

## TXM (depuis 2008)



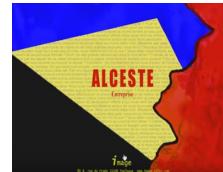
ENS Lyon  
<http://textometrie.ens-lyon.fr/>

## Lexico (depuis 1990)



Université Sorbonne nouvelle  
<http://lexi-co.com/>

## Alceste (depuis 1983)

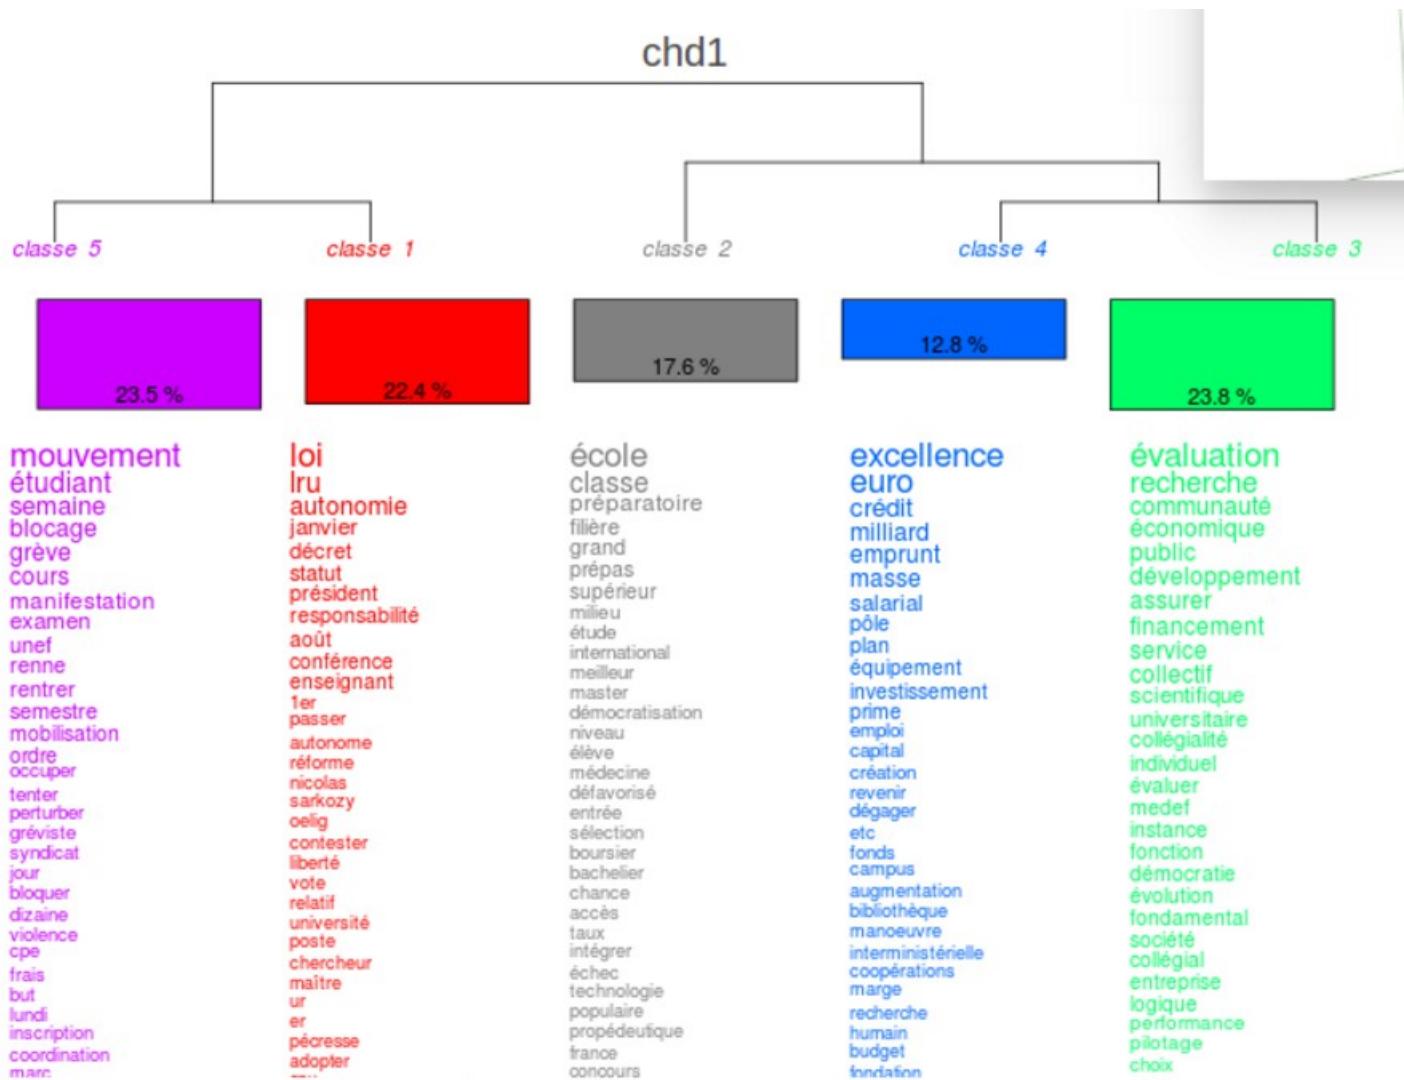


Société IMAGE  
<http://www.image-zafar.com/Logiciel.html>

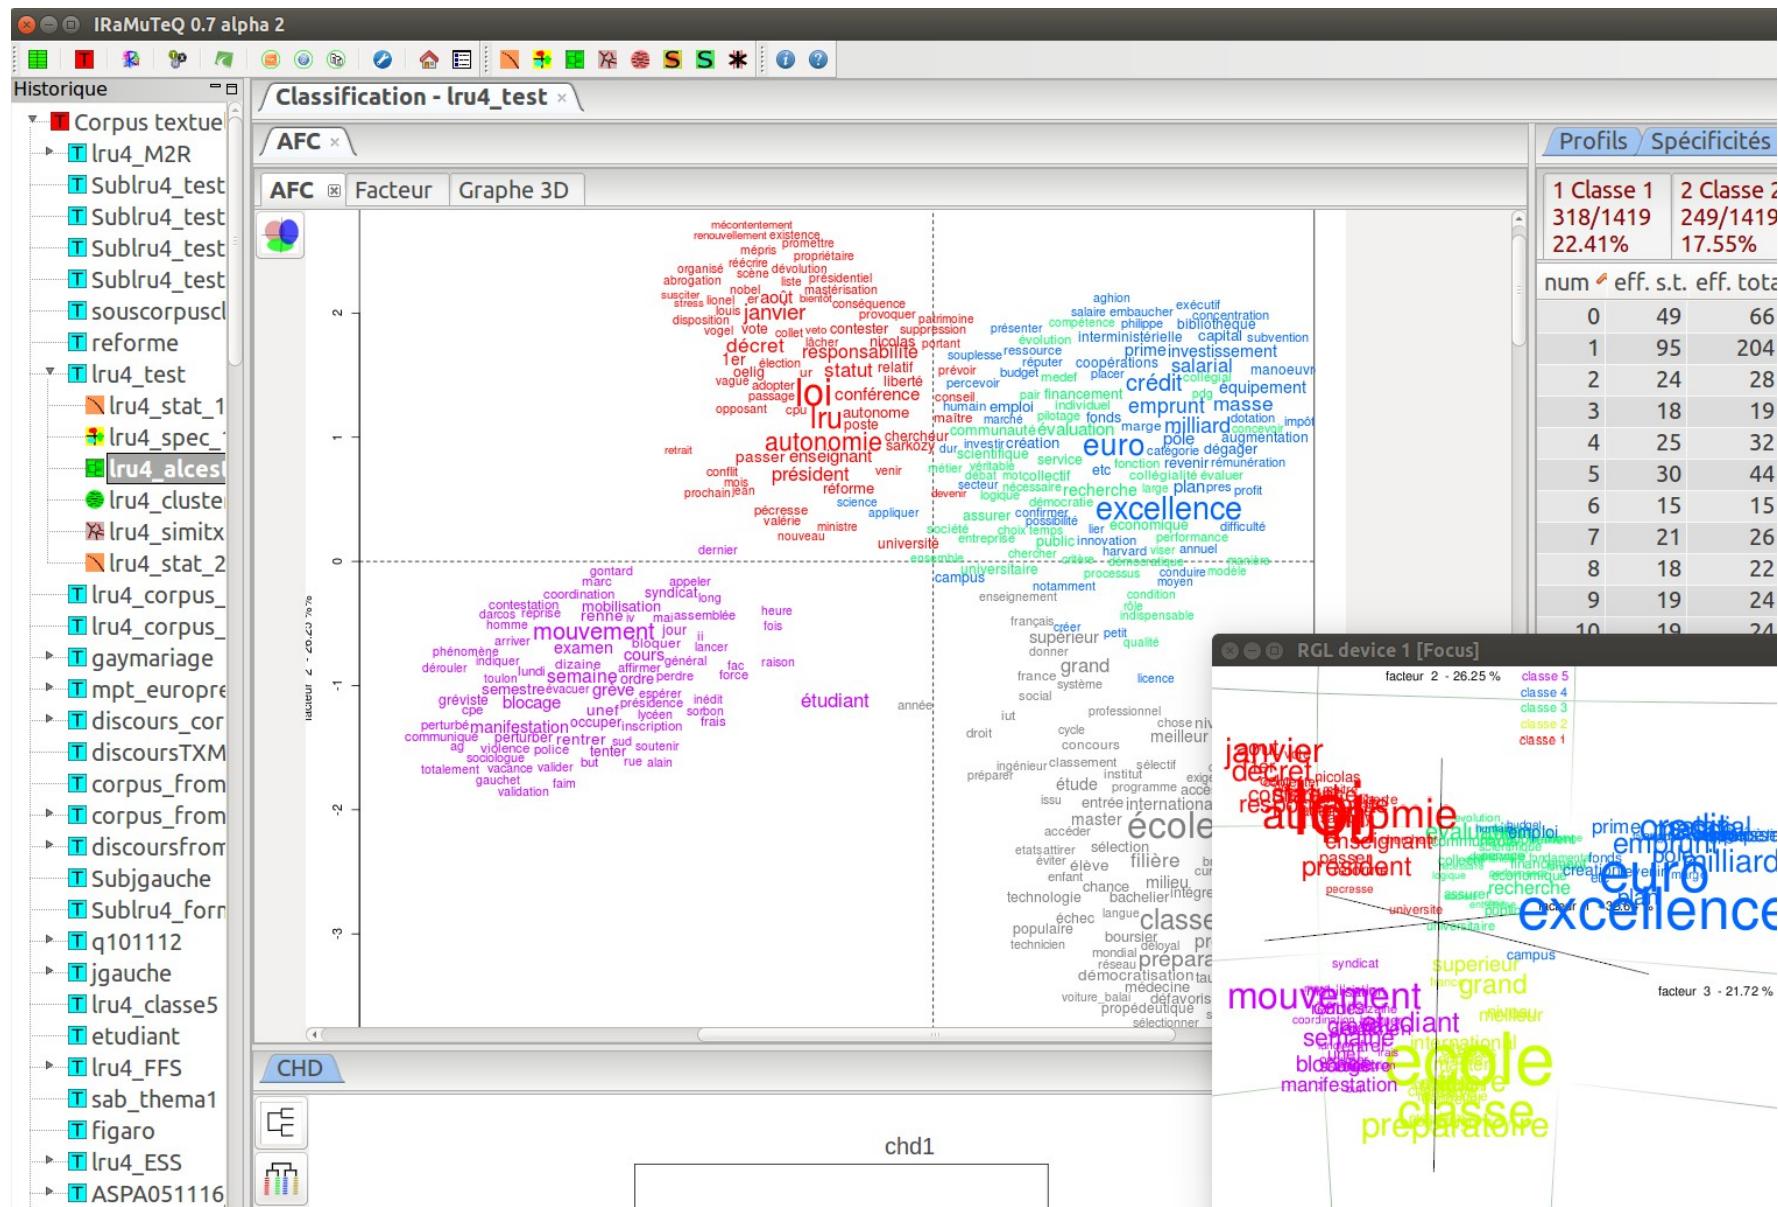
## Iramuteq (depuis 2009)



Université de Toulouse  
<http://www.iramuteq.org/>



# Iramuteq



# Quelques logiciels de textométrie

## Hyperbase (depuis 1989)



Université de Nice Sophia-Antipolis  
<http://logometrie.unice.fr>

## TXM (depuis 2008)



ENS Lyon  
<http://textometrie.ens-lyon.fr/>

## Lexico (depuis 1990)



Université Sorbonne nouvelle  
<http://lexi-co.com/>

## Alceste (depuis 1983)



Société IMAGE  
<http://www.image-zafar.com/Logiciel.html>

## Iramuteq (depuis 2009)



Université de Toulouse  
<http://www.iramuteq.org/>

# Caractéristiques des logiciels de textométrie

## Approches exploratoires

- explorer, générer des hypothèses : **visualisations**
- évaluer la pertinence d'une hypothèse :
  - indicateurs **statistiques**
  - **retour au texte**

# Exemple d'exploration : articles scientifiques

## Etape 1) Récupération du corpus (Scopus) et formatage (Lexico 3)

<annee=2015> <type=article> <doc=a1> background: lateral, or horizontal, gene transfers are a type of asymmetric evolutionary events where genetic material is transferred from one species to another. in this paper we consider lgt networks, a general model of phylogenetic networks with lateral gene transfers which consist, roughly, of a principal rooted tree with its leaves labelled on a set of taxa, and a set of extra secondary arcs between nodes in this tree representing lateral gene transfers. an lgt network gives rise in a natural way to a principal phylogenetic subtree and a set of secondary phylogenetic subtrees, which, roughly, represent, respectively, the main line of evolution of most genes and the secondary lines of evolution through lateral gene transfers. results: we introduce a set of simple conditions on an lgt network that guarantee that its principal and secondary phylogenetic subtrees are pairwise different and that these subtrees determine, up to isomorphism, the lgt network. we then give an algorithm that, given a set of pairwise different phylogenetic trees  $t_0, t_1, \dots, t_k$  on the same set of taxa, outputs, when it exists, the lgt network that satisfies these conditions and such that its principal phylogenetic tree is  $t_0$  and its secondary phylogenetic trees are  $t_1, \dots, t_k$ .

<annee=2015> <type=article> <doc=a2> this article presents an innovative approach to phylogenies based on the reduction of multistate characters to binary-state characters. we show that the reduction to binary characters' approach can be applied to both character- and distance-based phylogenies and provides a unifying framework to explain simply and intuitively the similarities and differences between distance- and character-based phylogenies. building on these results, this article gives a possible explanation on why phylogenetic trees obtained from a distance matrix or a set of characters are often quite reasonable despite lateral transfers of genetic material between taxa. in the presence of lateral transfers, outer planar networks furnish a better description of evolution than phylogenetic trees. we present a polynomial-time reconstruction algorithm for perfect outer planar networks with a fixed number of states, characters, and lateral transfers.

<annee=2015> <type=article> <doc=a3> background: many problems in comparative biology are, or are thought to be, best expressed as phylogenetic "networks" as opposed to trees. in trees, vertices may have only a single parent (ancestor), while networks allow for multiple parent vertices. there are two main interpretive

# Exemple d'exploration : articles scientifiques

## Etape 1) Récupération du corpus (Scopus) et formatage (Lexico 3)

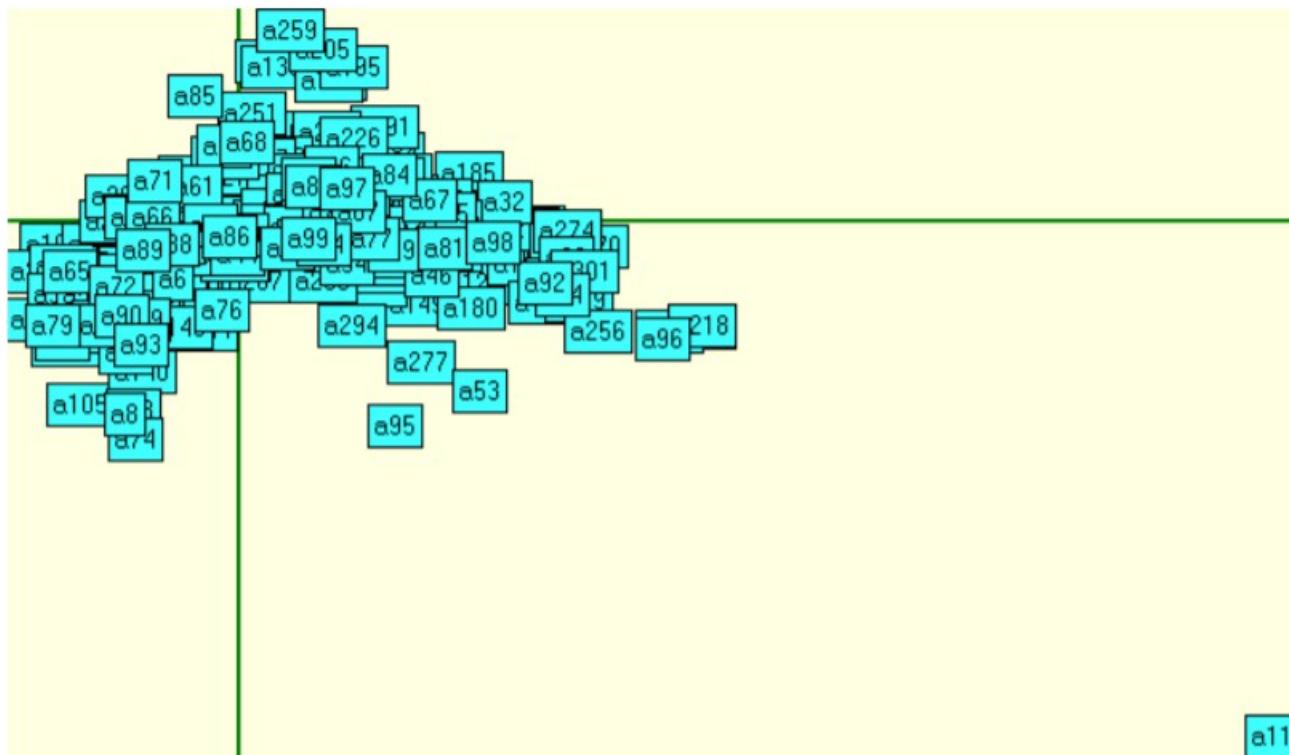
**<annee=2015> <type=article> <doc=a1>** background: lateral, or horizontal, gene transfers are a type of asymmetric evolutionary events where genetic material is transferred from one species to another. in this paper we consider lgt networks, a general model of phylogenetic networks with lateral gene transfers which consist, roughly, of a principal rooted tree with its leaves labelled on a set of taxa, and a set of extra secondary arcs between nodes in this tree representing lateral gene transfers. an lgt network gives rise in a natural way to a principal phylogenetic subtree and a set of secondary phylogenetic subtrees, which, roughly, represent, respectively, the main line of evolution of most genes and the secondary lines of evolution through lateral gene transfers. results: we introduce a set of simple conditions on an lgt network that guarantee that its principal and secondary phylogenetic subtrees are pairwise different and that these subtrees determine, up to isomorphism, the lgt network. we then give an algorithm that, given a set of pairwise different phylogenetic trees  $t_0, t_1, \dots, t_k$  on the same set of taxa, outputs, when it exists, the lgt network that satisfies these conditions and such that its principal phylogenetic tree is  $t_0$  and its secondary phylogenetic trees are  $t_1, \dots, t_k$ .

**<annee=2015> <type=article> <doc=a2>** this article presents an innovative approach to phylogenies based on the reduction of multistate characters to binary-state characters. we show that the reduction to binary characters' approach can be applied to both character- and distance-based phylogenies and provides a unifying framework to explain simply and intuitively the similarities and differences between distance- and character-based phylogenies. building on these results, this article gives a possible explanation on why phylogenetic trees obtained from a distance matrix or a set of characters are often quite reasonable despite lateral transfers of genetic material between taxa. in the presence of lateral transfers, outer planar networks furnish a better description of evolution than phylogenetic trees. we present a polynomial-time reconstruction algorithm for perfect outer planar networks with a fixed number of states, characters, and lateral transfers.

**<annee=2015> <type=article> <doc=a3>** background: many problems in comparative biology are, or are thought to be, best expressed as phylogenetic "networks" as opposed to trees. in trees, vertices may have only a single parent (ancestor), while networks allow for multiple parent vertices. there are two main interpretive

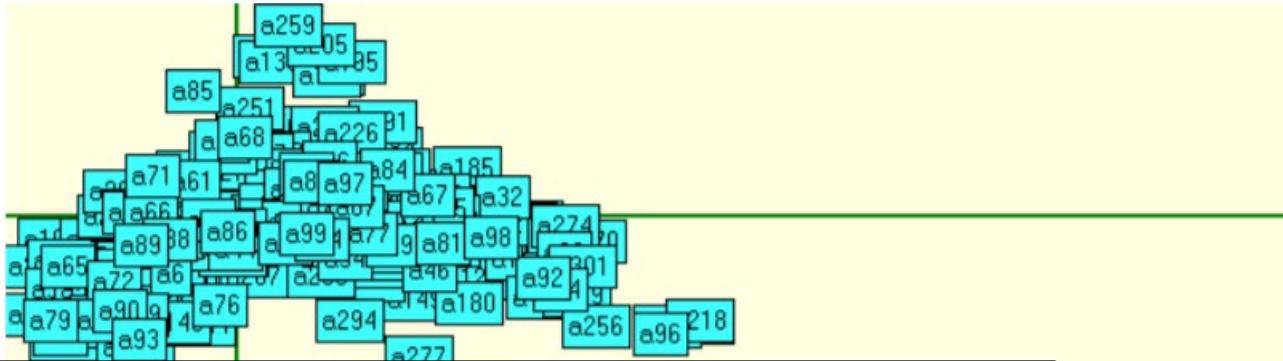
# Exemple d'exploration : articles scientifiques

Etape 2) Analyse factorielle des correspondances

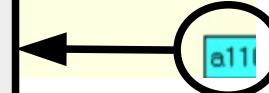


# Exemple d'exploration : articles scientifiques

## Etape 2) Analyse factorielle des correspondances

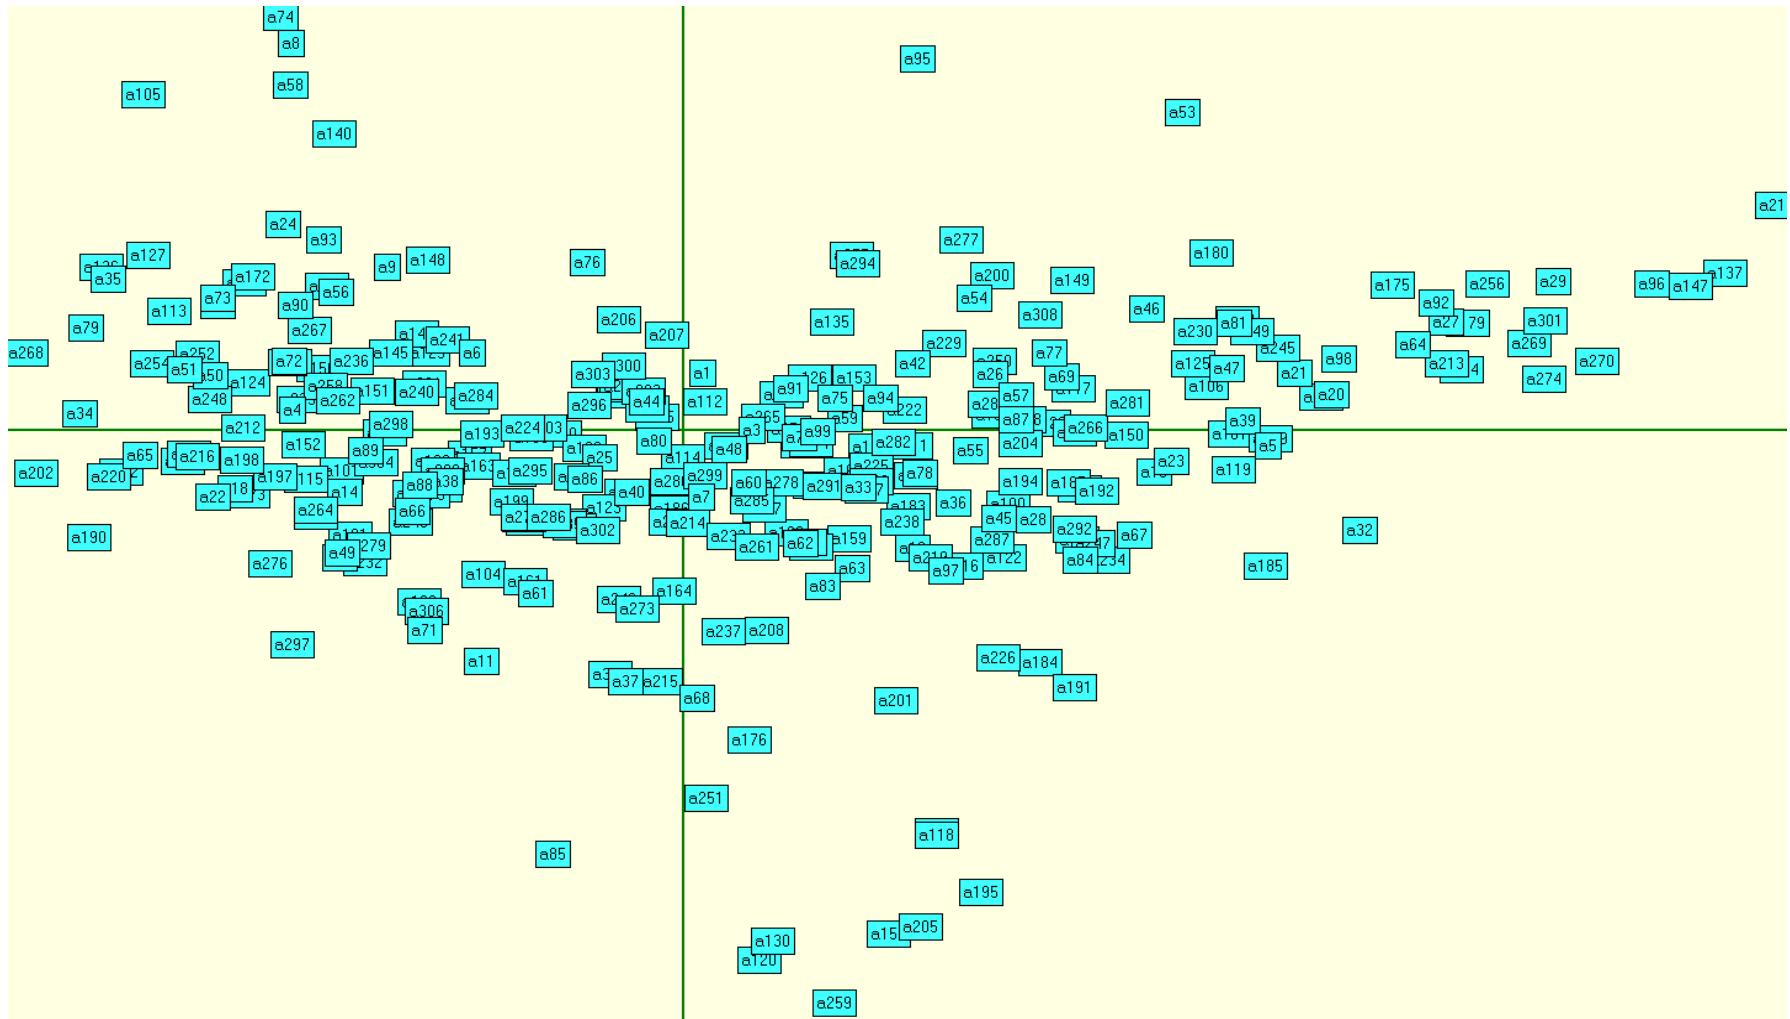


we study the asymptotic behavior of a new type of maximization recurrence, defined as follows. let  $k$  be a positive integer and  $p_k(x)$  a polynomial of degree  $k$  satisfying  $p_k(0) = 0$ . define  $a_0 = 0$  and for  $n \geq 1$ , let  $a_n = \max_{0 \leq i < n} \{a_i + n^{-k} p_k(i/n)\}$ . we prove that  $\lim_{n \rightarrow \infty} a_n/n = \sup\{p_k(x)/1-x^k : 0 \leq x < 1\}$ . we also consider two closely related maximization recurrences  $s_n$  and  $s'_n$ , defined as  $s_0 = s'_0 = 0$ , and for  $n \geq 1$ ,  $s_n = \max_{0 \leq i < n} \{s_i + i(n-i)(n-i-1)/2\}$  and  $s'_n = \max_{0 \leq i < n} \{s'_i + (3n-i) + 2i(2n-i) + (n-i)(2i)\}$ . we prove that  $\lim_{n \rightarrow \infty} s'_n/(3n) = 2(\sqrt{3}-1)/3 \approx 0.488033\dots$ , resolving an open problem from bioinformatics about rooted triplets consistency in phylogenetic networks.



# Exemple d'exploration : articles scientifiques

Etape 2) Analyse factorielle des correspondances (sans a110)



# Exemple d'exploration : articles scientifiques

## Etape 3) Analyse statistique

### Termes sur-représentés à gauche

| Terme          | Frq Tot. | Frq Pa... | Spécif |
|----------------|----------|-----------|--------|
| gene           | 412      | 342       | 44     |
| hgt            | 110      | 110       | 34     |
| reconciliation | 70       | 68        | 19     |
| transfer       | 134      | 111       | 15     |
| genes          | 88       | 77        | 14     |
| and            | 1320     | 792       | 14     |
| methods        | 208      | 154       | 13     |
| species        | 261      | 186       | 12     |
| lineage        | 32       | 32        | 11     |
| model          | 130      | 101       | 11     |
| method         | 168      | 122       | 10     |
| event          | 34       | 33        | 10     |
| phylogeny      | 52       | 47        | 10     |
| accurate       | 32       | 31        | 9      |
| data           | 227      | 155       | 9      |
| horizontal     | 77       | 63        | 9      |
| events         | 232      | 160       | 9      |
| population     | 26       | 26        | 9      |
| genome         | 49       | 44        | 9      |
| likelihood     | 39       | 36        | 9      |
| evolutionary   | 279      | 188       | 9      |
| coalescent     | 31       | 30        | 9      |
| consensus      | 24       | 24        | 8      |
| inference      | 40       | 36        | 8      |
| role           | 30       | 29        | 8      |
| detection      | 24       | 24        | 8      |
| families       | 27       | 26        | 8      |
| sorting        | 29       | 28        | 8      |
| inferring      | 47       | 41        | 8      |
| vertical       | 23       | 23        | 8      |

### Termes sous-représentés à gauche

| Terme        | Frq Tot. | Frq Pa... | Spécif |
|--------------|----------|-----------|--------|
| child        | 24       | 1         | -7     |
| 2            | 47       | 8         | -7     |
| m            | 37       | 4         | -7     |
| split        | 79       | 19        | -7     |
| e            | 53       | 10        | -7     |
| constructing | 53       | 8         | -8     |
| galled       | 40       | 4         | -8     |
| construct    | 48       | 7         | -8     |
| graph        | 60       | 11        | -8     |
| binary       | 75       | 16        | -8     |
| t            | 51       | 6         | -9     |
| input        | 83       | 16        | -9     |
| given        | 137      | 36        | -9     |
| distance     | 120      | 30        | -9     |
| d            | 33       | 1         | -9     |
| consistent   | 54       | 7         | -9     |
| class        | 34       | 2         | -9     |
| x            | 47       | 4         | -10    |
| polynomial   | 62       | 7         | -11    |
| problem      | 240      | 72        | -11    |
| number       | 206      | 56        | -12    |
| level        | 93       | 14        | -13    |
| 1            | 71       | 7         | -13    |
| a            | 1675     | 701       | -13    |
| is           | 922      | 360       | -13    |
| leaves       | 54       | 2         | -14    |
| if           | 95       | 12        | -15    |
| set          | 252      | 68        | -15    |
| k            | 69       | 4         | -16    |
| o            | 73       | 4         | -17    |

# Exemple d'exploration : articles scientifiques

## Etape 3) Analyse statistique

### Termes sur-représentés à gauche

| Terme          | Frq Tot. | Frq Pa... | Spécif |
|----------------|----------|-----------|--------|
| gene           | 412      | 342       | 44     |
| hgt            | 110      | 110       | 34     |
| reconciliation | 70       | 68        | 19     |
| transfer       | 134      | 111       | 15     |
| genes          | 88       | 77        | 14     |
| and            | 1320     | 792       | 14     |
| methods        | 208      | 154       | 13     |
| species        | 261      | 186       | 12     |
| lineage        | 32       | 32        | 11     |
| model          | 130      | 101       | 11     |
| method         | 168      | 122       | 10     |
| event          | 34       | 33        | 10     |
| phylogeny      | 52       | 47        | 10     |
| accurate       | 32       | 31        | 9      |
| data           | 227      | 155       | 9      |
| horizontal     | 77       | 63        | 9      |
| events         | 232      | 160       | 9      |
| population     | 26       | 26        | 9      |
| genome         | 49       | 44        | 9      |
| likelihood     | 39       | 36        | 9      |
| evolutionary   | 279      | 188       | 9      |
| coalescent     | 31       | 30        | 9      |
| consensus      | 24       | 24        | 8      |
| inference      | 40       | 36        | 8      |
| role           | 30       | 29        | 8      |
| detection      | 24       | 24        | 8      |
| families       | 27       | 26        | 8      |
| sorting        | 29       | 28        | 8      |
| inferring      | 47       | 41        | 8      |
| vertical       | 23       | 23        | 8      |

**Spécificité**  
**>2 ou <-2 :**  
**statistiquement**  
**significatif !**

### Termes sous-représentés à gauche

| Terme        | Frq Tot. | Frq Pa... | Spécif |
|--------------|----------|-----------|--------|
| child        | 24       | 1         | -7     |
| 2            | 47       | 8         | -7     |
| m            | 37       | 4         | -7     |
| split        | 79       | 19        | -7     |
| e            | 53       | 10        | -7     |
| constructing | 53       | 8         | -8     |
| galled       | 40       | 4         | -8     |
| construct    | 48       | 7         | -8     |
| graph        | 60       | 11        | -8     |
| binary       | 75       | 16        | -8     |
| t            | 51       | 6         | -9     |
| input        | 83       | 16        | -9     |
| given        | 137      | 36        | -9     |
| distance     | 120      | 30        | -9     |
| d            | 33       | 1         | -9     |
| consistent   | 54       | 7         | -9     |
| class        | 34       | 2         | -9     |
| x            | 47       | 4         | -10    |
| polynomial   | 62       | 7         | -11    |
| problem      | 240      | 72        | -11    |
| number       | 206      | 56        | -12    |
| level        | 93       | 14        | -13    |
| 1            | 71       | 7         | -13    |
| a            | 1675     | 701       | -13    |
| is           | 922      | 360       | -13    |
| leaves       | 54       | 2         | -14    |
| if           | 95       | 12        | -15    |
| set          | 252      | 68        | -15    |
| k            | 69       | 4         | -16    |
| o            | 73       | 4         | -17    |

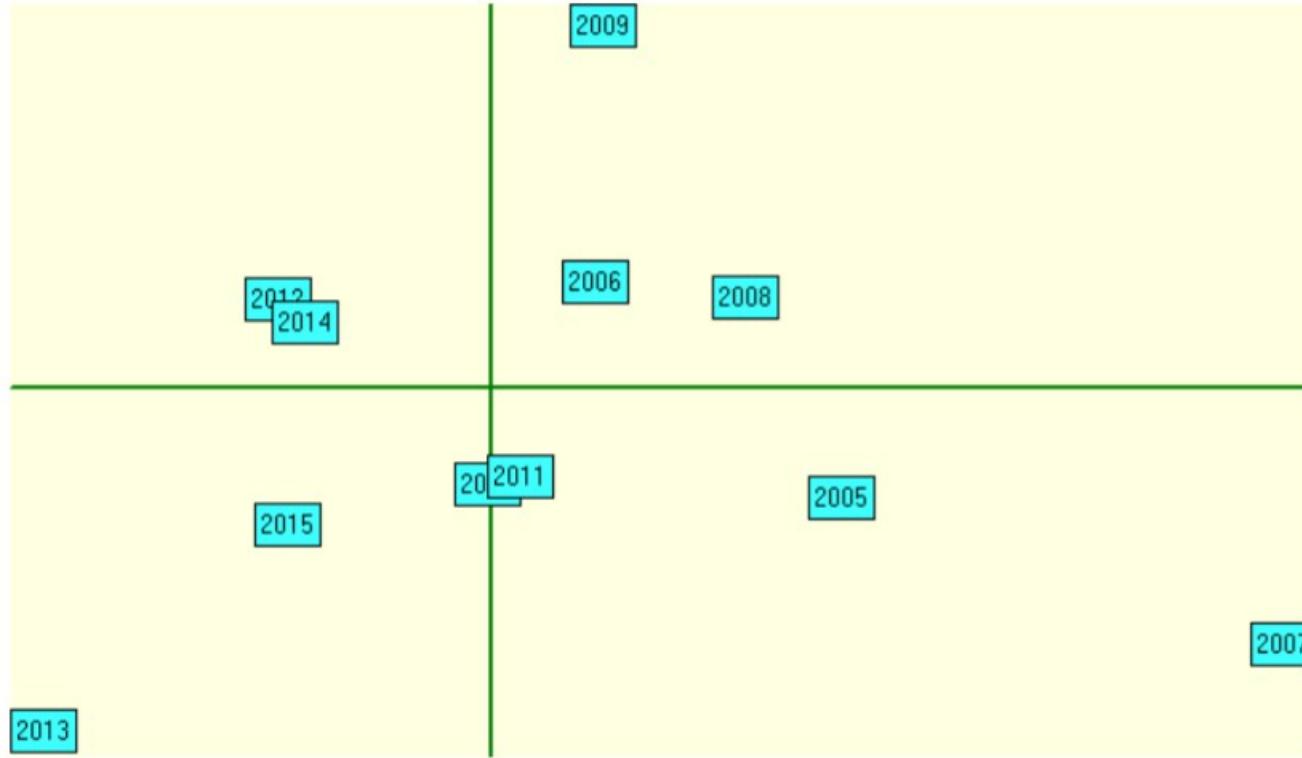
# Exemple d'exploration : articles scientifiques

## Etape 4) Retour au texte : concordance

n is a normal network , a binary tree - child network , or a level - k network . rec  
table networks include normal and tree - child networks , they claim that important e  
general networks , and 5 / 4 for tree - child and normal networks . we also show tha  
hat the number of leaf - labelled tree - child and normal networks with  $\geq n$  leaves ar  
ons , or lateral gene transfers . tree - child reticulate networks ( tc networks ) ar  
ary level - 2 networks and binary tree - child networks are also encoded by their tri  
etworks that is more general than tree - child networks . background : the advent of  
hich pairs of individuals are parent and child . new methods to automate this process  
rtices that are not leaves have a tree - child . background : phylogenetic networks a  
for normal networks , for binary tree - child networks , and for level - k networks  
it possible the generalization to tree - child time consistent ( ttc ) hybridization  
of phylogenetic networks , called tree - child phylogenetic networks , and we provide  
1 algorithms for reconstructing a tree - child phylogenetic network from its path mul  
omputing the distance between two tree - child phylogenetic networks and for aligning  
tworks and for aligning a pair of tree - child phylogenetic networks , are provided .  
s also a metric on the classes of tree - child phylogenetic networks , semibinary tre  
sis and comparison of metrics for tree - child time consistent phylogenetic networks  
they are metrics on any class of tree - child time consistent phylogenetic networks  
t only to establish properties of tree - child time consistent phylogenetic networks  
uction , but also to generate all tree - child time consistent phylogenetic networks  
sis and comparison of metrics for tree - child time consistent phylogenetic networks  
ain tight bounds on the size of a tree - child time consistent phylogenetic network .  
ed them as regular , tree sibling , tree child , or galled trees . we show that , as  
netic networks , which generalize tree - child time consistent phylogenetic networks

# Exemple d'exploration : articles scientifiques

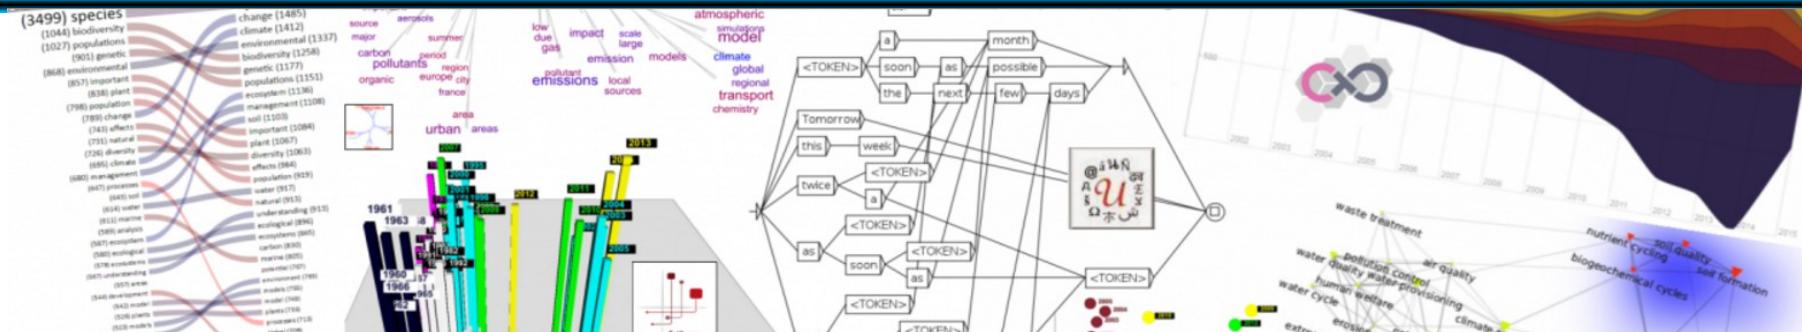
Test de l'effet d'un paramètre : l'année de publication



Tushar Agarwal, Philippe Gambette, David Morrison (2016) *Who is Who in Phylogenetic Networks: Articles, Authors and Programs.*

<https://hal-upec-upem.archives-ouvertes.fr/hal-01376483>

# Logiciels d'analyse textuelle à Université Paris-Est



## ECLAVIT

Extraction, classification et visualisation de données textuelles, mutualisation de méthodes et interopérabilité d'outils textuels existants

Recherche...

ECLAVIT

À PROPOS

MEMBRES

ACTUALITÉS ▾

CRÉDITS

BIOGRAPHIE



<https://eclavit.hypotheses.org/>

## Logiciels développés à Université Paris-Est :

- Unitex (LIGM, <http://www-igm.univ-mlv.fr/~unitex/>) : annotation de textes, extraction d'informations par recherche de patrons grammaticaux ou lexicaux
- Cortex (LISIS, <http://www.cortex.net/>) : analyses textométriques sur le web
- TextObserver (CEDITEC, <http://textopol.u-pec.fr/textobserver/>) : analyses textométriques avec interactivité et mise à jour dynamique
- TreeCloud (LIGM, <http://www.treecloud.org>) : arbres de mots

# Formation aux outils de textométrie

http://textopol.u-pec.fr

## Web

<http://ceditec.u-pec.fr>  
<http://textopol.u-pec.fr>

## Contact

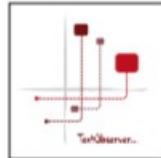
[jean-marc.leblanc@u-pec.fr](mailto:jean-marc.leblanc@u-pec.fr)

## Localisation

Salle multimédia, I2-317  
bâtiment i - Campus centre (CMC)  
61 avenue du Général de Gaulle  
94010 Créteil Cedex

## Horaire

samedi 10h-13h  
6 séances - 20 heures



## Stages de formation à TextObserver

Préparation de corpus, prise en main sur les corpus des participants.

En semaine, deux séances (dates à préciser).

## PROGRAMME 2015-2016

### 5 novembre 2016 : Introduction - Approches textométriques des discours.

Présentation et typologie pratique de logiciels standard et d'analyseurs de données textuelles. Options théoriques, principes méthodologiques, limites interprétatives.

#### Initiation à Lexico 3 / 5 :

- Fonctions documentaires, décomptes statistiques, modèles probabilistes.
- Distributions statistiques, distributions linguistiques.
- Analyse factorielle des correspondances, spécificités, fréquences...

### 10 décembre 2016 : Présentation et prise en main de TextObserver [10h-16h]

- Expliciter l'analyse factorielle des correspondances
- Analyser la variation lexicométrique
- Introduction aux opérations de catégorisation
- <http://textopol.u-pec.fr/textobserver>
- Recension du corpus et balisage semi-automatisé : présentation de la base Textopol

### 21 janvier 2017 : Des corpus textuels aux corpus multimodaux (annoter, catégoriser, étiqueter, visualiser, interpréter).

- Transformer des textes pour les soumettre à des traitements automatisés. Repérer les régularités d'un document, extraire des motifs textuels, concaténer des fichiers.
- Forme graphique, catégories morphosyntaxiques, univers sémantiques.
- Prise en main de quelques catégoriseurs, évaluateurs, étiqueteurs (*cordial, treetagger, tropes*)
- Base de données textuelles et outils de constitution et de balisage de corpus.
- Outils de visualisation, de caractérisation de corpus : Gephi, R, Xlistat, Textstat.

### 25 février 2017 : De la lexicométrie au traitement automatique des langues (TAL) [10h-16h]

P. Gambette (LIGM-MLV) : Les nuages arborés dans TextObserver et Treecloud.  
C. Martineau (LIGM-MLV) : Présentation et prise en main du logiciel UNITEX.

## PROGRAMME 2015-2016

### 25 mars 2017 : Corrélations et causalités interprétatives. Expérimentations, distance intertextuelle et voisinages.

Distances, cooccurrences, voisinage

Présentation et prise en main d'[Hyperbase](#) : de la lexicométrie à la stylométrie.

Présentation d'[Hyperbase](#) en ligne.

### 22 avril 2017 : De la textométrie à l'analyse des données, quels outils pour quels usages ?

Cooccurrences généralisées et mondes lexicaux : analyses comparées [Alceste](#) et [Iramuteq](#).

Outils de dépouillement d'enquêtes et de formulaires : [Sphinx](#), [Modalisa](#).

Ontologies et mondes sémantiques ([Tropes](#), [Alceste](#), [Astartex](#))

Quantifier les données en sciences sociales : [Prospero](#), [Nvivo](#)

## Séances spécifiques

Certaines séances spécifiques sont organisées sur la journée entière (10h-16h).

Le samedi après-midi sera consacré aux questions des participants (sur rendez-vous).

## Courant 2016 - 2017 :

### 3e journée de présentation des outils de traitements de corpus textuels

Gramlab/Unitex, Treecloud, TextObserver/WebObserver, Context....

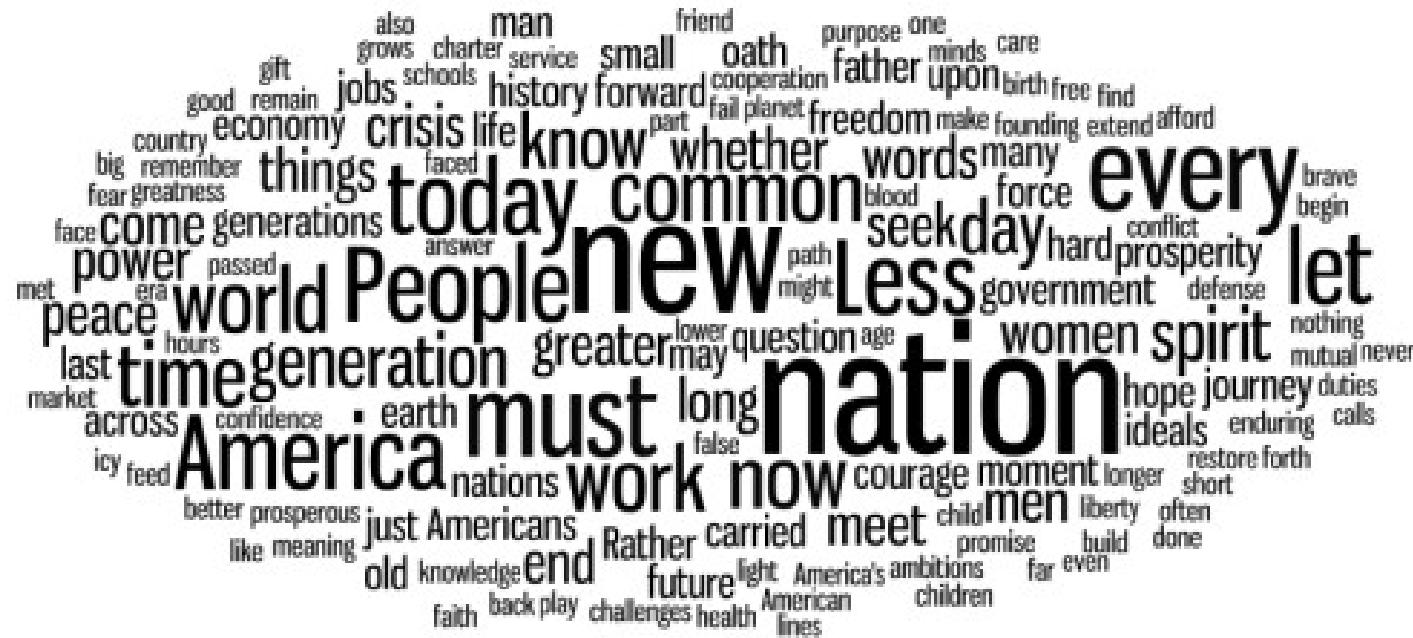
Echanges, présentations, ateliers. Outils développés par les équipes de recherche de Paris-Est.

Le programme détaillé sera mis en ligne sur Textopol.

# **Arbres de mots**

# Le « nuage arboré », une information double

nuage de  
mots



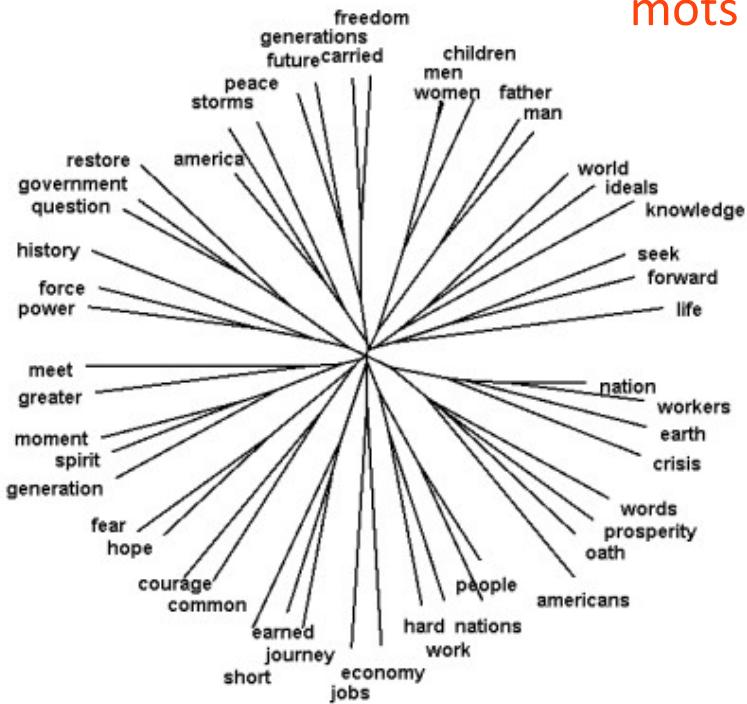
Discours inaugural de Barack Obama en 2008,  
Wordle

# Le « nuage arboré », une information double

nuage de mots

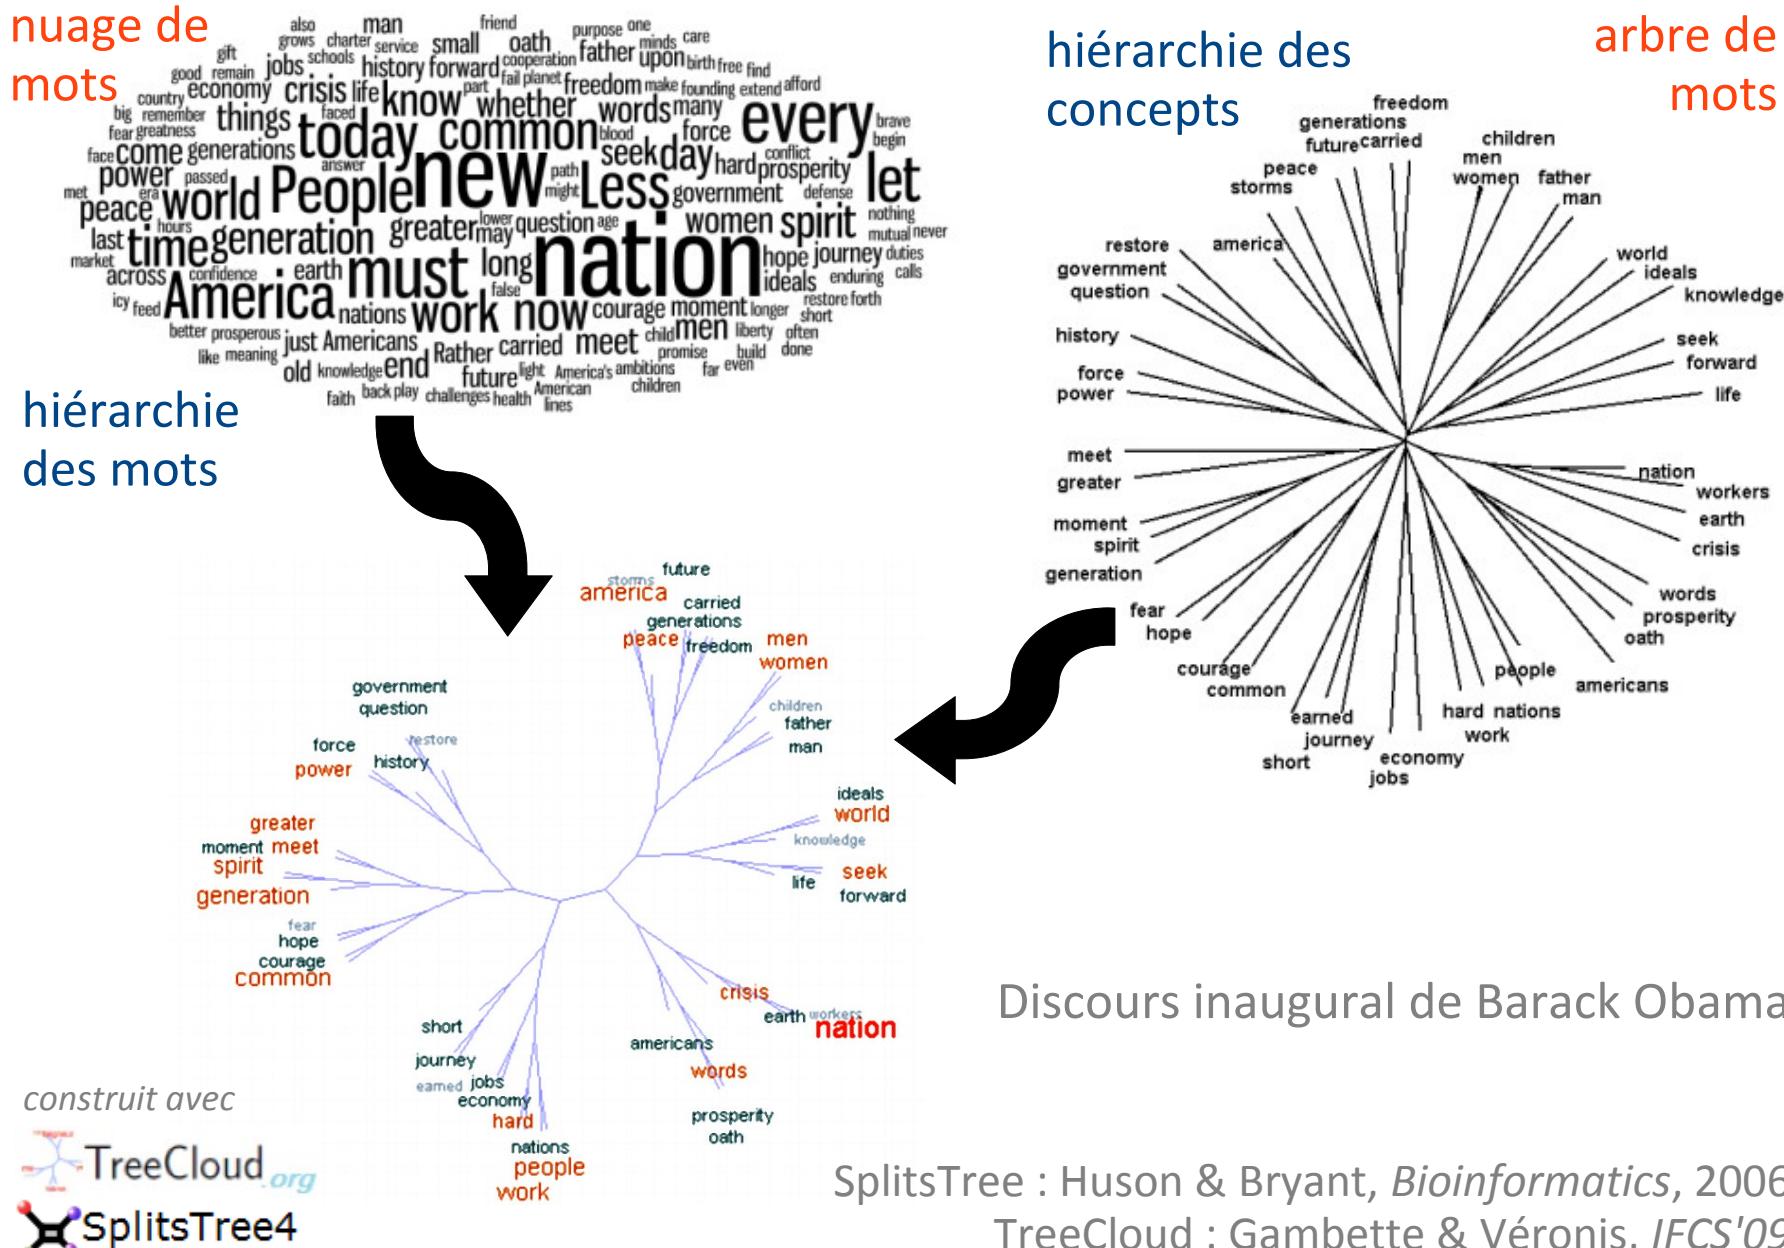
man friend purpose one  
also grows charter service small oath  
good remain jobs schools history forward  
economy crisis life forward fail planet make  
country remember part freedom founding extend afford  
big fear greatness faced know whether words many  
things faced every brave begin  
face come generations seek day hard conflict  
power passed new less government defense  
met era world people let  
peace last hours generation greater may women spirit  
market across confidence earth long hope journey duties  
time ideal enduring calls  
icy feed America must nation  
nations work now courage moment longer restore forth  
better prosperous just Americans men liberty often  
like meaning old knowledge end Rather carried meet child promise build done  
old knowledge end Rather carried meet child promise build done  
faith back play challenges health American children far even  
lines

arbre de mots

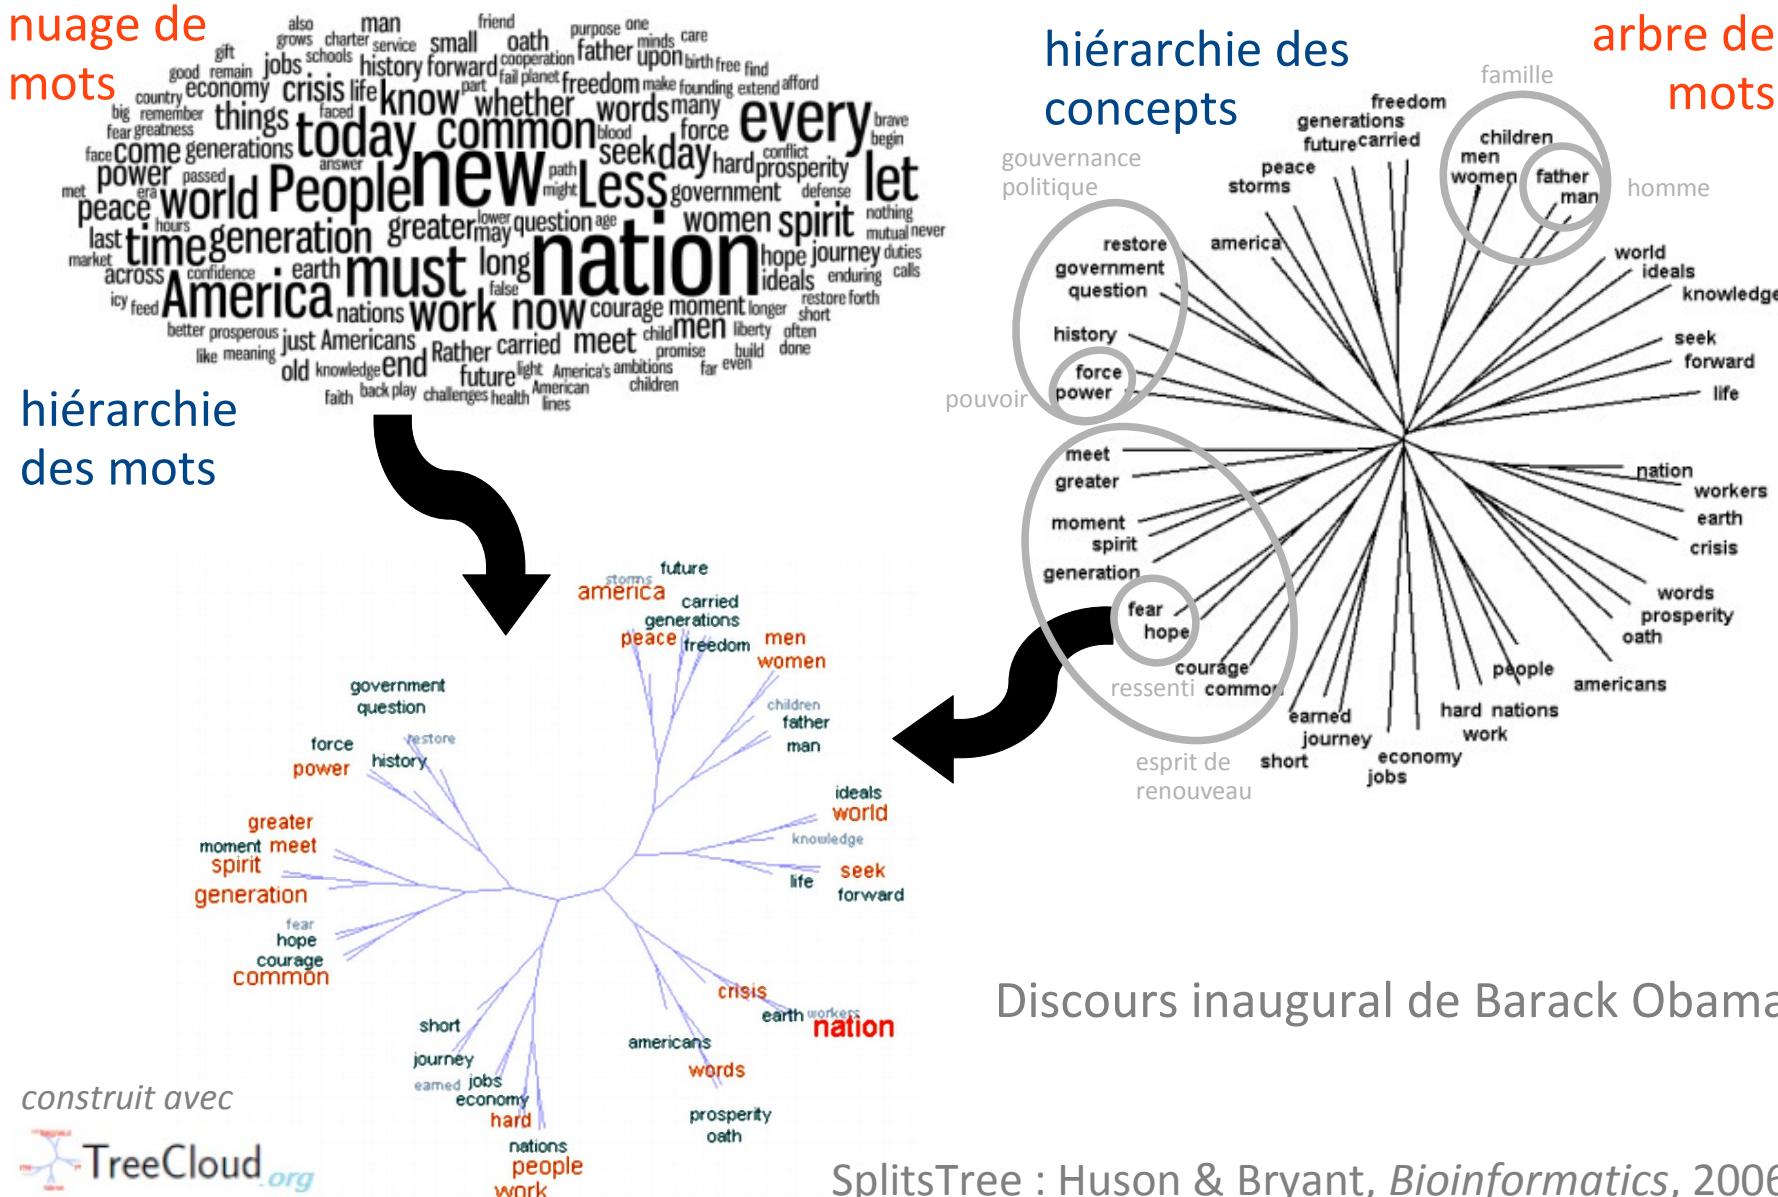




# Le « nuage arboré », une information double

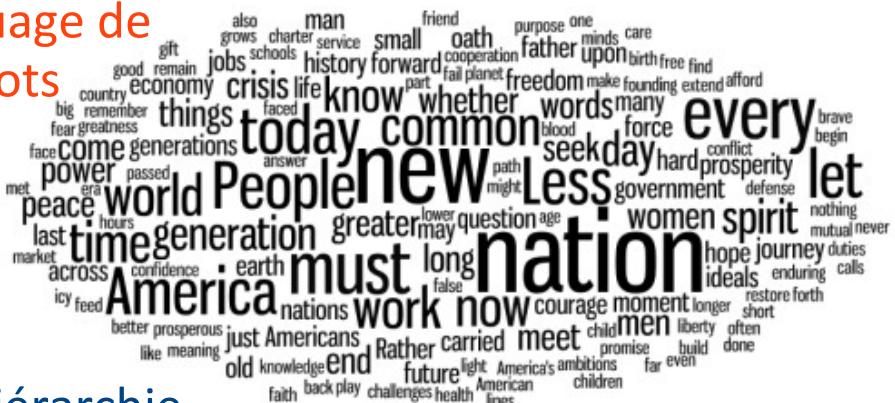


# Le « nuage arboré », une information double



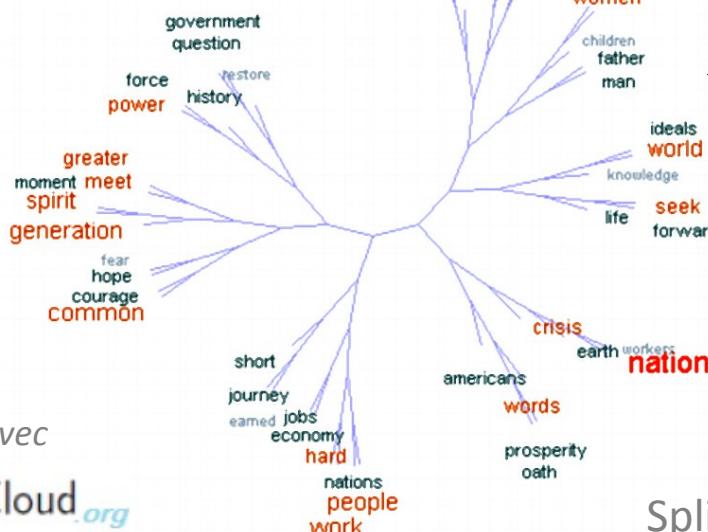
# Le « nuage arboré », une information double

nuage de mots



hiérarchie des mots

occurrences



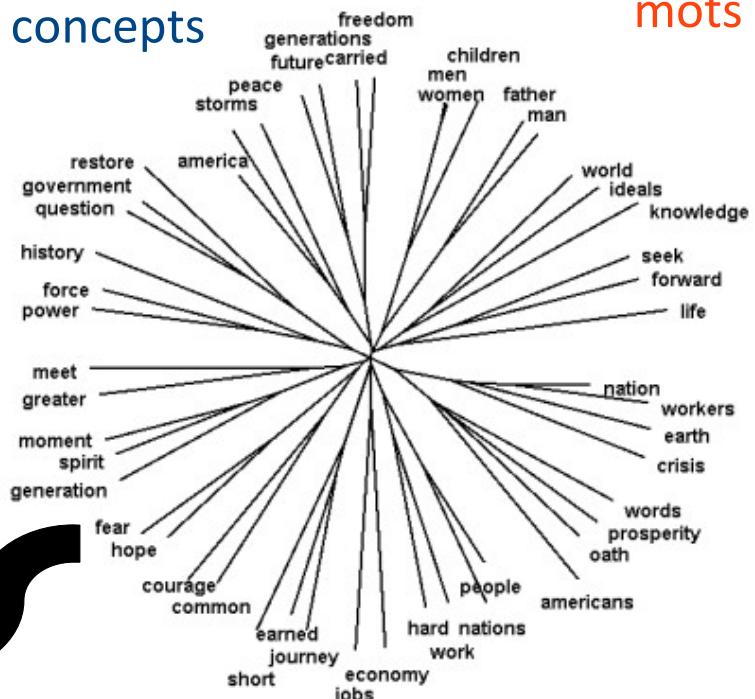
construit avec

 TreeCloud.org

 SplitsTree4

hiérarchie des concepts

arbre de mots



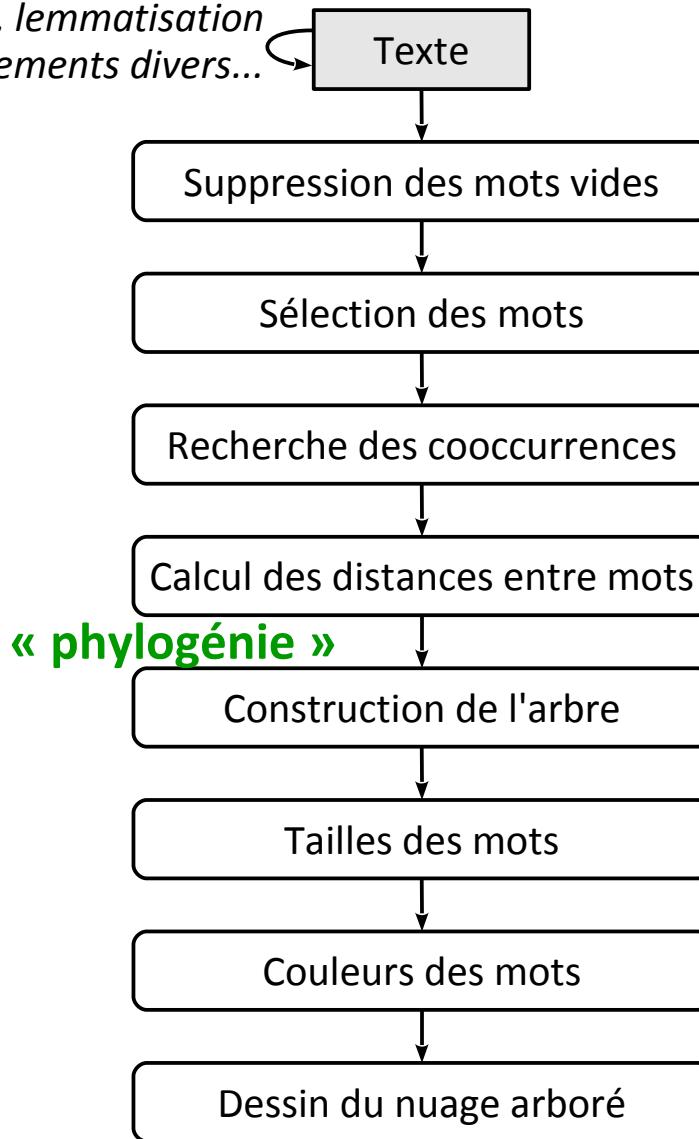
cooccurrences

Discours inaugural de Barack Obama

SplitsTree : Huson & Bryant, *Bioinformatics*, 2006  
TreeCloud : Gambette & Véronis, *IFCS'09*

# Processus de construction

Concordance d'un mot, lemmatisation  
ou remplacements divers...



**Proposé dans la version  
téléchargeable de TreeCloud**

*antidico anglais, français*

*n mots les plus fréquents, mots  
apparaissant plus de n fois, ou liste  
personnalisée*

*Fenêtre de cooccurrence paramétrée par  
taille et pas de glissement, ou caractère  
 séparateur*

*12 formules de distance de cooccurrence*

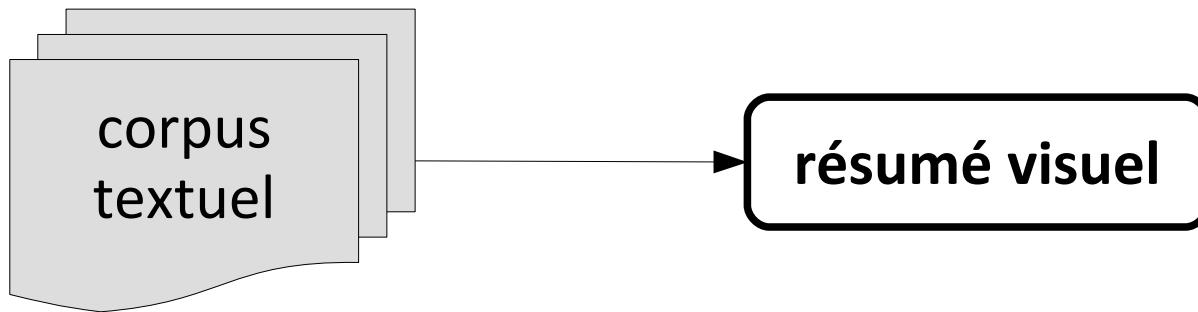
*Appel transparent au logiciel  
SplitsTree*

*Fréquences ou valeurs personnalisées*

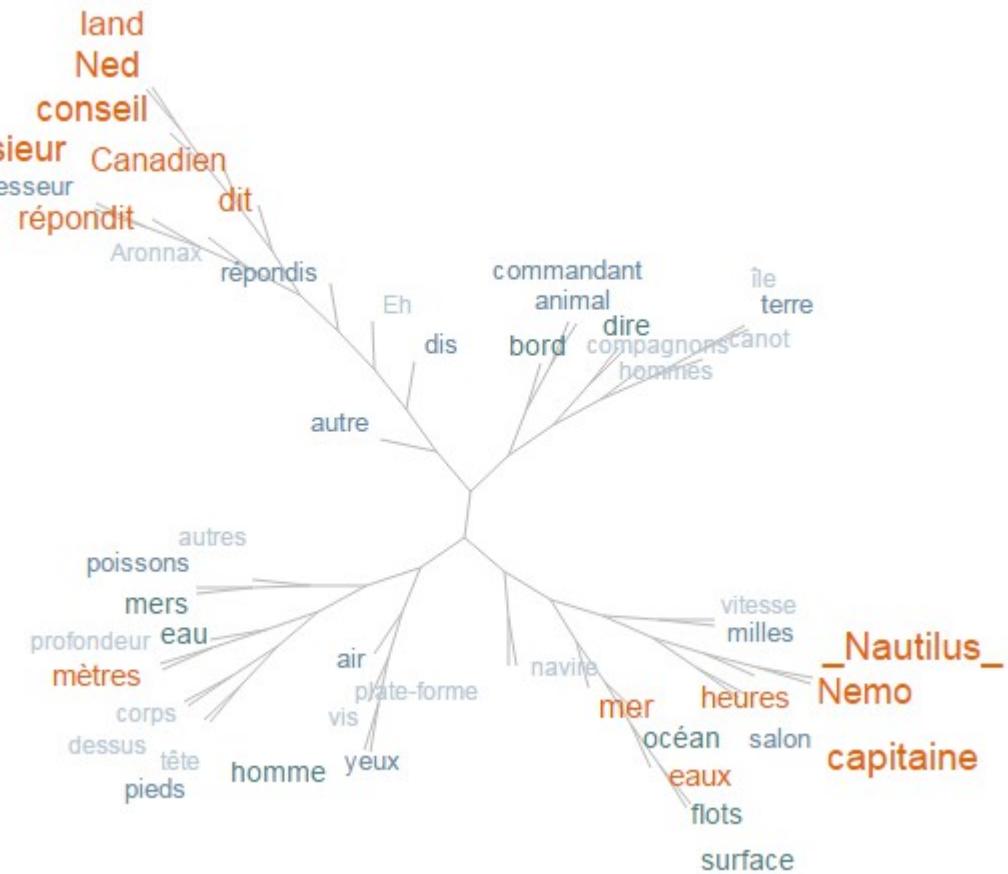
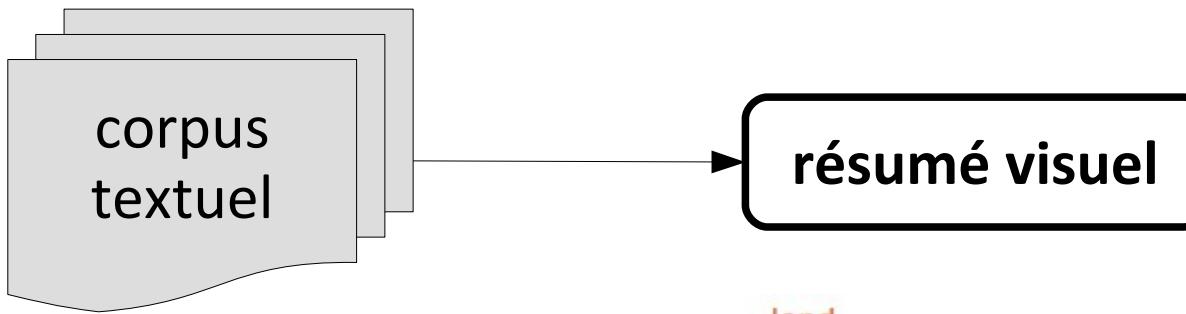
*Fréquences, chronologie, dispersion,  
ciblées sur la cooccurrence d'un mot,  
ou valeurs personnalisées*

*Appel transparent au logiciel SplitsTree  
ou Dendroscope*

# Le « nuage arboré », pour quoi faire ?

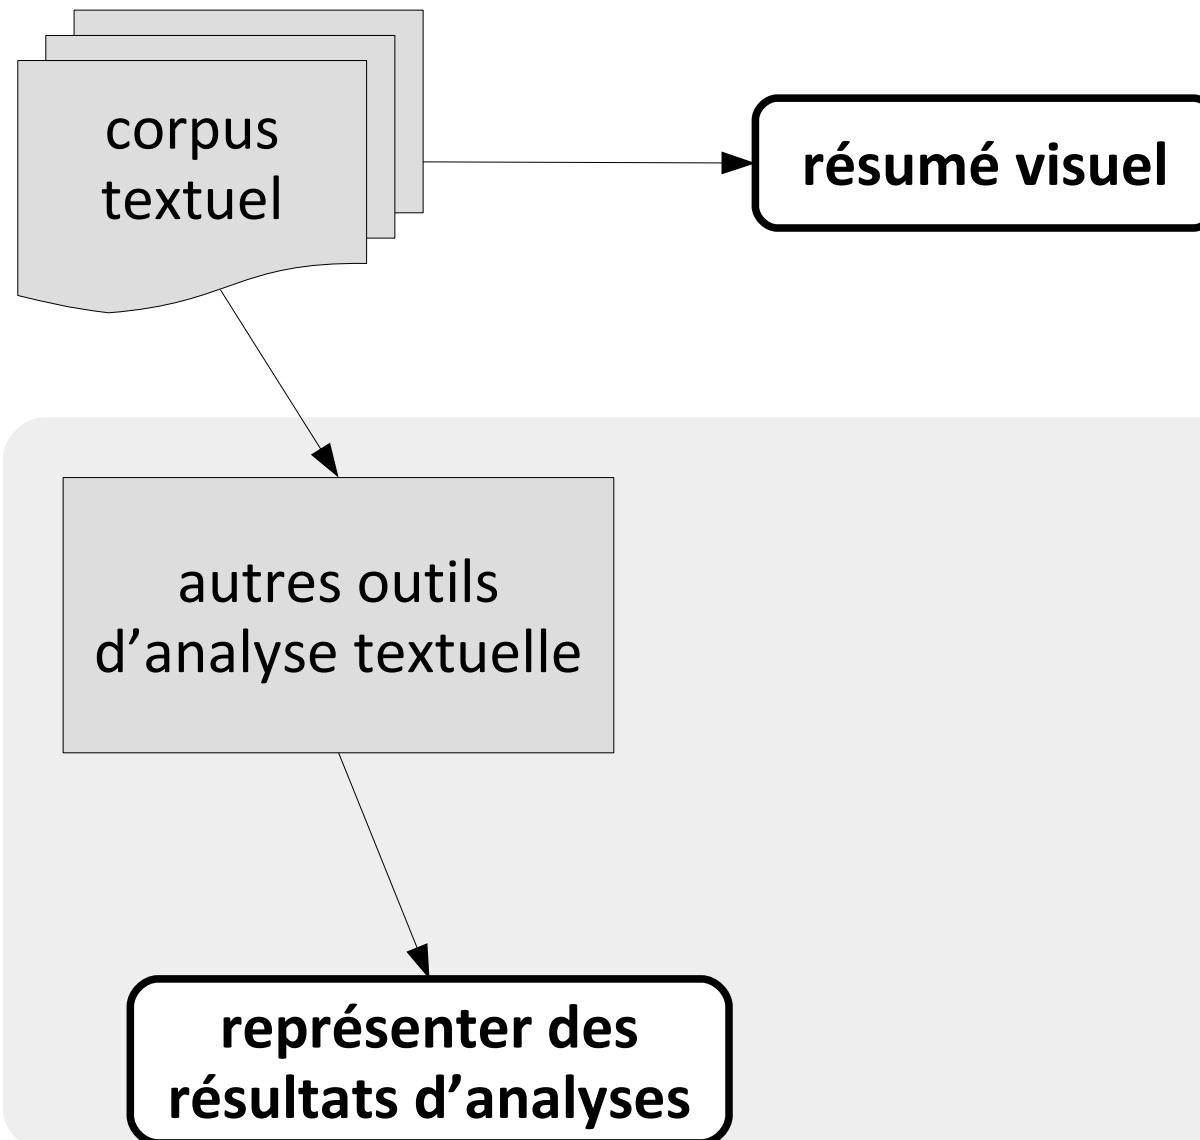


# Le « nuage arboré », pour quoi faire ?



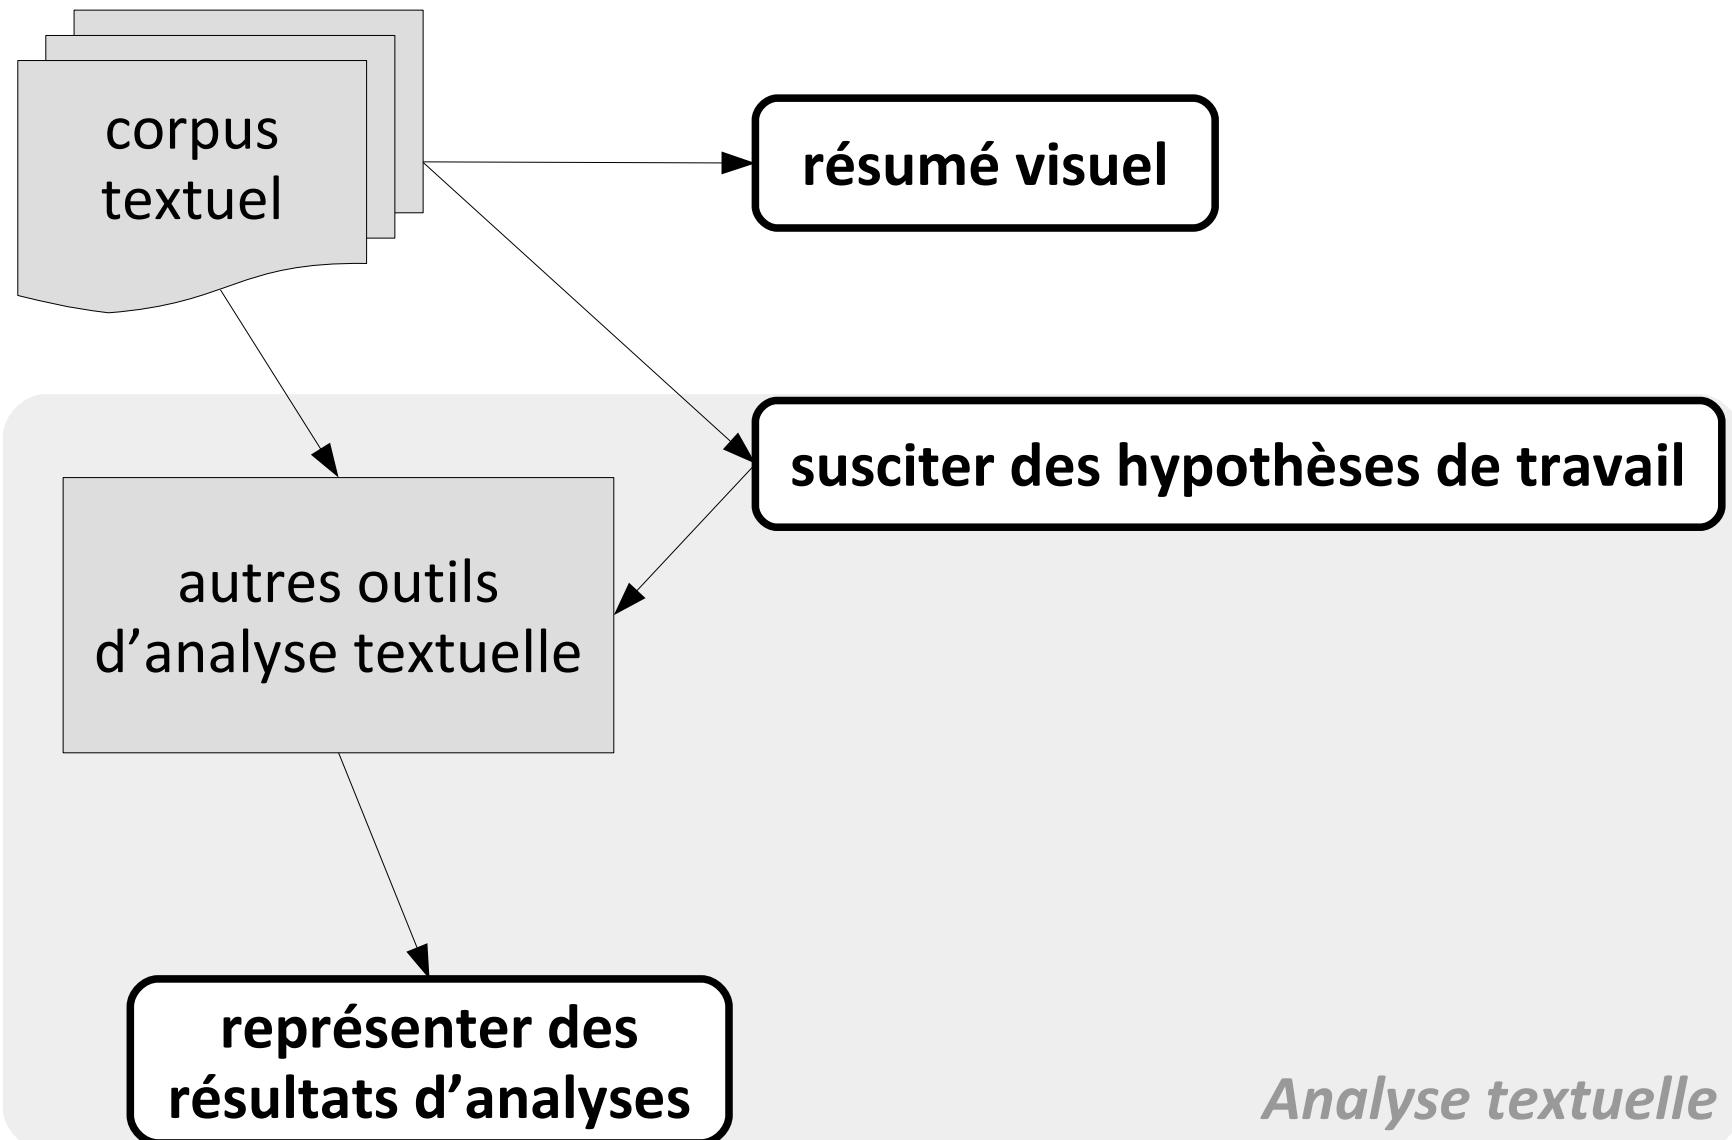
Nuage arboré construit sur  
Treecloud.org du roman *Vingt  
mille lieues sous les mers* de Jules  
Verne (distance Jaccard, 50 mots  
les plus fréquents)

# Le « nuage arboré », pour quoi faire ?



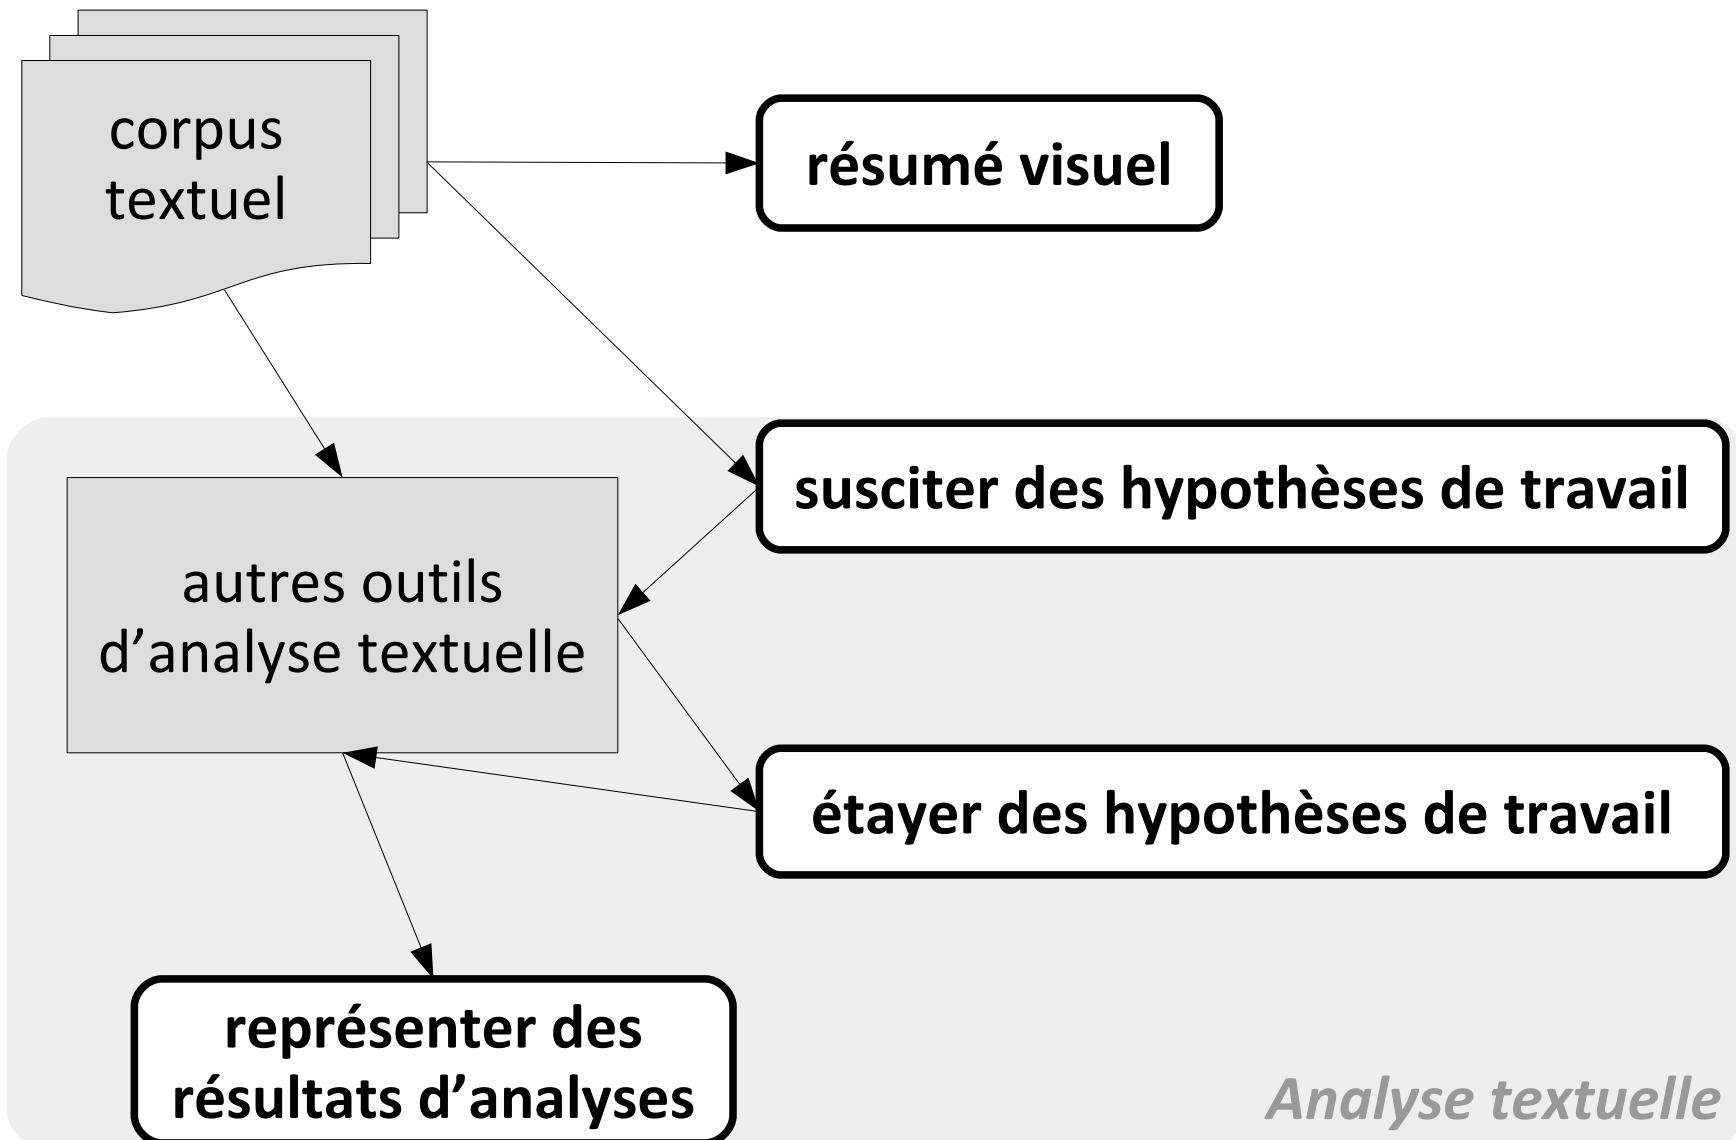
*Analyse textuelle*

# Le « nuage arboré », pour quoi faire ?

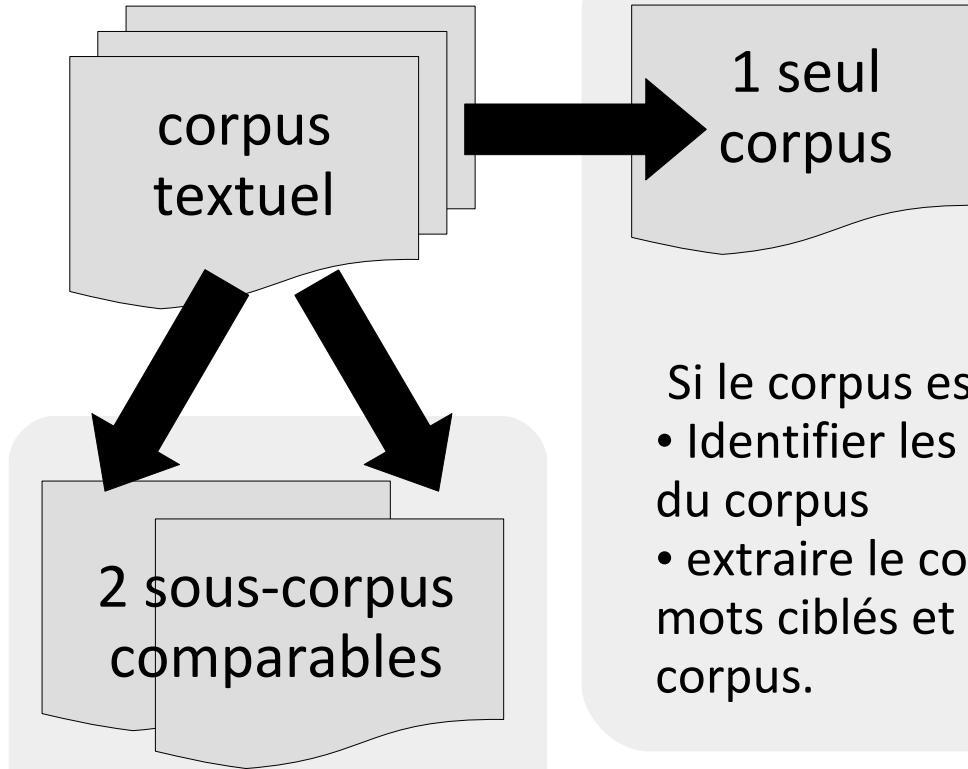


*Analyse textuelle*

# Le « nuage arboré », pour quoi faire ?



# Exploration de corpus avec TreeCloud



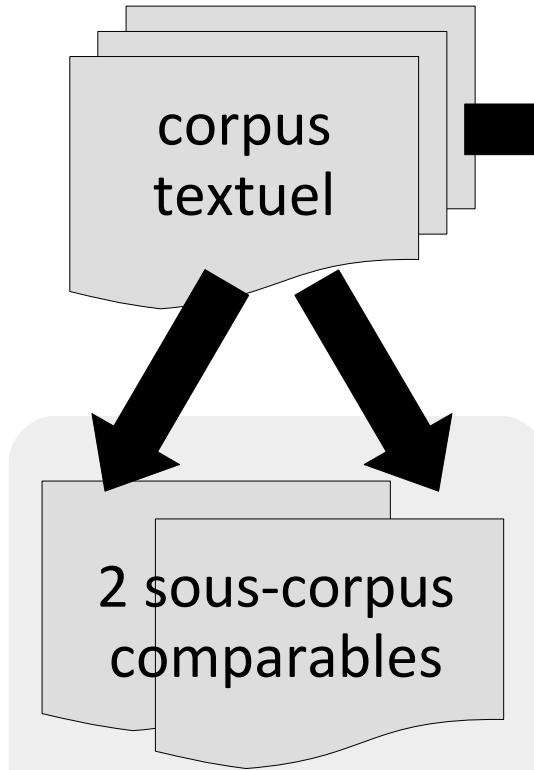
- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)

Si le corpus est assez grand :

- Identifier les mots plutôt au début ou à la fin du corpus
- extraire le contexte dans le corpus de certains mots ciblés et utiliser ces données comme corpus.

- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

# Exploration de corpus avec TreeCloud



- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)

Si le corpus est assez grand :

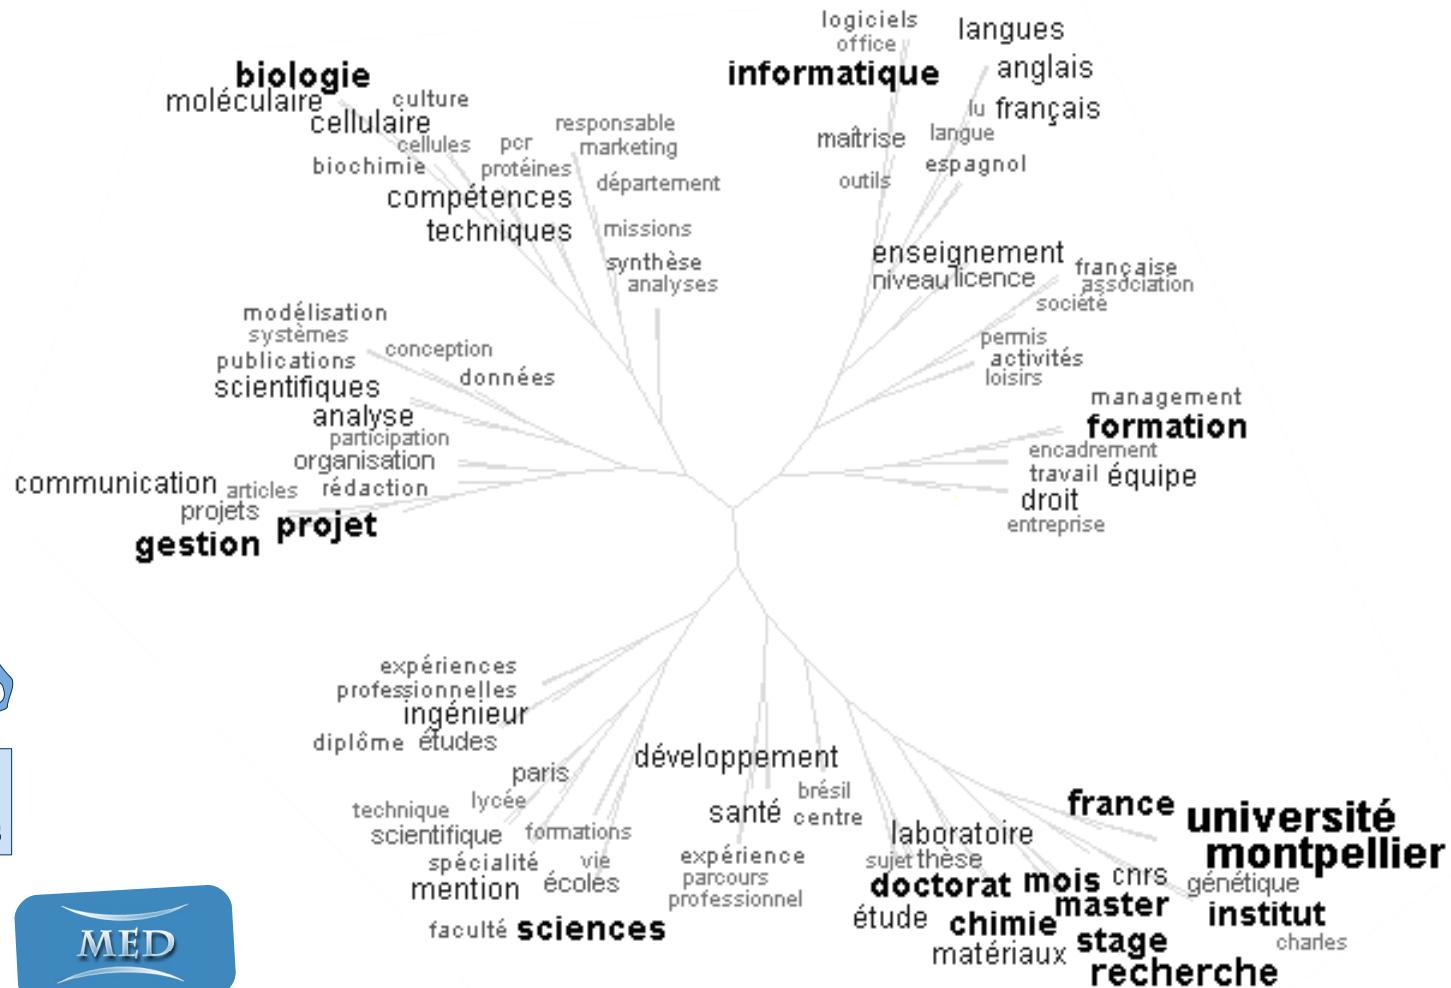
- Identifier les mots plutôt au début ou à la fin du corpus
- extraire le contexte dans le corpus de certains mots ciblés et utiliser ces données comme corpus.

- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

# Méthode : interpréter les regroupements

## Dessiner des « patates »

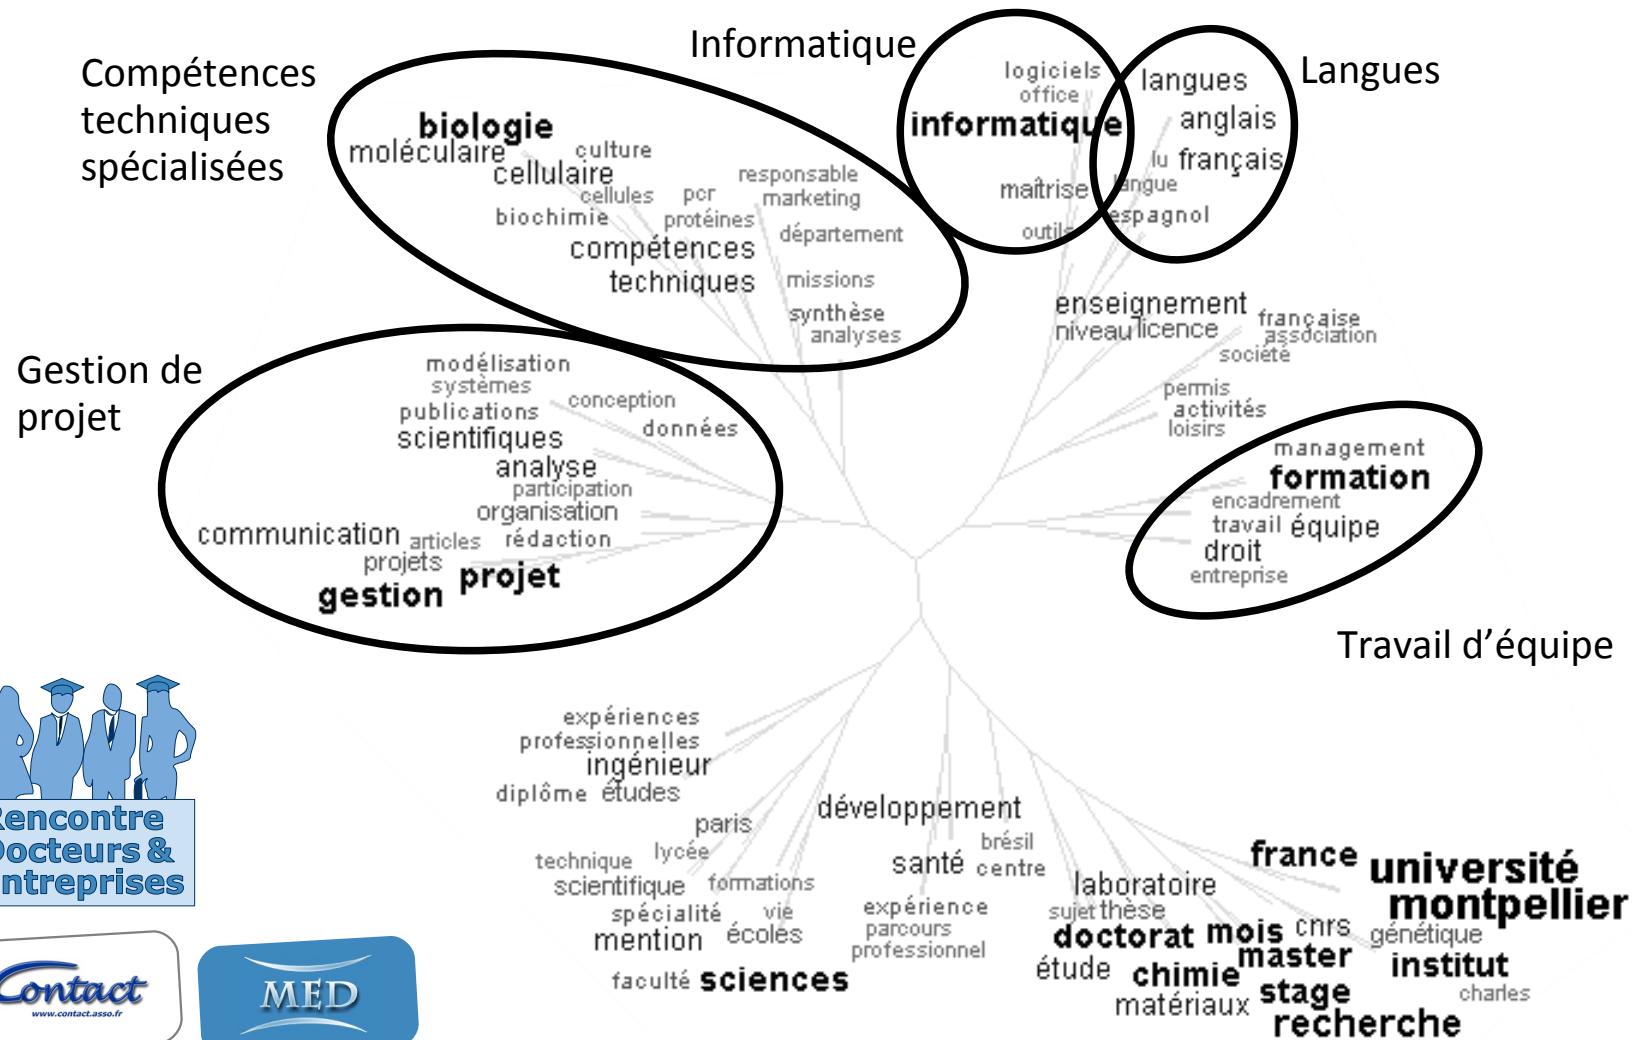
Corpus : une centaine de CV soumis à une rencontre docteurs-entreprises



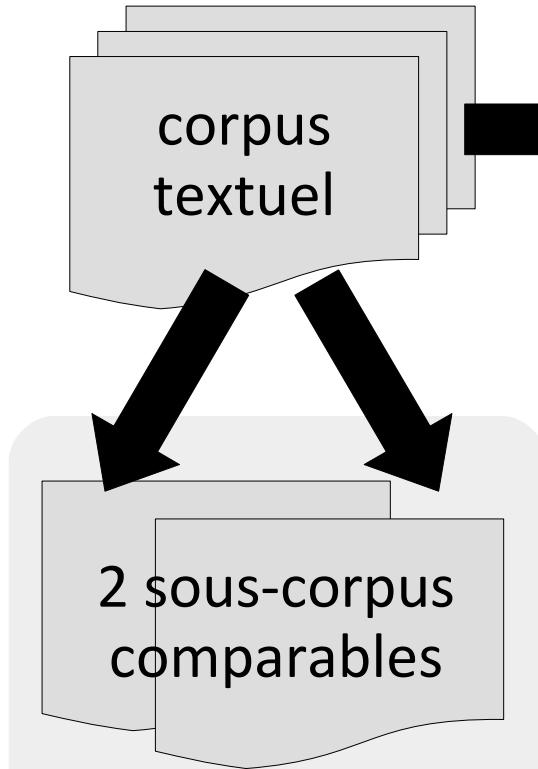
# Méthode : interpréter les regroupements

## Dessiner des « patates »

Corpus : une centaine de CV soumis à une rencontre docteurs-entreprises

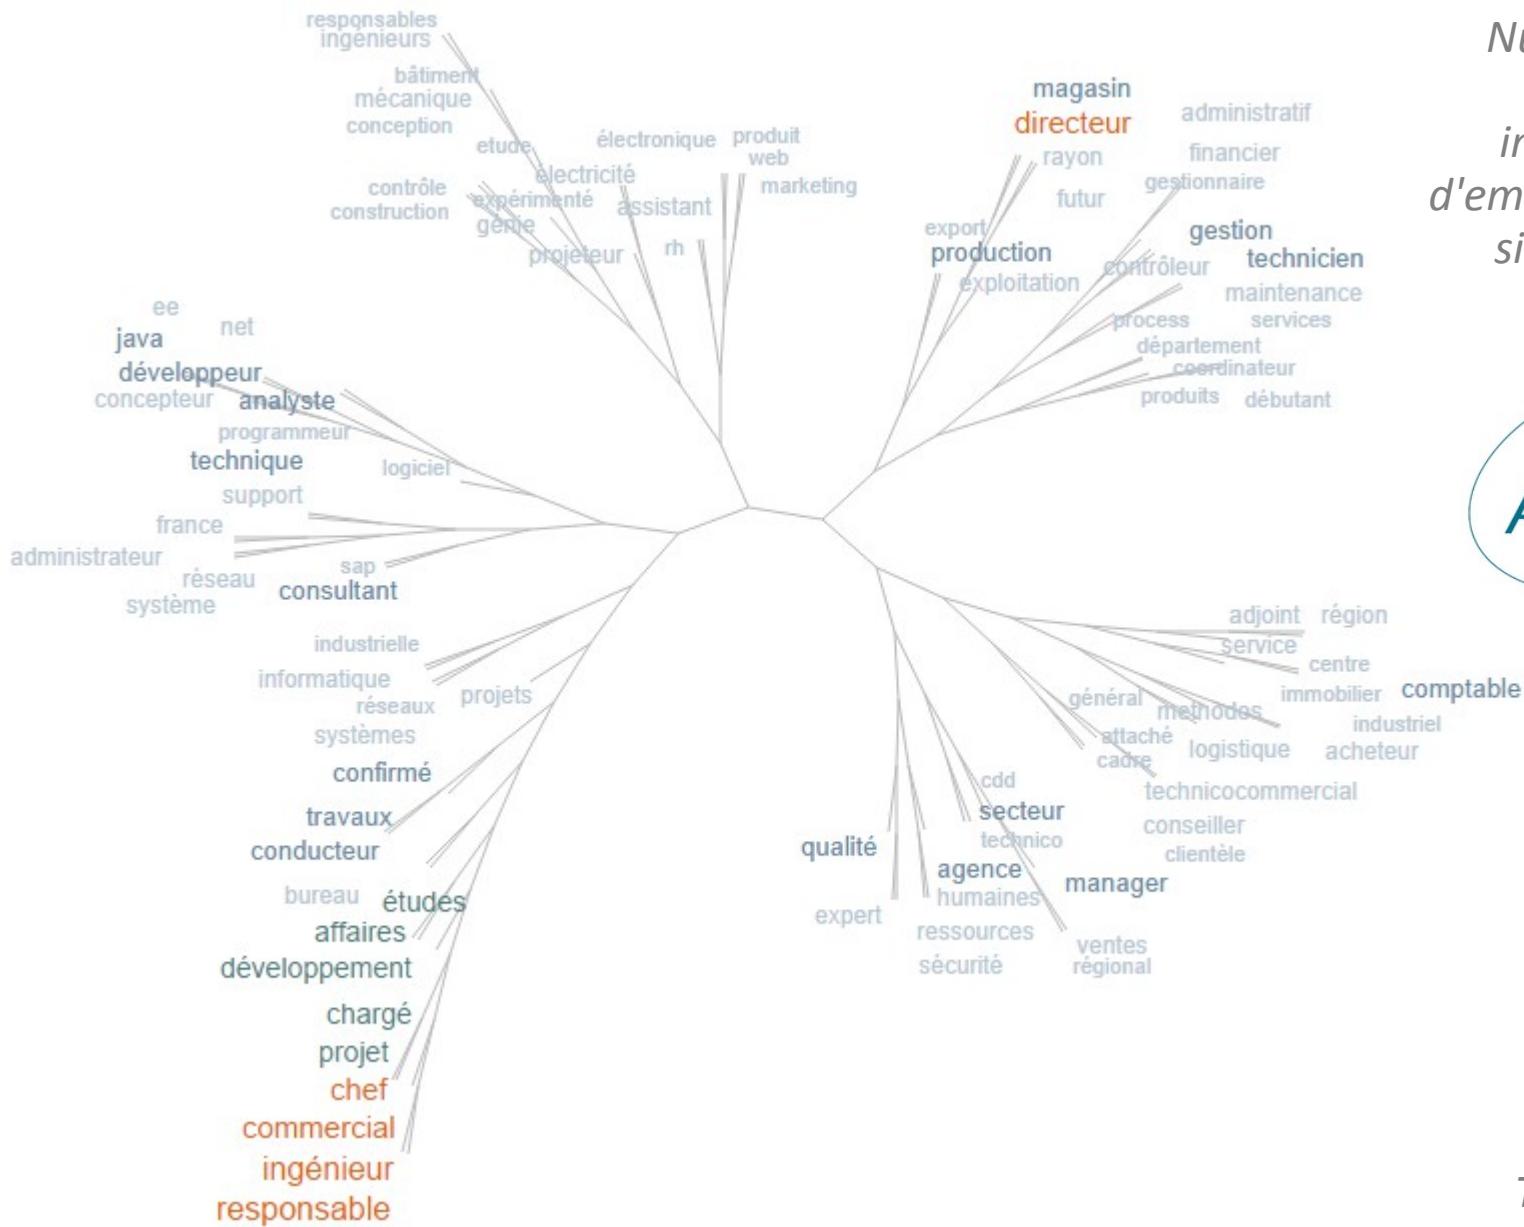


# Exploration de corpus avec TreeCloud



- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

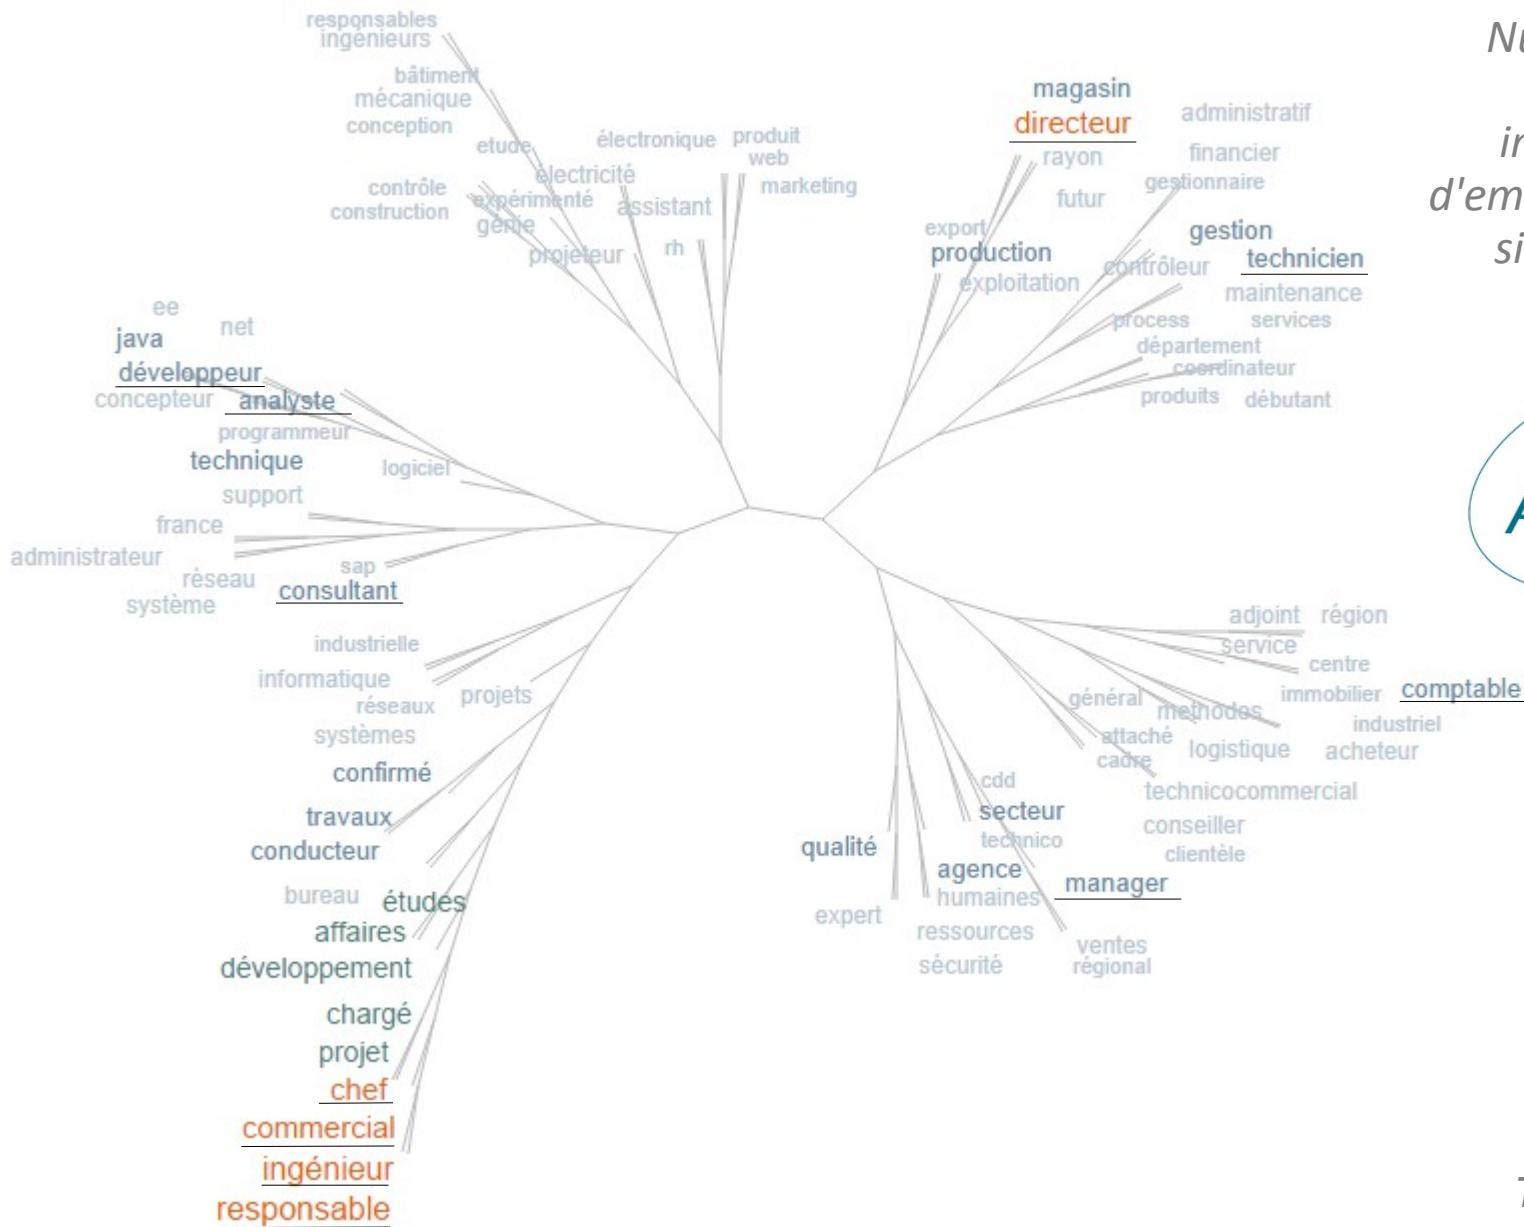
# Méthode : voisinage des mots fréquents



Nuage arboré de plus de 4800 intitulés d'offres d'emploi extraits du site de l'APEC en avril 2011.

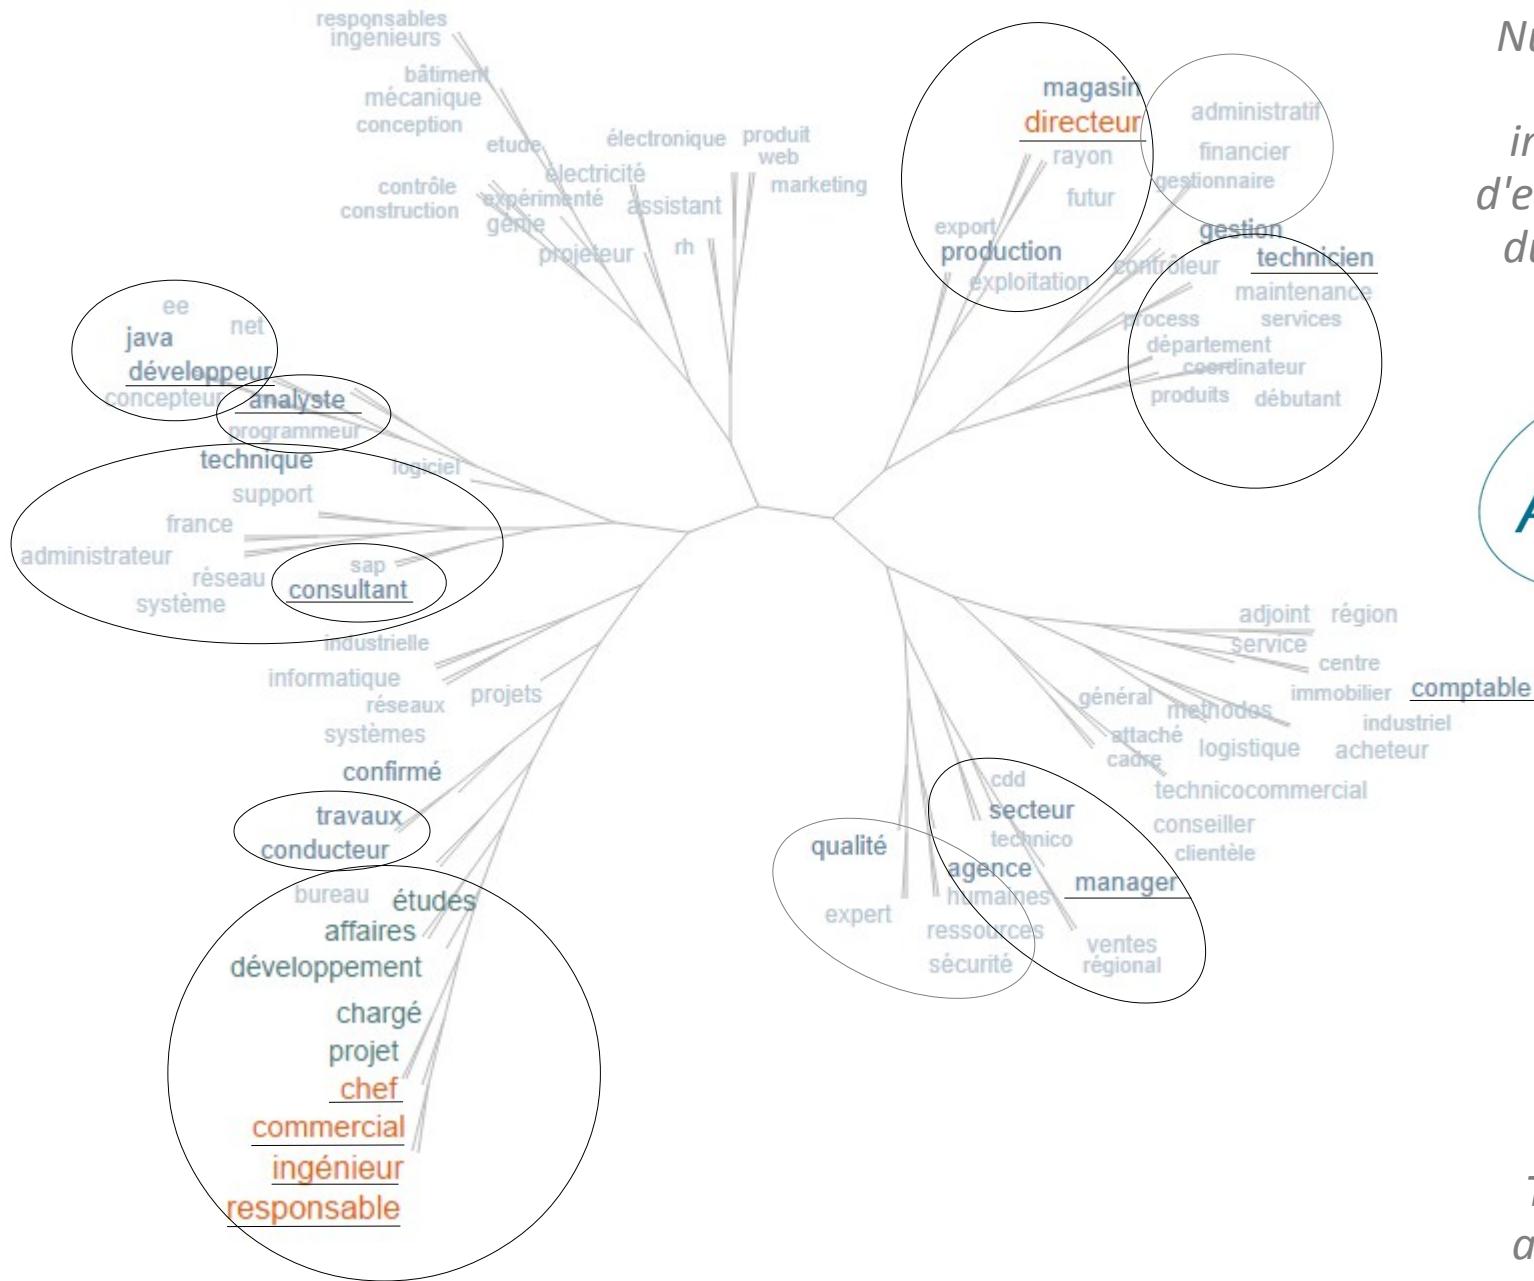


# Méthode : voisinage des mots fréquents



Travail de 2011  
avec Paola Salle

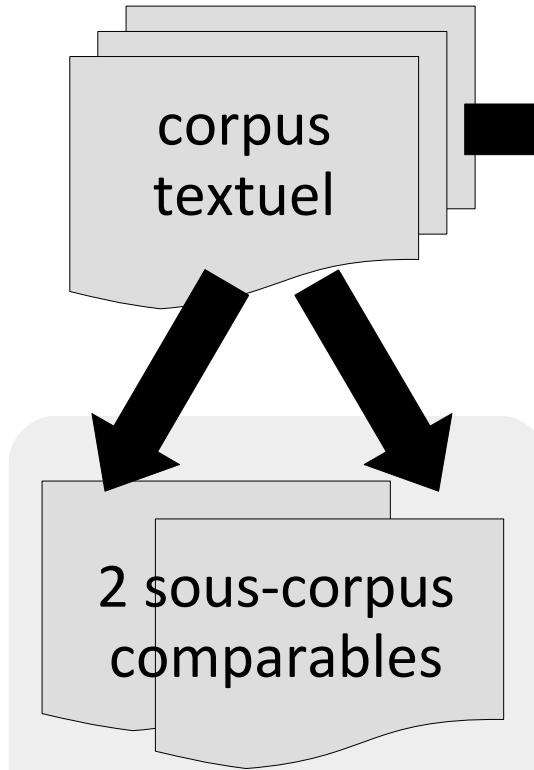
# Méthode : voisinage des mots fréquents



Nuage arboré de plus de 4800 intitulés d'offres d'emploi extraits du site de l'APEC en avril 2011.



# Exploration de corpus avec TreeCloud



- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- **Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)**

Si le corpus est assez grand :

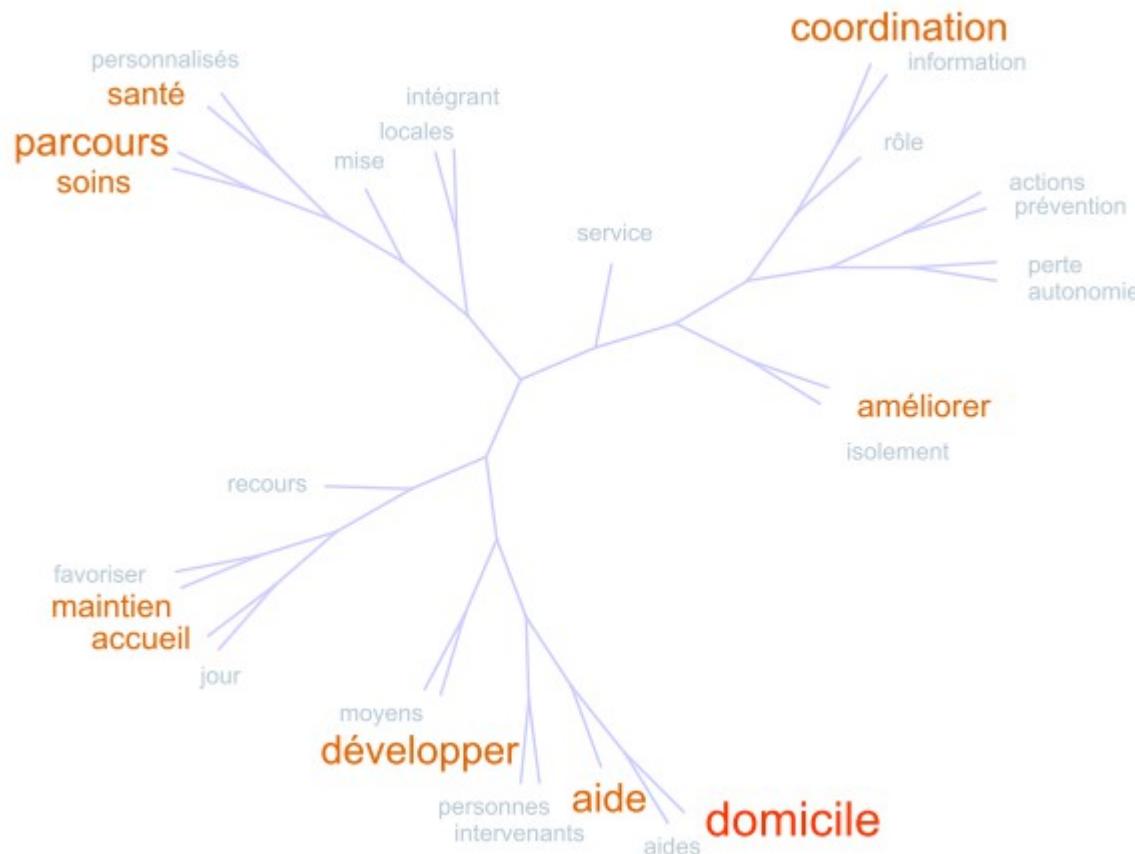
- Identifier les mots plutôt au début ou à la fin du corpus
- extraire le contexte dans le corpus de certains mots ciblés et utiliser ces données comme corpus.

- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

# Méthode : voisinage des verbes

## Corpus : réponses à des questions ouvertes à des professionnels de la santé sur le parcours de santé des personnes âgées dans les Alpes de Haute-Provence

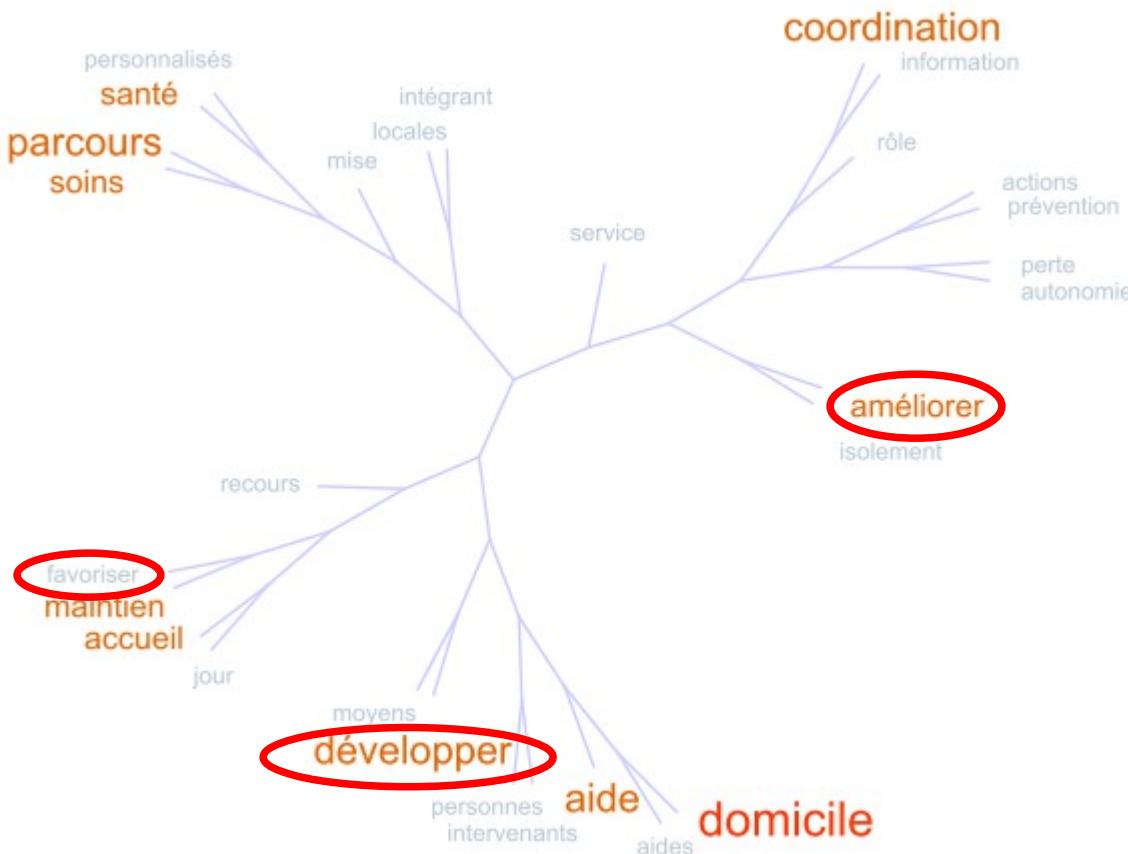
### Suggestions d'améliorations :



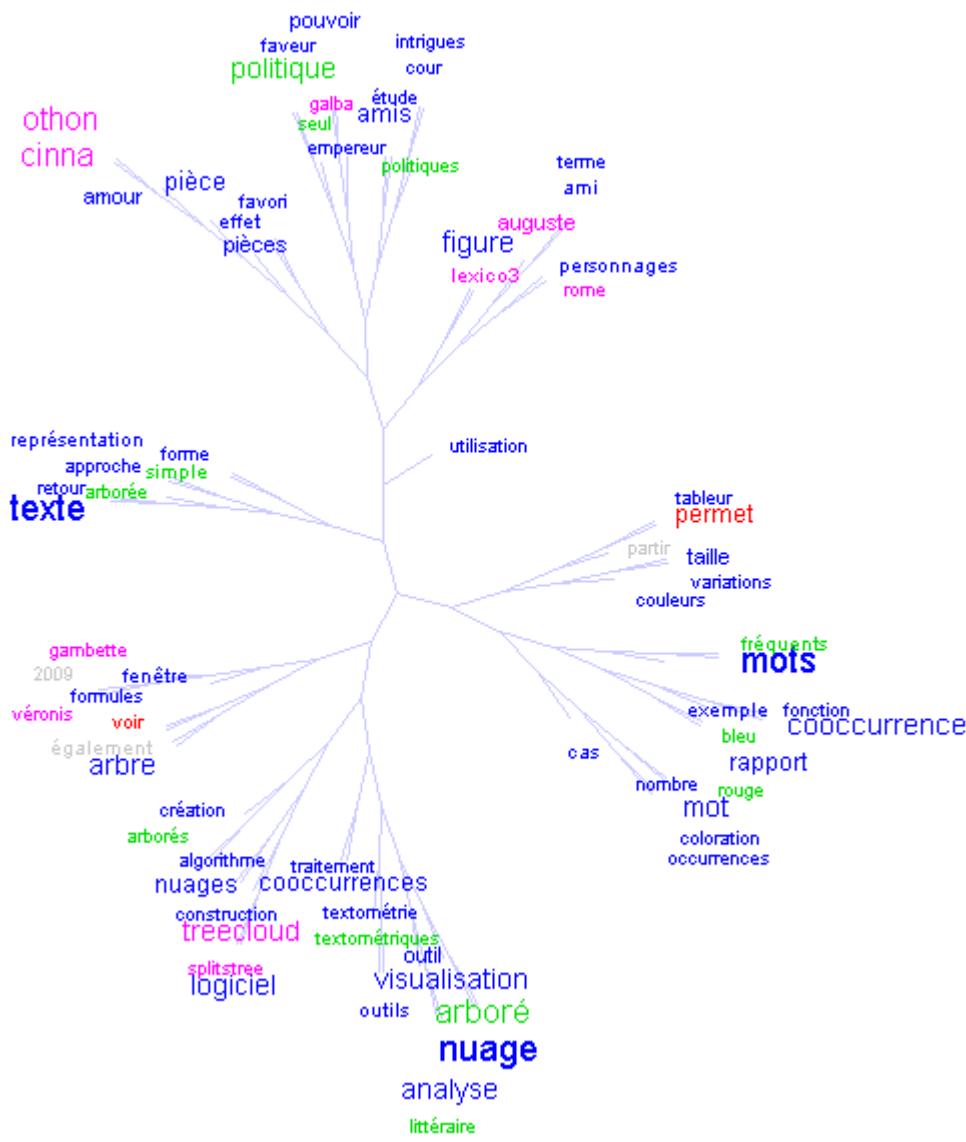
# Méthode : voisinage des verbes

Corpus : réponses à des questions ouvertes à des professionnels de la santé sur le parcours de santé des personnes âgées dans les Alpes de Haute-Provence

Suggestions d'améliorations :



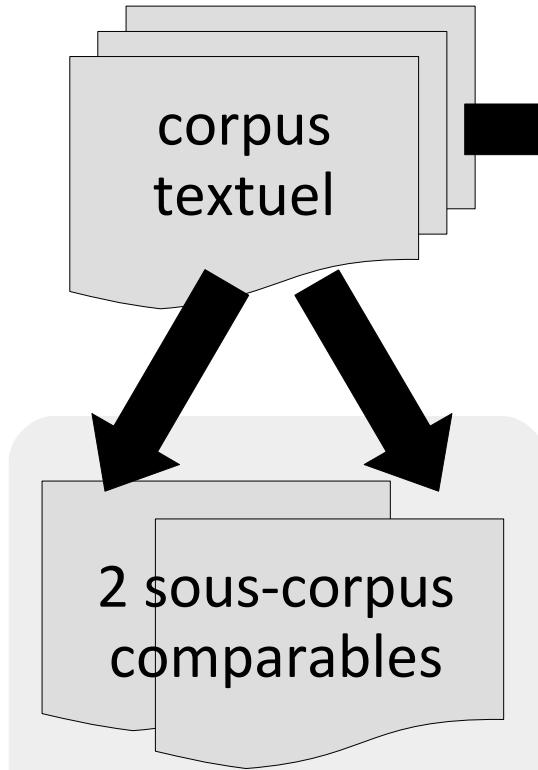
# Perspective : coloration grammaticale



noms  
adjectifs  
verbes  
noms propres

Nuage arboré des mots apparaissant 5 fois ou plus dans l'article d'Amstutz & Gambette, JADT 2010, distance Liddell, fenêtre de 20 mots, coloration personnalisée à partir d'un étiquetage TreeTagger

# Exploration de corpus avec TreeCloud



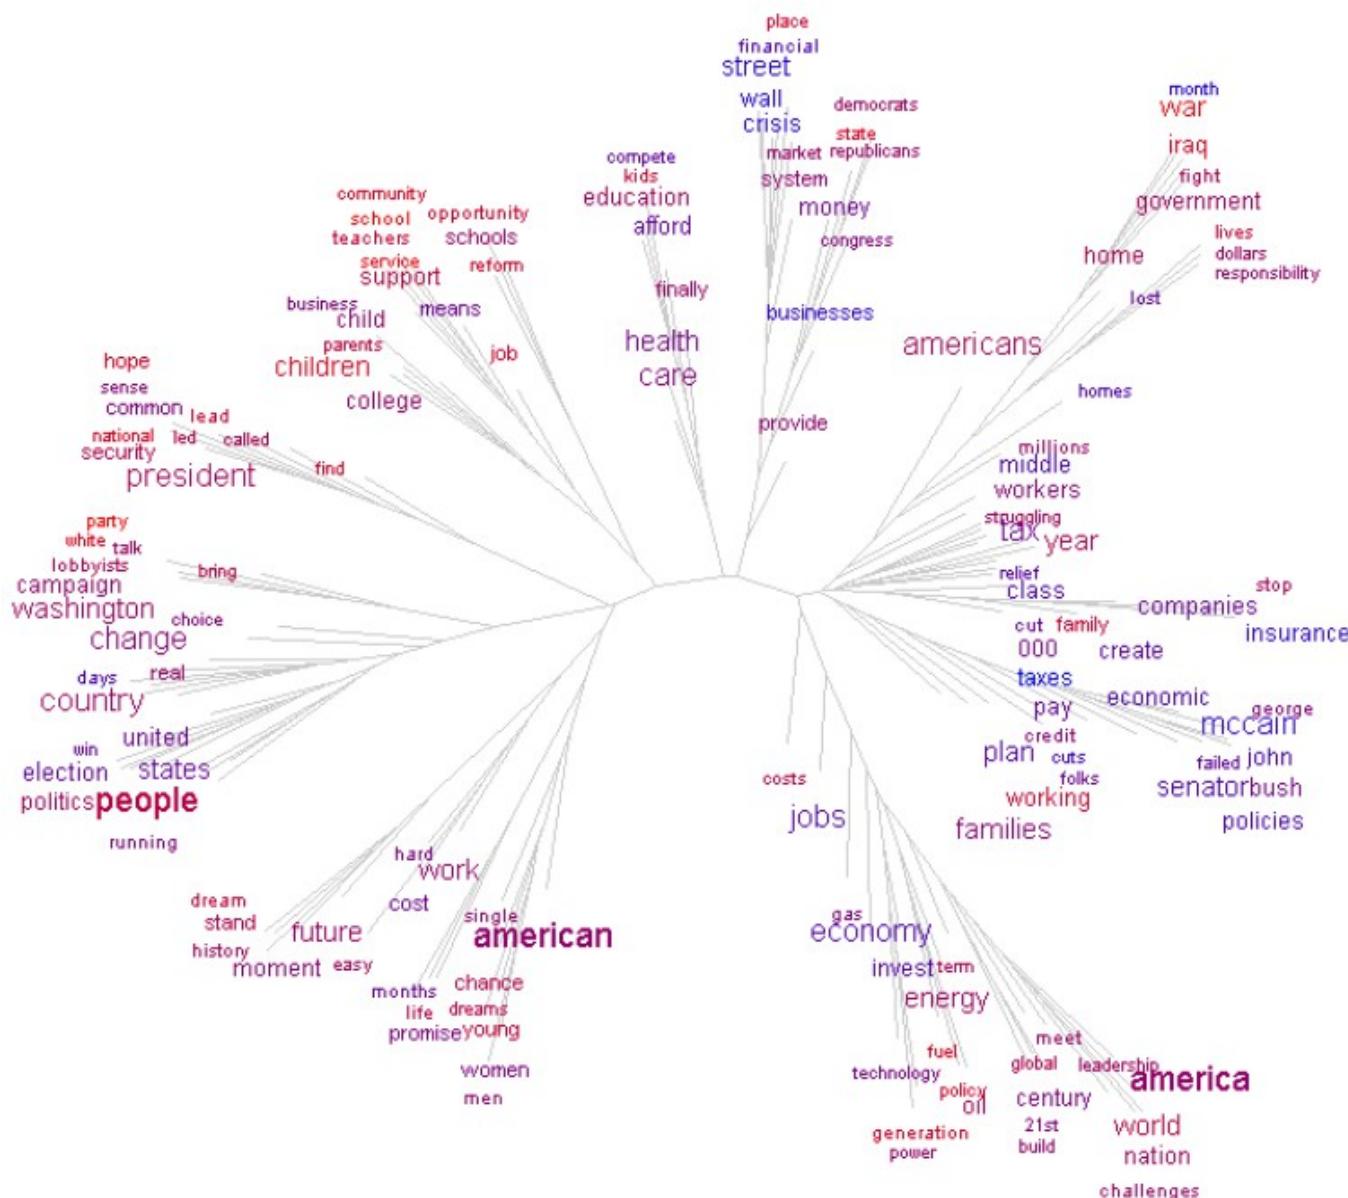
- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)

Si le corpus est assez grand :

- **Identifier les mots plutôt au début ou à la fin du corpus**
  - extraire le contexte dans le corpus de certains mots ciblés et utiliser ces données comme corpus.

- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

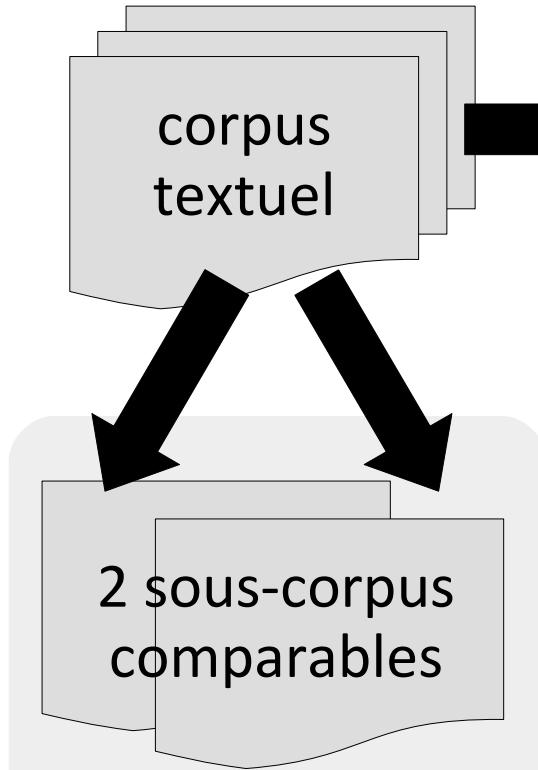
# Méthode : mots au début ou à la fin



NUAGE ARBORÉ DE  
L'ENSEMBLE DES DISCOURS  
DE CAMPAGNE DE 2008  
DE BARACK OBAMA,  
COLORATION CHRONOLOGIQUE

début de la campagne  
fin de la campagne

# Exploration de corpus avec TreeCloud



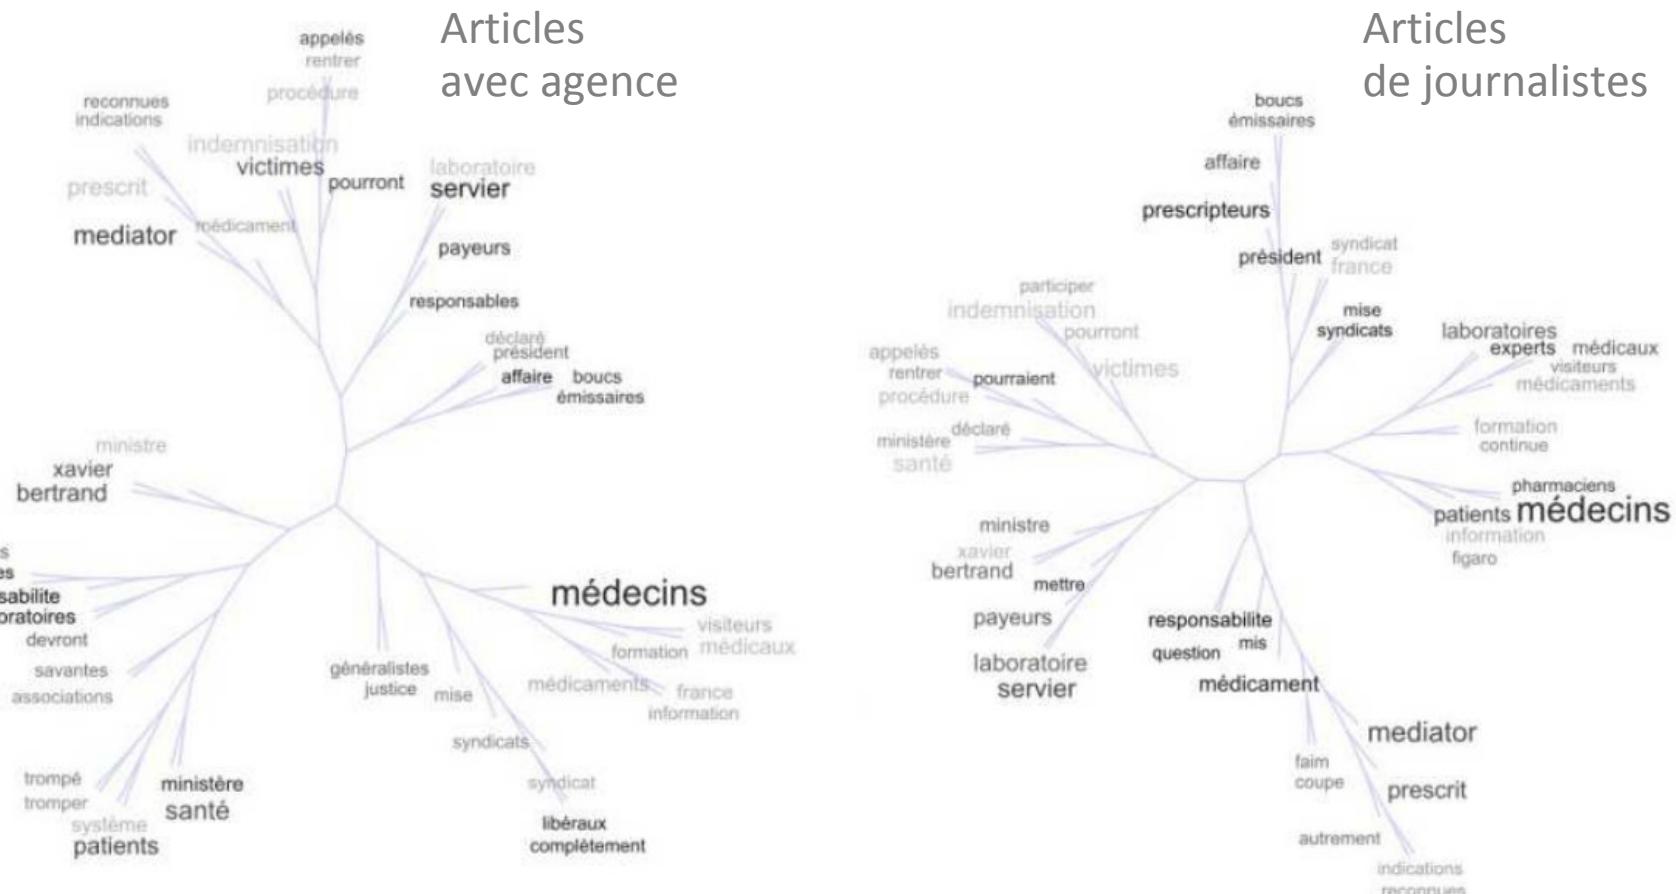
- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)

Si le corpus est assez grand :

- Identifier les mots plutôt au début ou à la fin du corpus
- **extraire le contexte dans le corpus de certains mots ciblés et utiliser ces données comme corpus.**

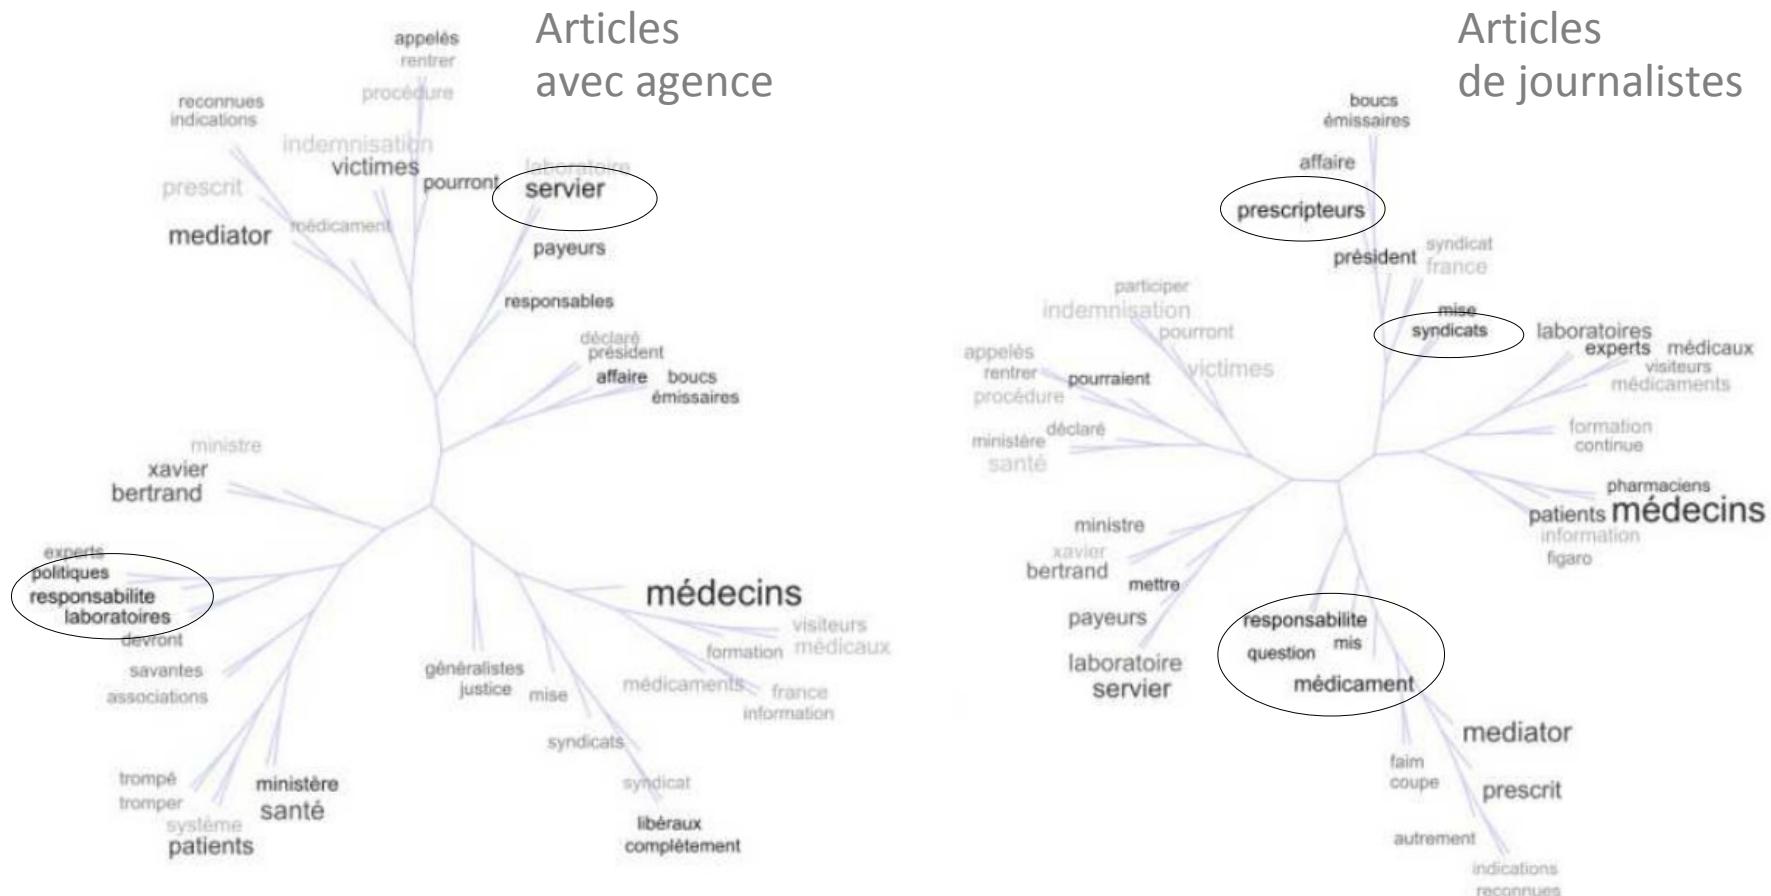
- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

# Nuages arborés des contextes de « médecins »



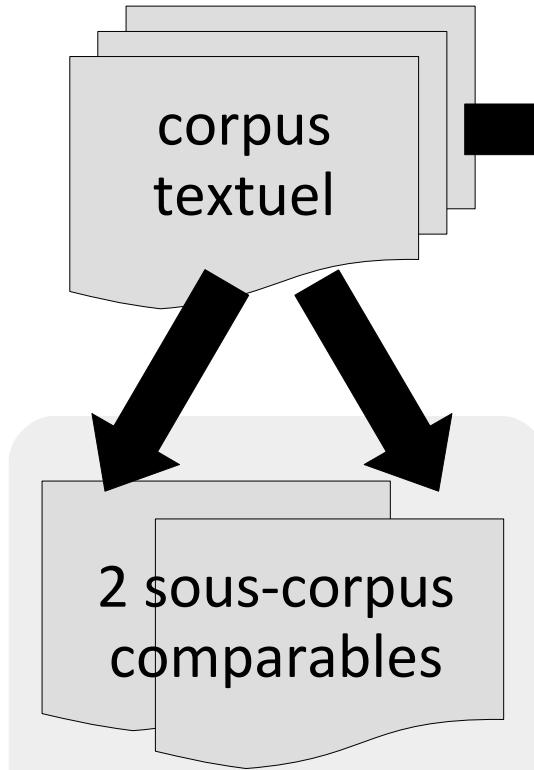
Nuage arboré des 50 mots les plus fréquents des contextes (10 mots avant et 10 mots après) du mot médecins dans le sous-corpus des articles sur le Mediator, colorés par le degré de cooccurrence avec le mot responsabilités (en noir pour les mots les plus cooccurrents), construit par TreeCloud avec la formule Liddell, et des fenêtres glissantes de 20 mots

# Nuages arborés des contextes de « médecins »



Nuage arboré des 50 mots les plus fréquents des contextes (10 mots avant et 10 mots après) du mot médecins dans le sous-corpus des articles sur le Mediator, colorés par le degré de cooccurrence avec le mot responsabilités (en noir pour les mots les plus cooccurrents), construit par TreeCloud avec la formule Liddell, et des fenêtres glissantes de 20 mots

# Exploration de corpus avec TreeCloud



- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)

Si le corpus est assez grand :

- Identifier les mots plutôt au début ou à la fin du corpus
- extraire le voisinage dans le corpus de certains mots ciblés et utiliser ces données comme corpus.

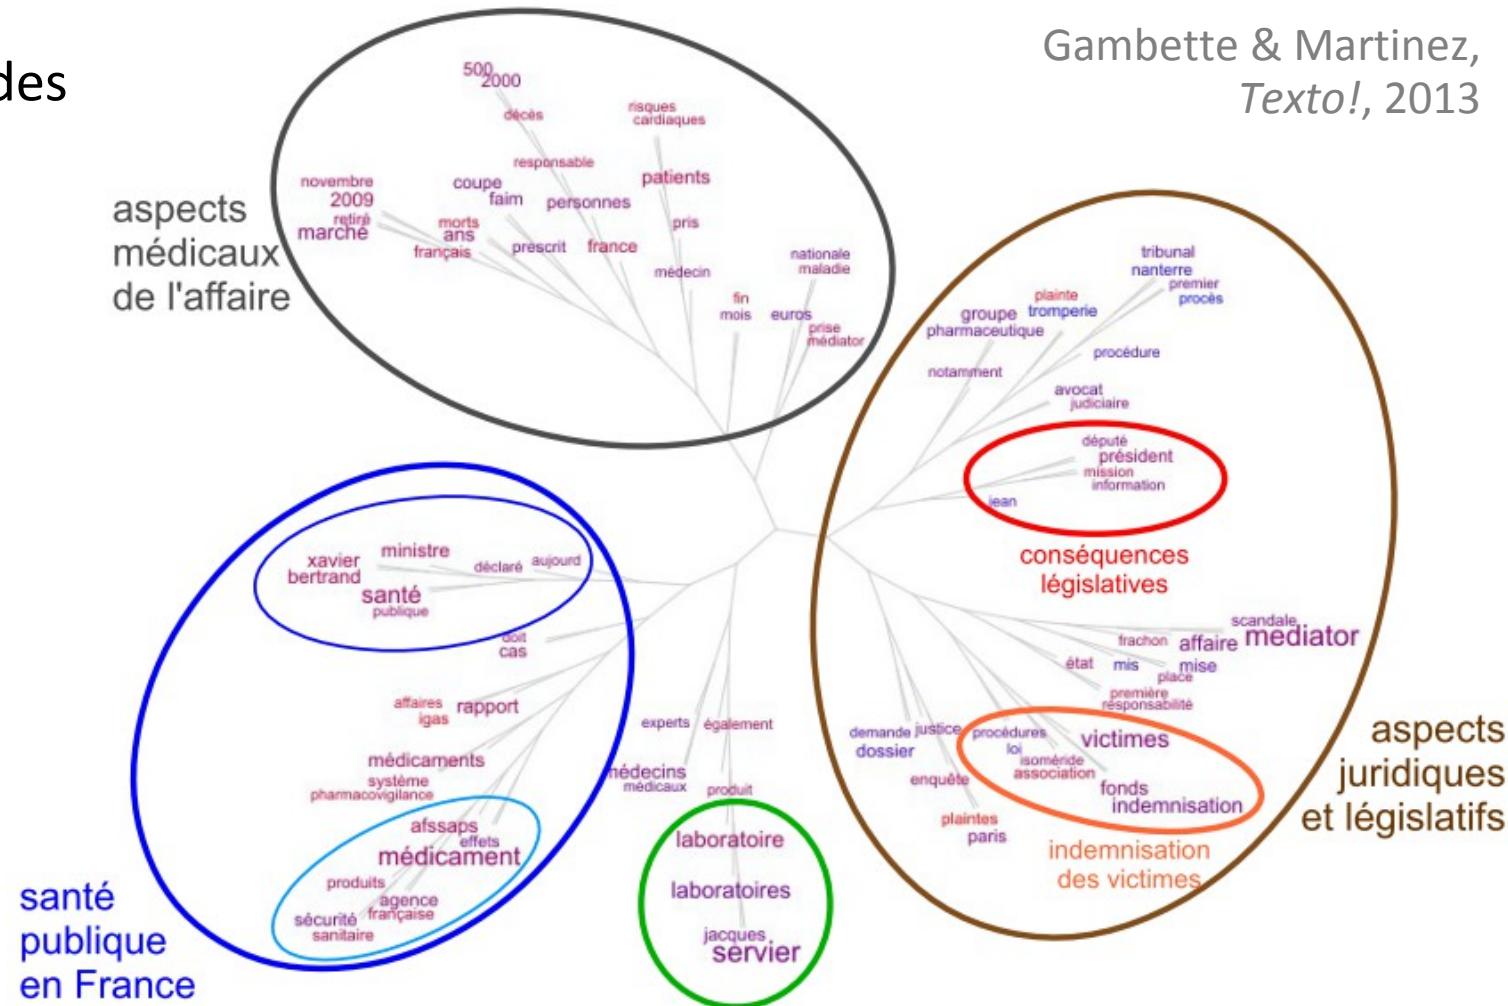
- **Identifier des regroupements communs ou différents**
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

# Illustration sur le corpus Mediator

## Comparer les articles d'agences et articles de journalistes

Corpus : 595 articles d'agences contre 1496 articles de journalistes de 2011 évoquant l'affaire du Mediator dans la presse française.

Ensemble des articles

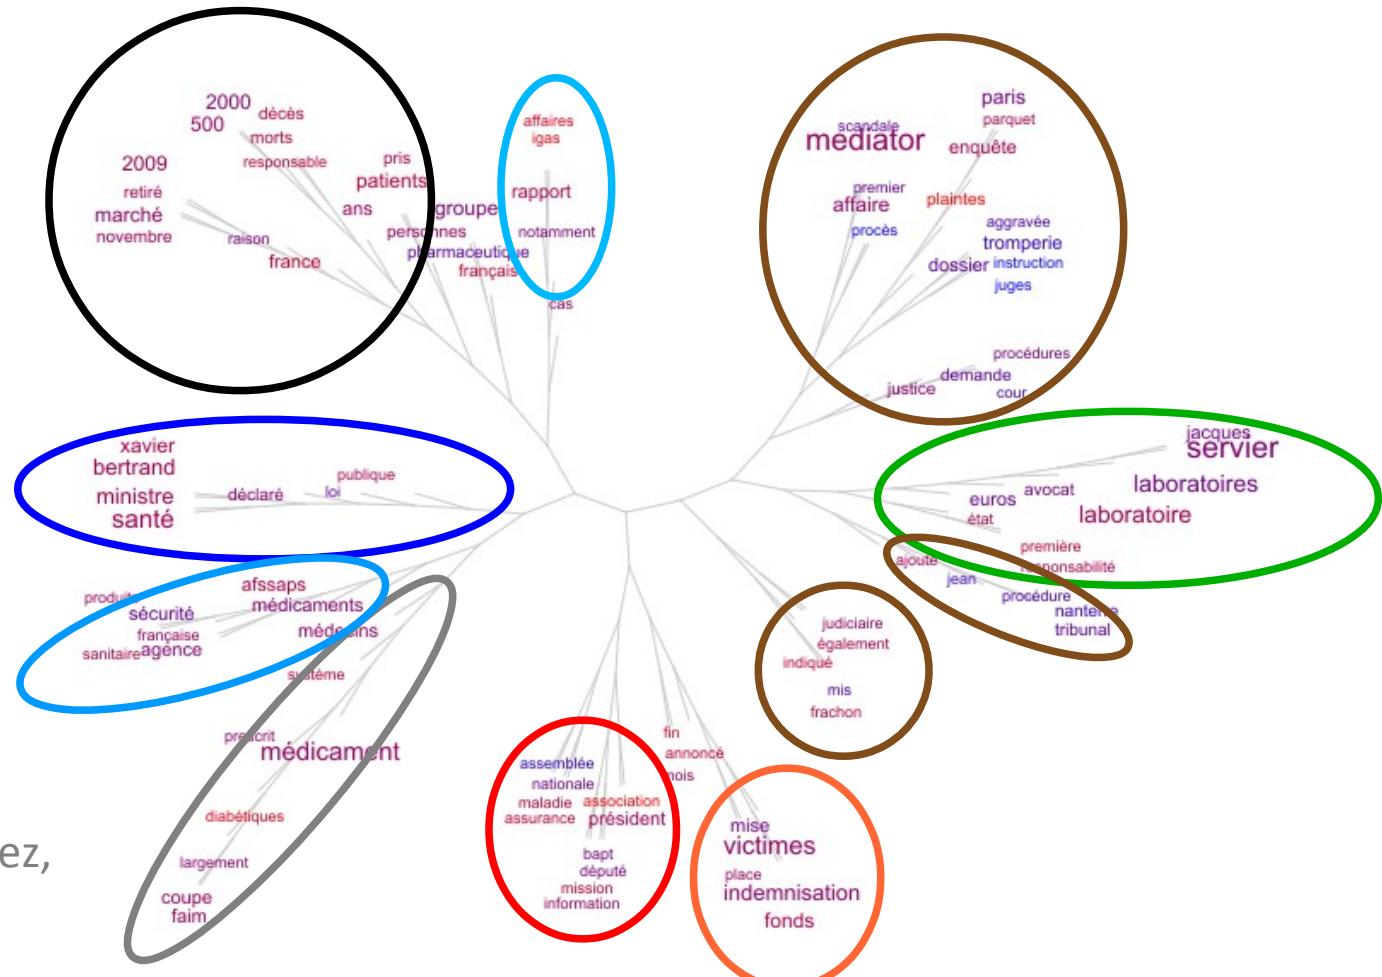


# Illustration sur le corpus Mediator

## Comparer les articles d'agences et articles de journalistes

Corpus : 595 articles d'agences contre 1496 articles de journalistes de 2011 évoquant l'affaire du Mediator dans la presse française.

### Articles d'agences

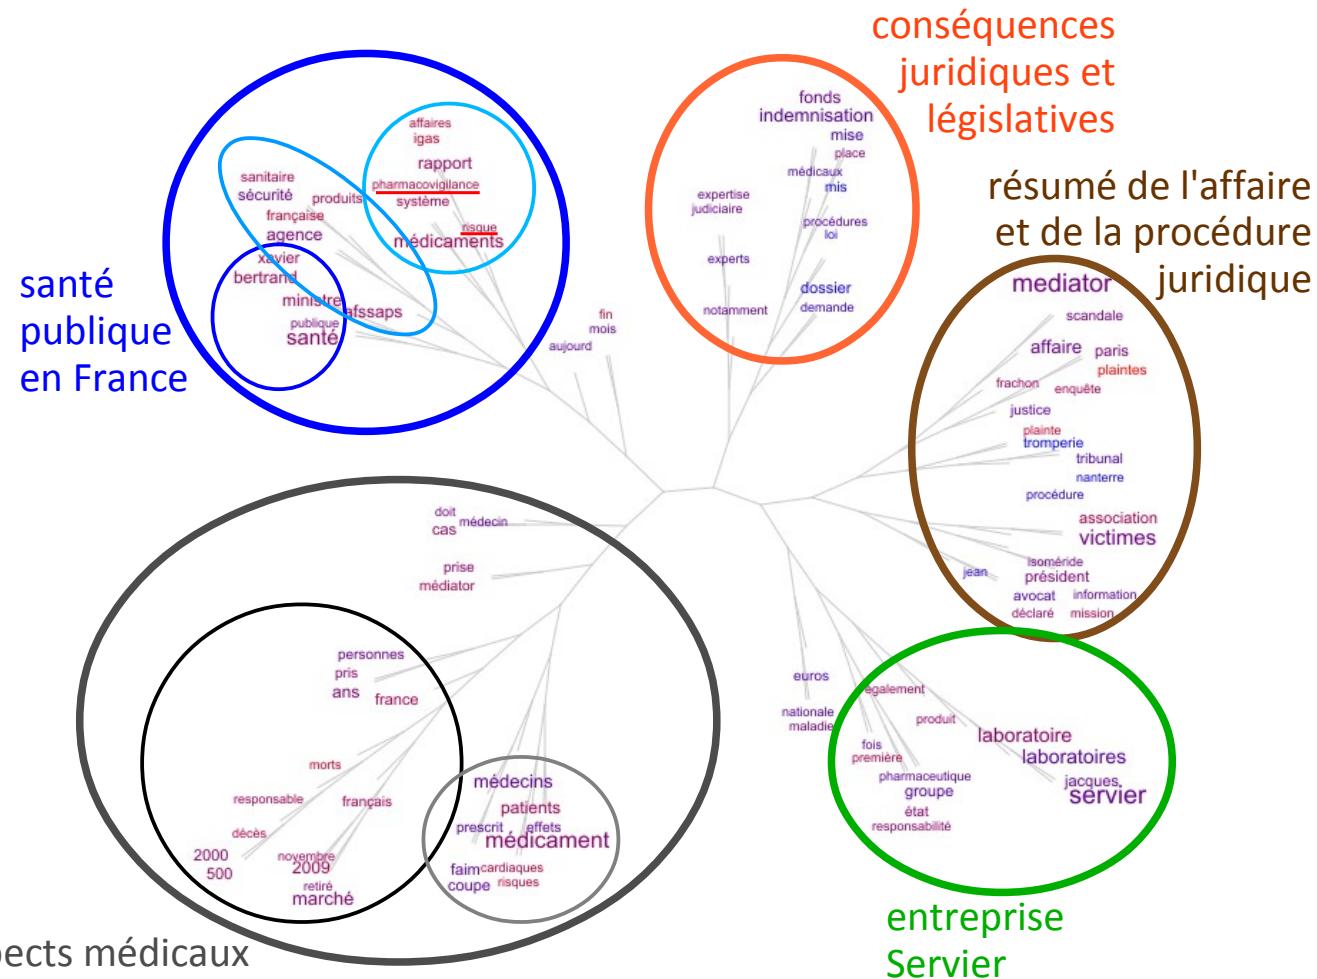


# Illustration sur le corpus Mediator

## Comparer les articles d'agences et articles de journalistes

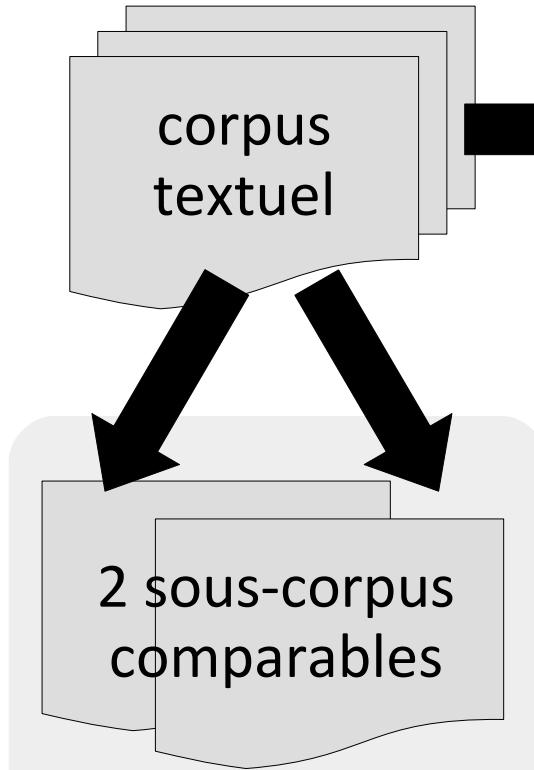
Corpus : 595 articles d'agences contre 1496 articles de journalistes de 2011 évoquant l'affaire du Mediator dans la presse française.

Articles  
de journalistes



Gambette & Martinez,  
*Texto!*, 2013

# Exploration de corpus avec TreeCloud



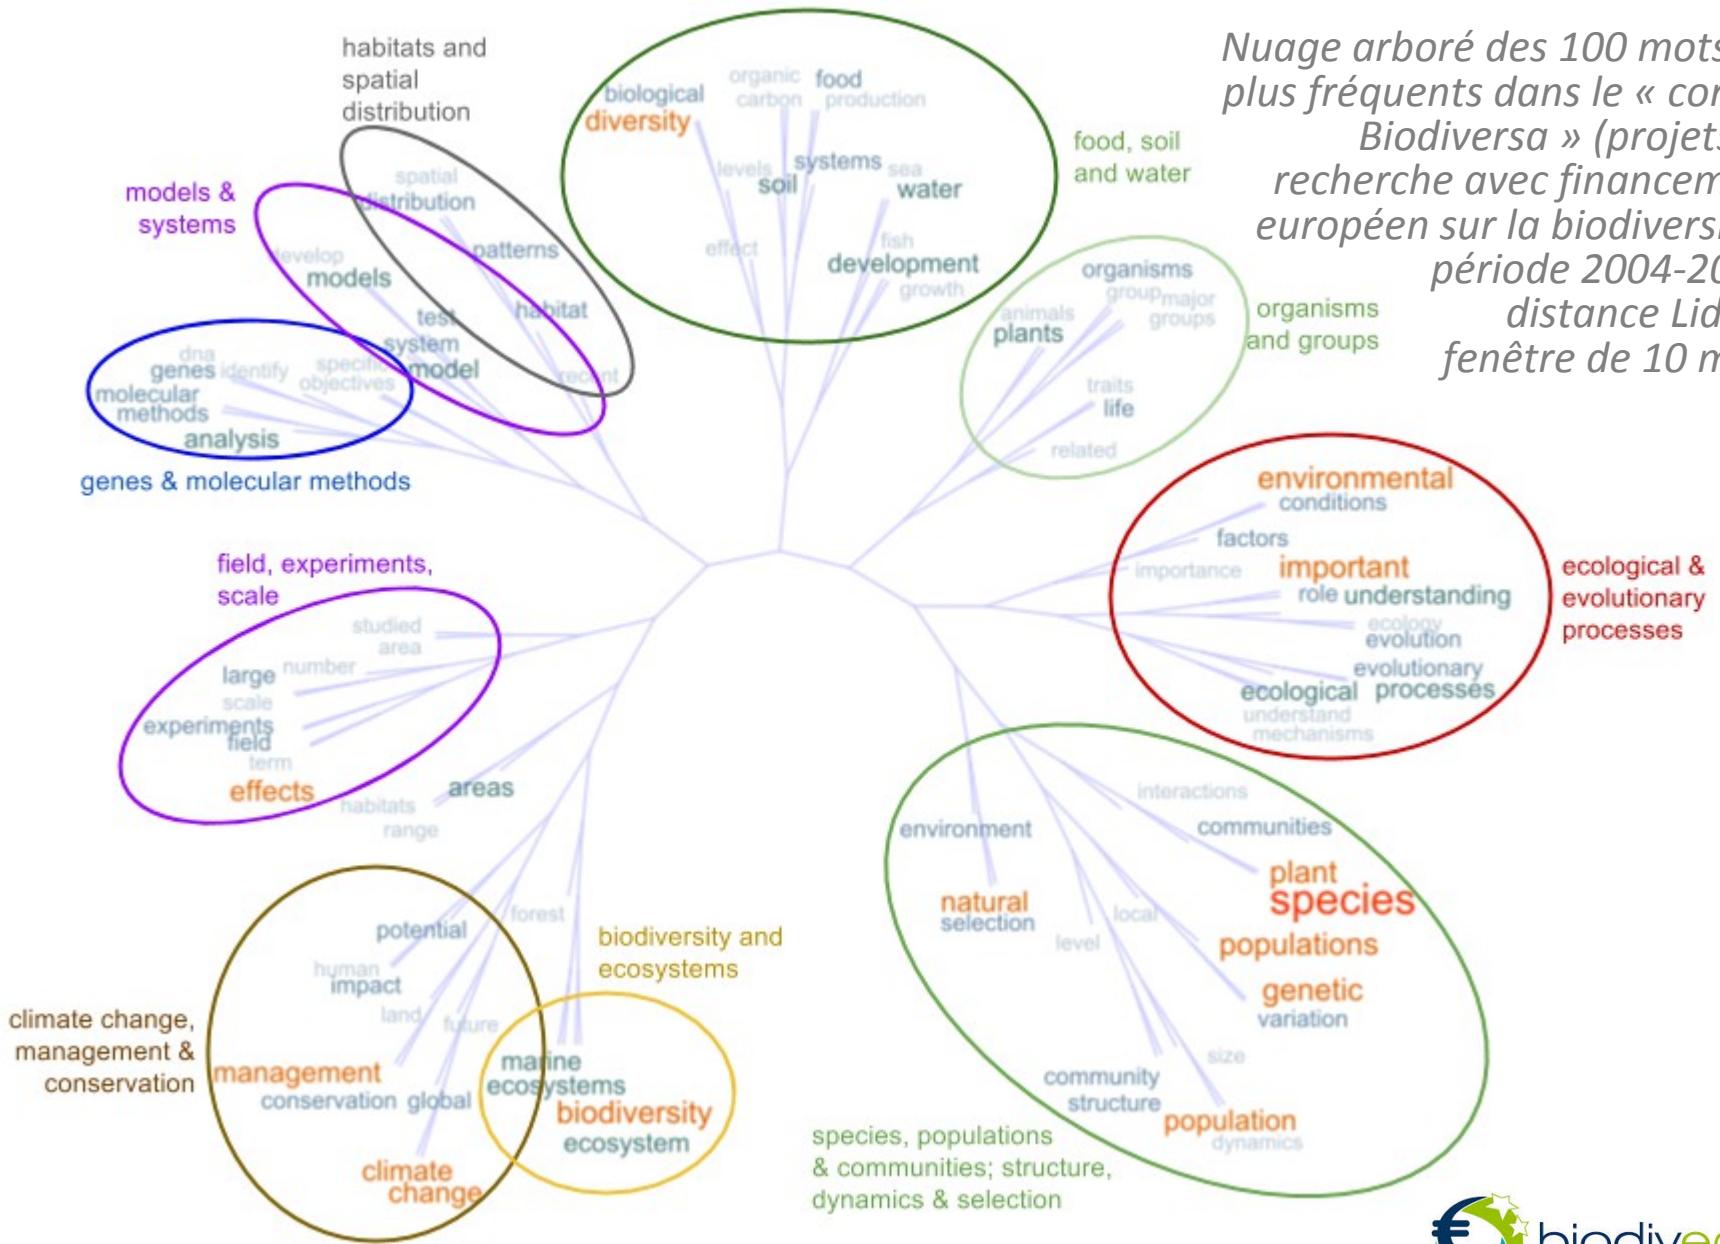
- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)

Si le corpus est assez grand :

- Identifier les mots plutôt au début ou à la fin du corpus
- extraire le voisinage dans le corpus de certains mots ciblés et utiliser ces données comme corpus.

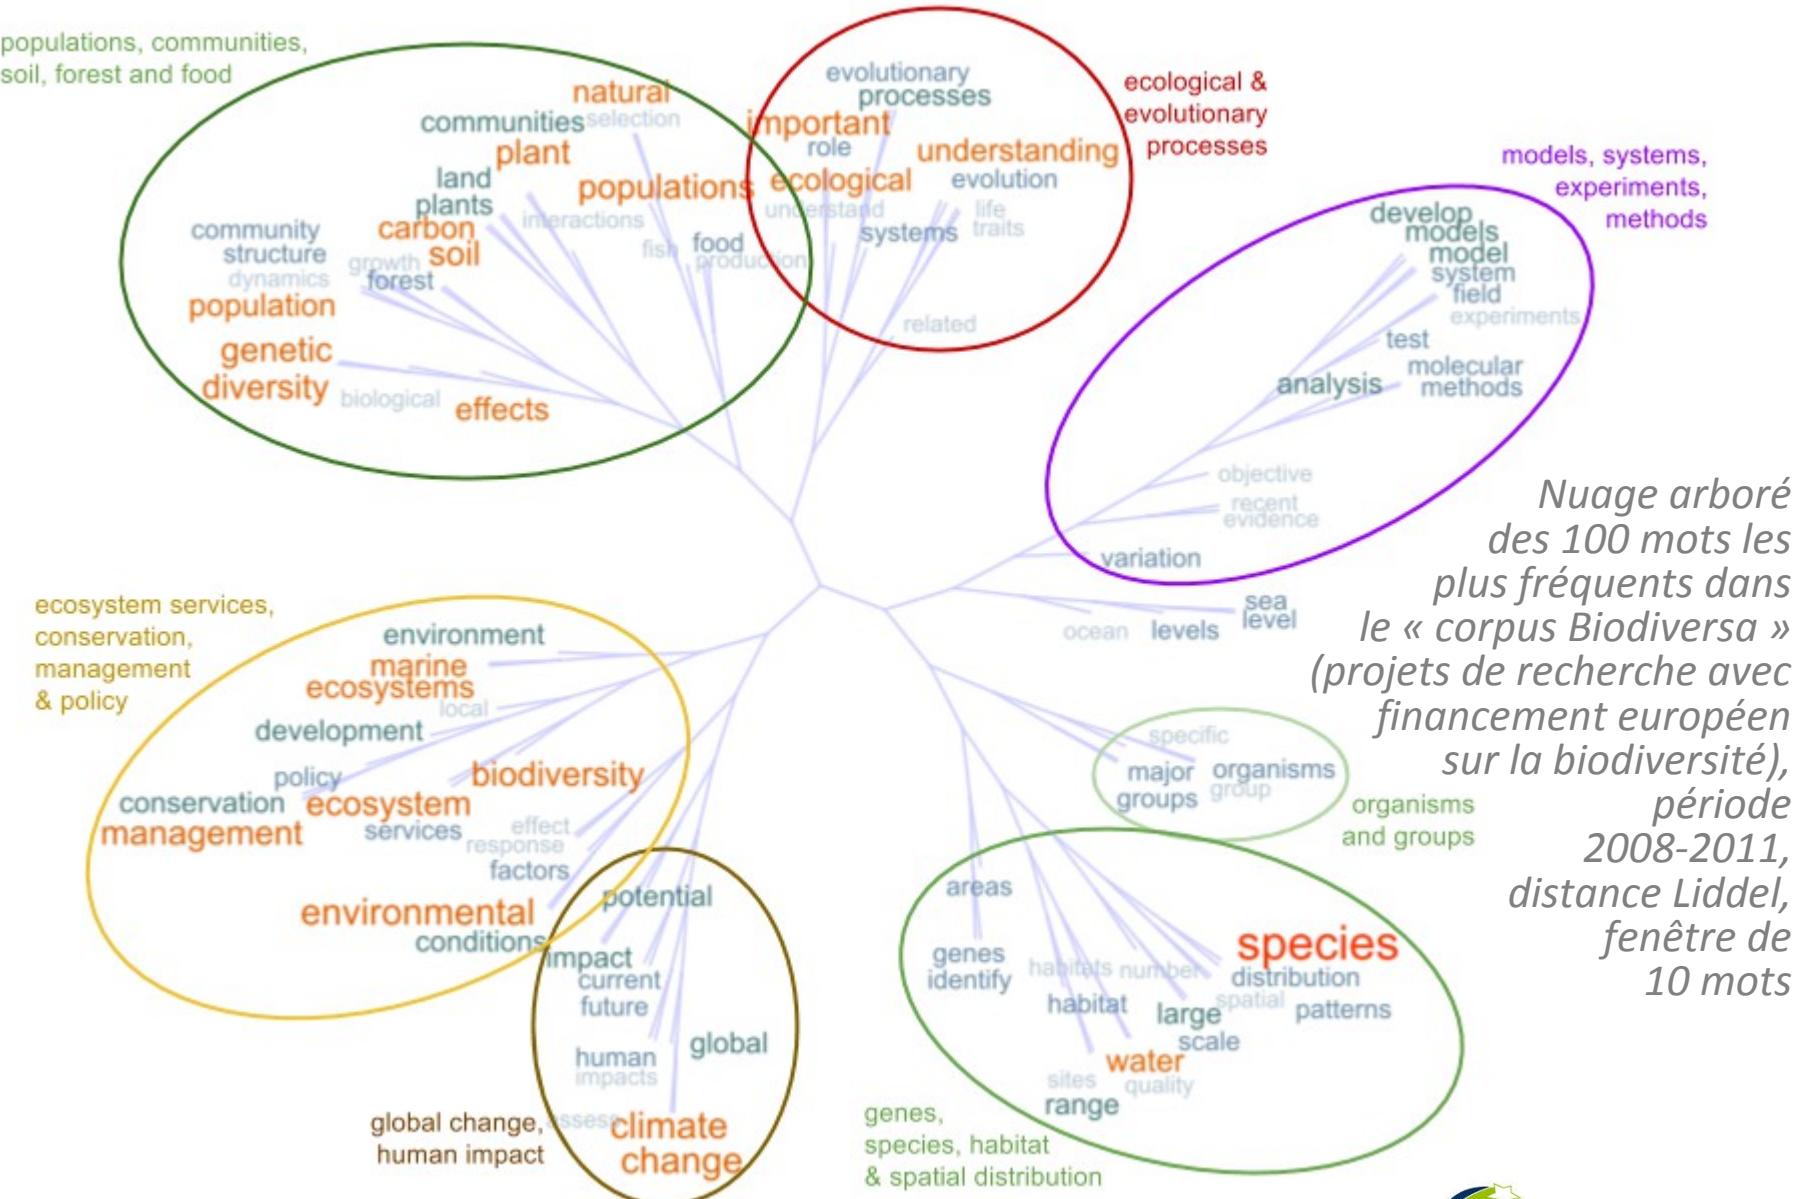
- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- **Comparer (quanti+quali) les regroupements dans les deux arbres**
- Construire le nuage arboré des mots spécifiques de chaque sous-corpus

# Méthode : comparaison de voisinages dans l'arbre

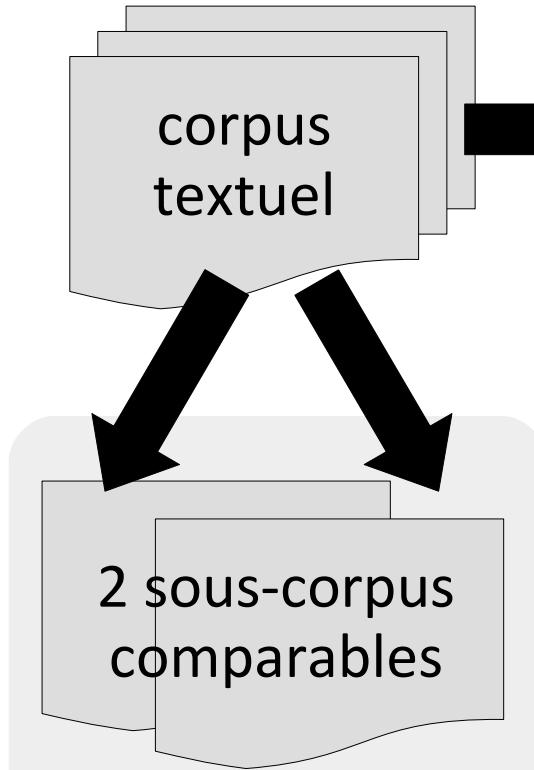


Nuage arboré des 100 mots les plus fréquents dans le « corpus Biodiversa » (projets de recherche avec financement européen sur la biodiversité), période 2004-2007, distance Liddel, fenêtre de 10 mots

# Méthode : comparaison de voisinages dans l'arbre



# Exploration de corpus avec TreeCloud



- Interpréter les regroupements
- Examiner les voisinages des mots fréquents dans l'arbre
- Examiner le voisinage de mots ciblés dans l'arbre («acteurs», verbes, etc.)

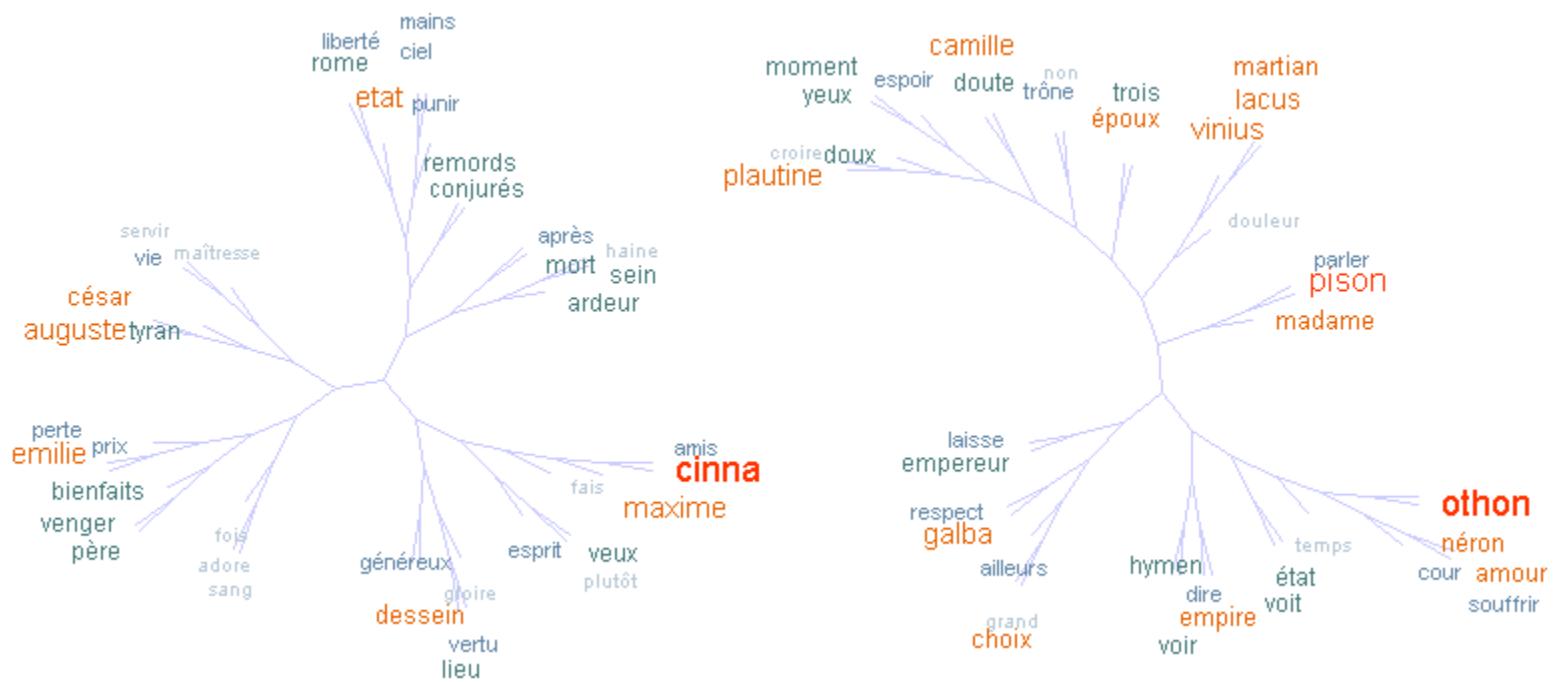
Si le corpus est assez grand :

- Identifier les mots plutôt au début ou à la fin du corpus
- extraire le voisinage dans le corpus de certains mots ciblés et utiliser ces données comme corpus.

- Identifier des regroupements communs ou différents
- Comparer la fréquence des mots fréquents dans les deux arbres
- Comparer (quanti+quali) les regroupements dans les deux arbres
- **Construire le nuage arboré des mots spécifiques de chaque sous-corpus**

# Méthode : comparaison des spécifiques

Amstutz & Gambette,  
JADT 2010



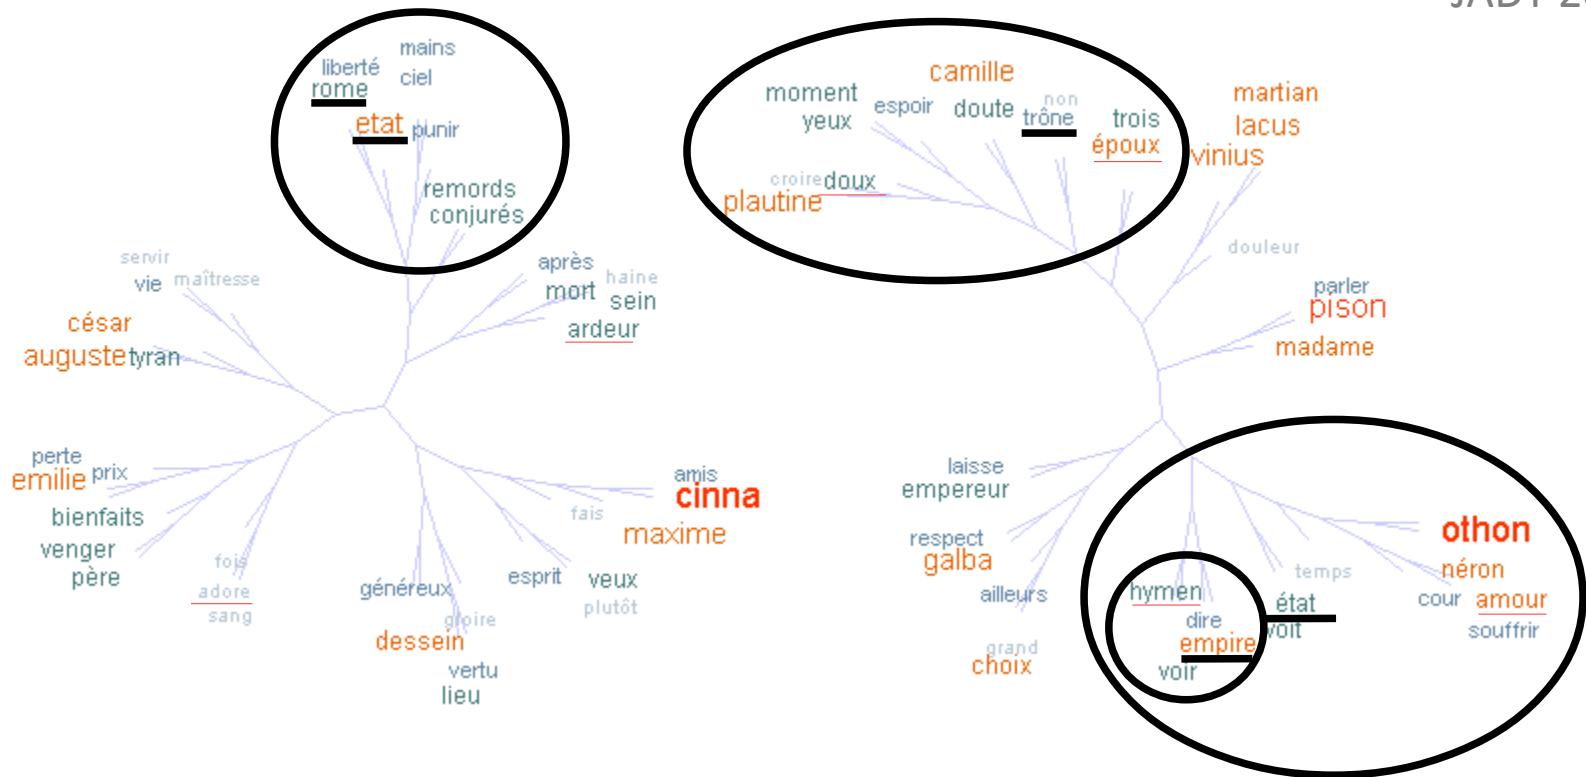
*Nuages arborés des mots spécifiques de Cinna et Othon, dimensionnés et colorés d'après leur spécificité calculée dans Lexico3.*

Quels moyens au service de la cause politique ?



# Méthode : comparaison des spécifiques

Amstutz & Gambette,  
JADT 2010

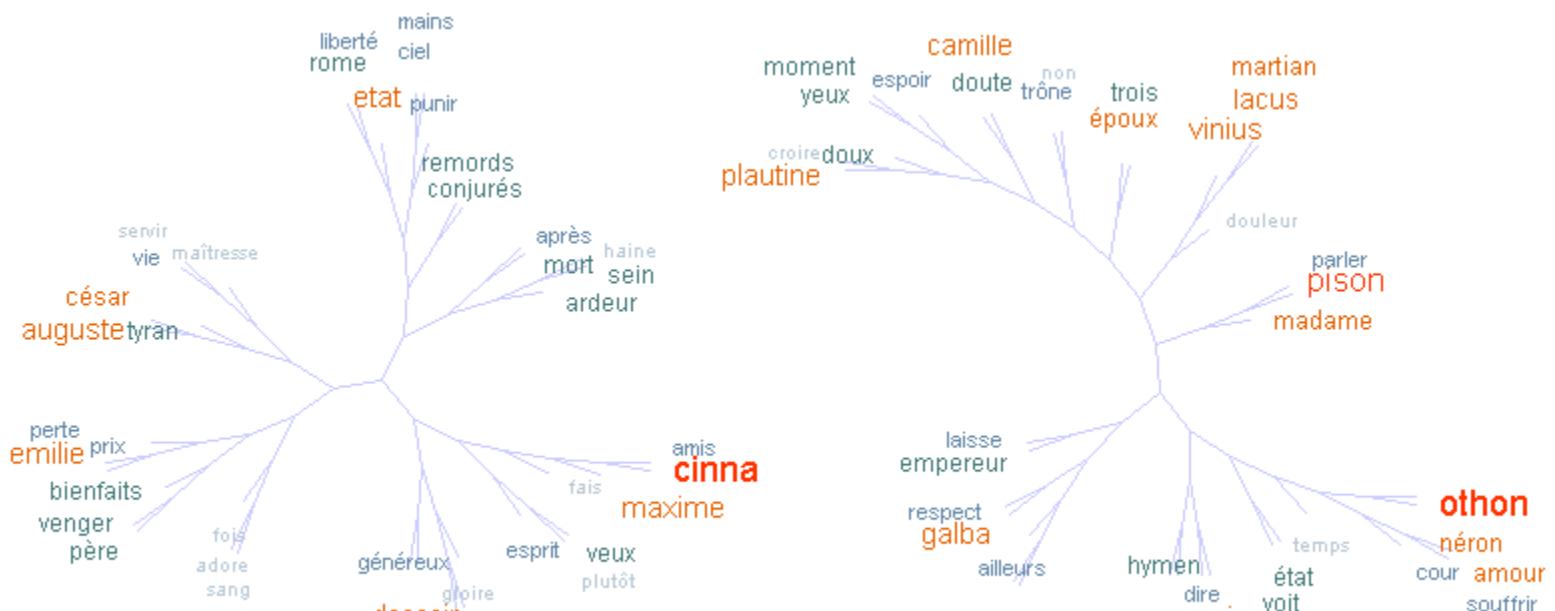


*Nuages arborés des mots spécifiques de Cinna et Othon, dimensionnés et colorés d'après leur spécificité calculée dans Lexico3.*



Quels moyens au service de la cause politique ?

# Méthode : comparaison des spécifiques

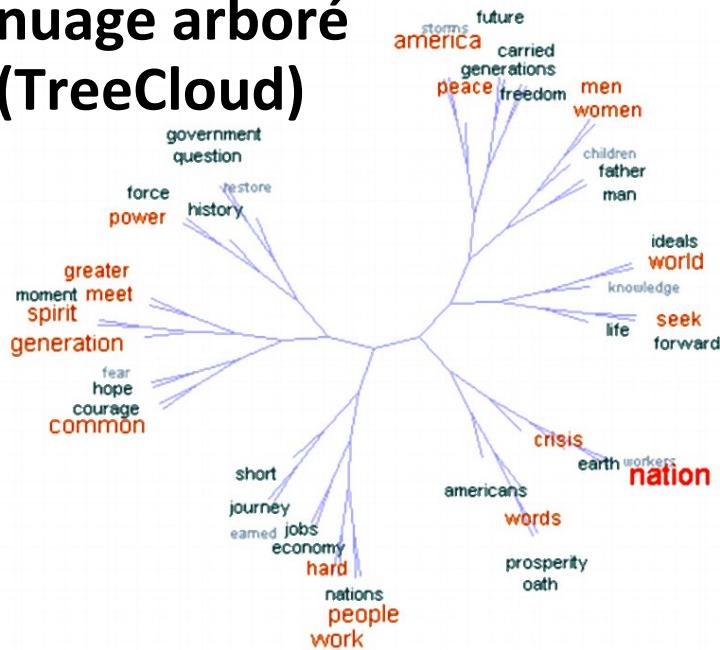


*mots spécifiques de  
Cinna et Othon d'après Lexico3*

|  | <i>Cinna</i>       | <i>Othon</i>  |
|--|--------------------|---|
| Lieu du pouvoir et objet de la confrontation entre les personnages | Rome (« liberté ») | Empire (« trône »)                                  |
| Souverain en place   | tyran              | Empereur  |
| Membres du corps politique   | amis               | maîtres / seigneurs                                 |
| Moyens au service de la cause politique                            | gloire             | amour matrimonial (« amour », « hymen », « choix ») |
| Caractérisation de la pièce  | Pièce de FONDATION | Pièce de SUCCESSION DYNASTIQUE                      |

# Comparaison avec d'autres visualisations

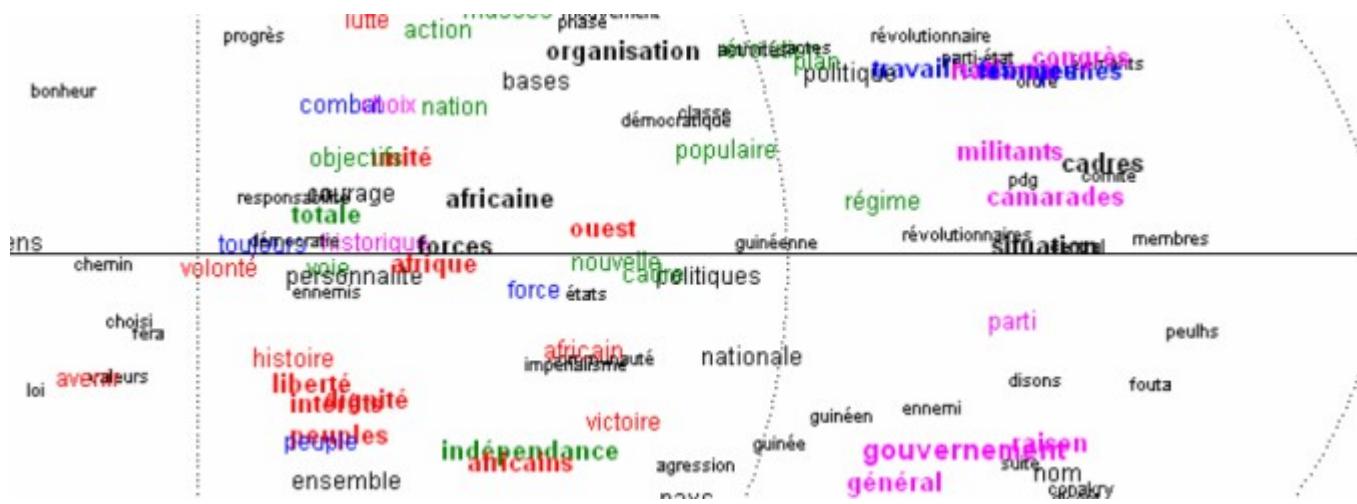
nuage arboré  
(TreeCloud)



réseau de mots  
(PhraseNet d'IBM ManyEyes)



projection des mots (Astartex)



# Comparaison avec d'autres visualisations

nuage arboré  
(TreeCloud)



information globale

réseau de mots  
(PhraseNet d'IBM ManyEyes)



information locale

projection des mots (Astartex)



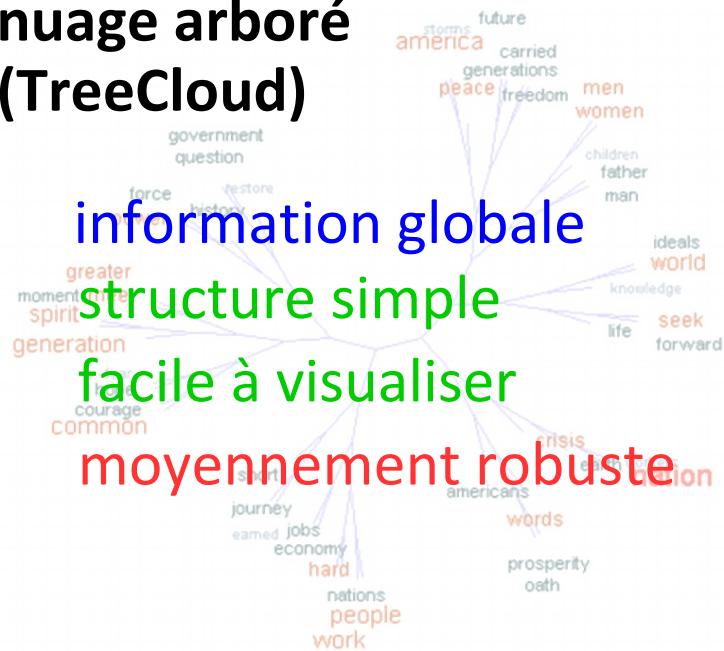
information globale





# Comparaison avec d'autres visualisations

## nuage arboré (TreeCloud)



information globale  
structure simple  
facile à visualiser  
moyennement robuste

## réseau de mots (PhraseNet d'IBM ManyEyes)



## projection des mots (Astartex)

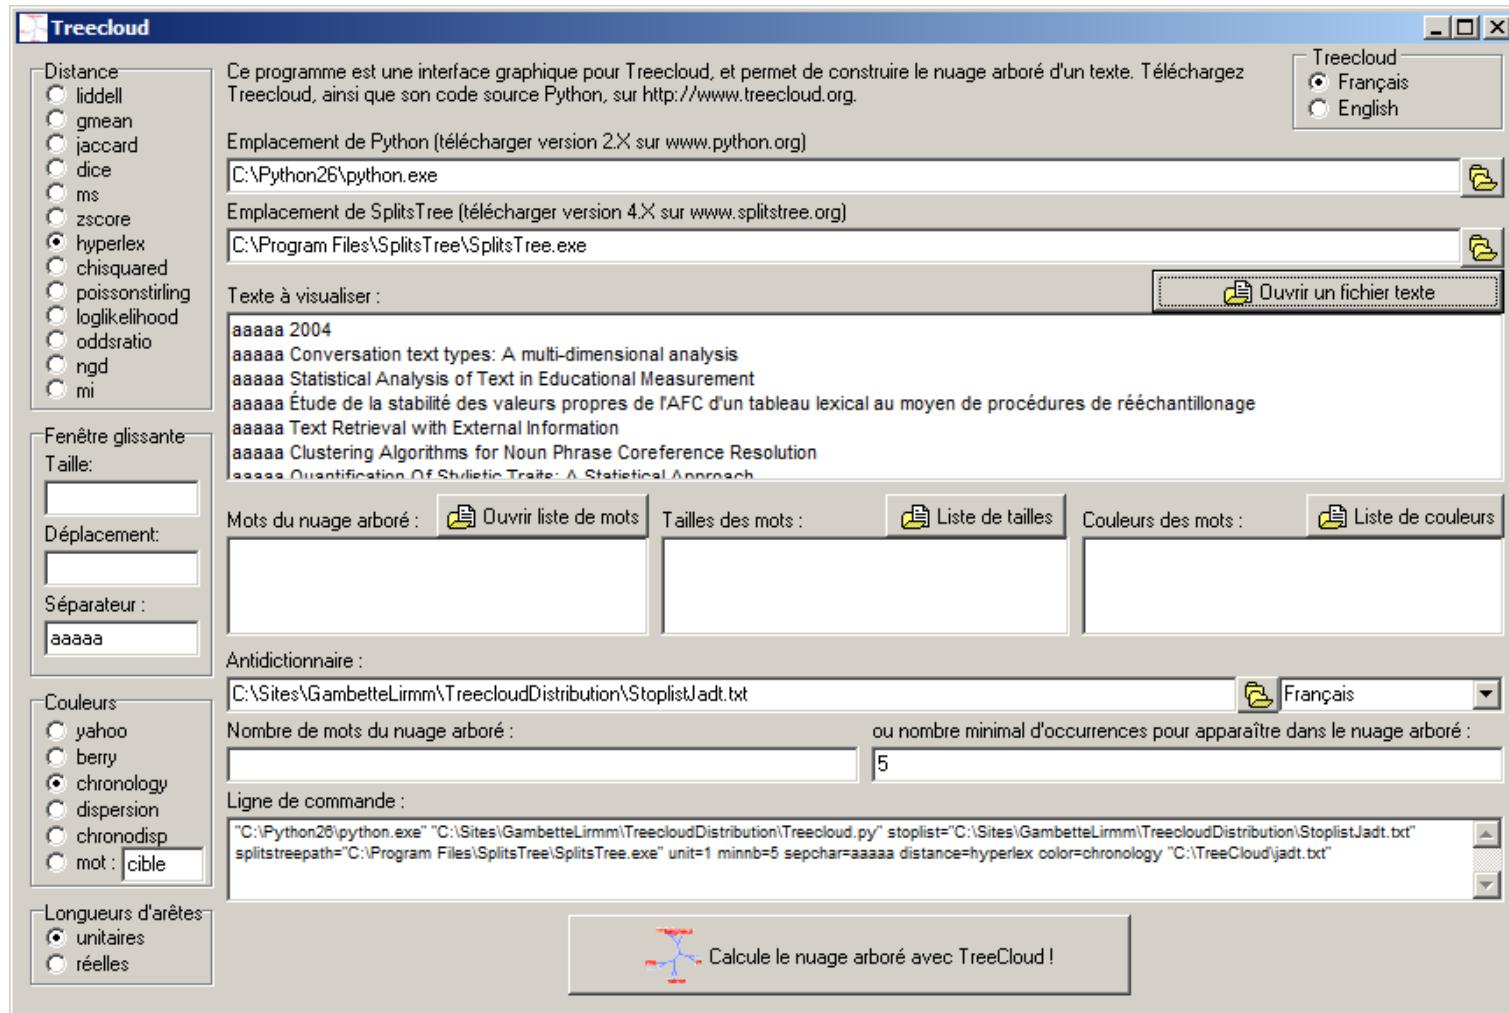


information globale  
structure complexe  
facile à visualiser mais chevauchements  
robuste



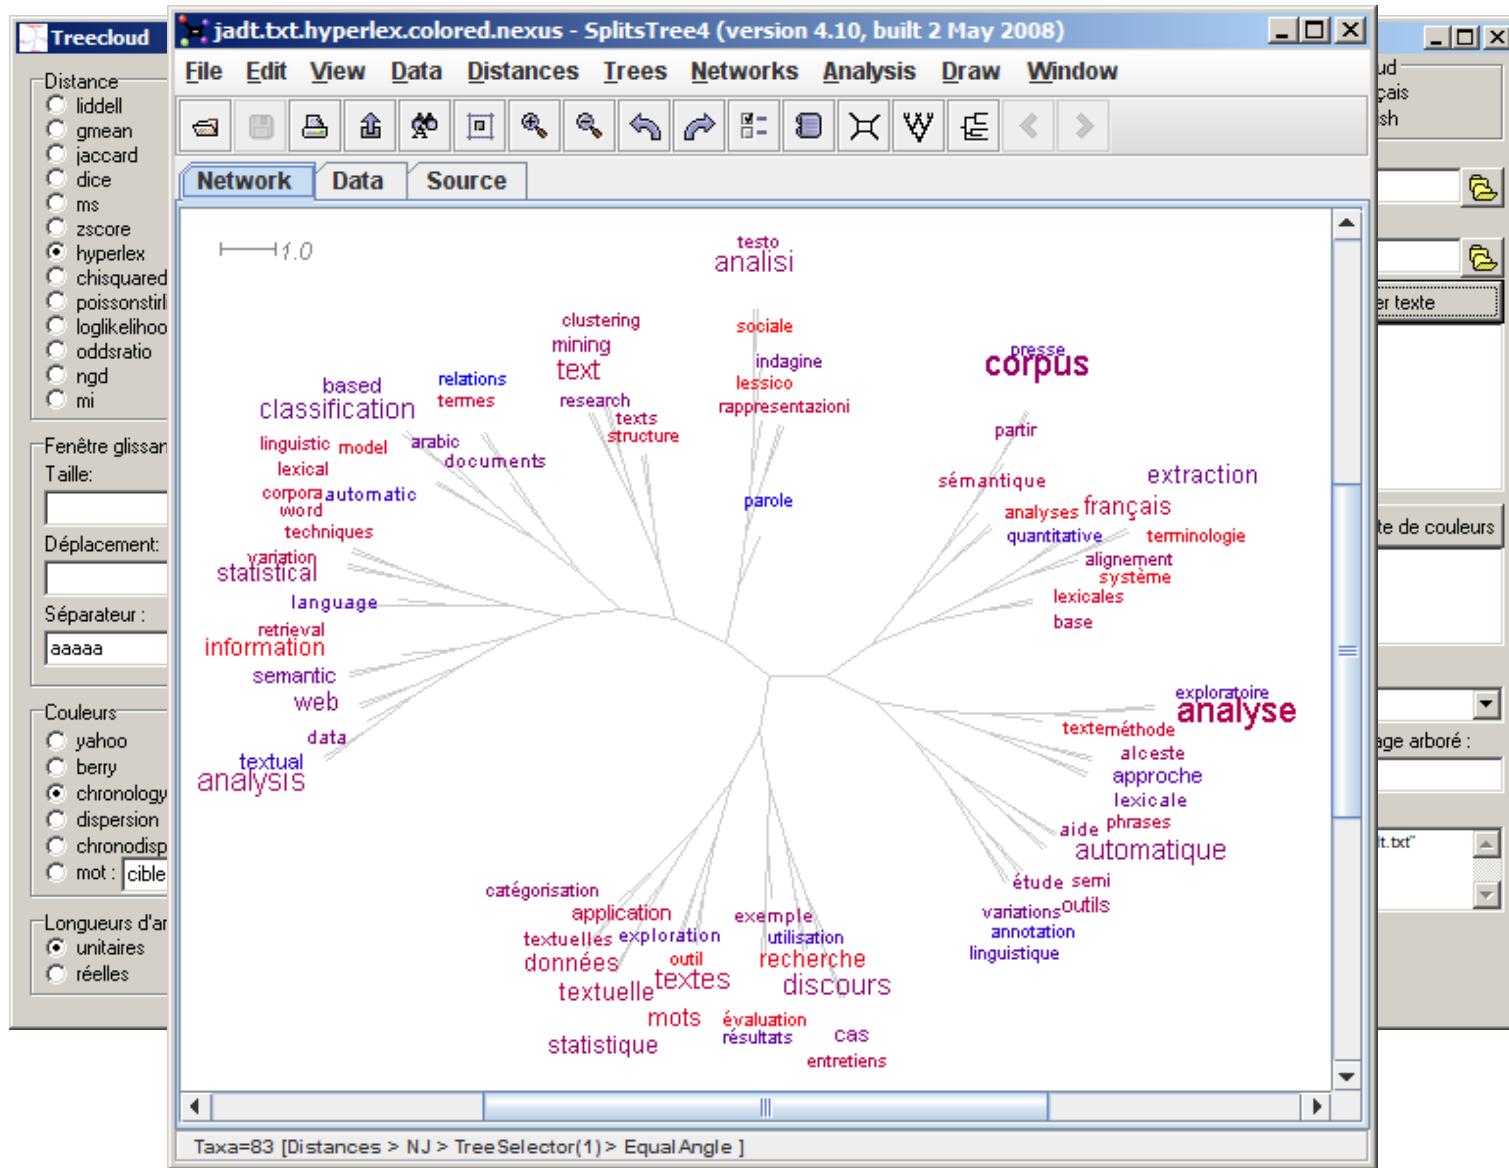
# Implémentations

## Logiciel libre TreeCloud (Python/Delphi) + SplitsTree (Java)



# Implémentations

Logiciel libre TreeCloud (Python/Delphi) + SplitsTree (Java)



# Interface web

 TreeCloud.org Nuage Arboré

Create! Downloads Gallery Credits FAQ  
Créer! Téléchargements Gallerie A propos FAQ

This website helps you to generate **tree clouds** from a text, that is word clouds where the words are arranged on a tree which reflects their semantic proximity inside the text. The first tree cloud appeared on [Jean Véronis's blog](#) in December 2007, you can now [create your own with this website](#), or [with the TreeCloud software](#).

**Create your own tree cloud online!**

Ce site web vous permet de générer des **nuages arborés** à partir d'un texte, c'est à dire des nuages de mots disposés autour d'un arbre qui indique leur proximité dans le texte. Le premier nuage arboré est apparu sur le [blog de Jean Véronis](#) en décembre 2007, vous pouvez maintenant [créer les vôtres avec ce site web](#), ou [avec le logiciel TreeCloud](#).

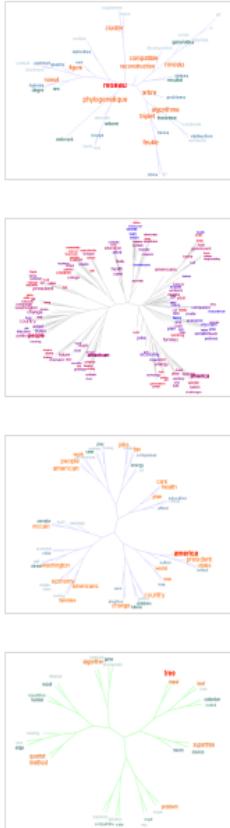
**Créez vos propres nuages arborés en ligne !**

**Documents :**


If you use TreeCloud or this website, please cite [www.treecloud.org](http://www.treecloud.org) or:  
Philippe Gambette et Jean Véronis: *Visualising a Text with a Tree Cloud*, In Locarek-Junge H. and Weihs C., editors, *Classification as a Tool of Research*, Proc. of *IFCS'09* (11th Conference of the International Federation of Classification Societies), to appear, 2010 ([supplementary material](#)).

Pour des exemples d'utilisation de la visualisation en nuage arboré, vous pouvez lire :  
Delphine Amstutz et Philippe Gambette: *Utilisation de la visualisation en nuage arboré pour l'analyse littéraire*, Proc. of *JADT'10* (10th International Conference on statistical analysis of textual data), à paraître, 2010 ([matériel supplémentaire](#)).



[www.treecloud.org](http://www.treecloud.org)

Interface basée sur le logiciel libre NuageArboré de Jean-Charles Bontemps, en C, CGI/Python, et JavaScript.

<http://sourceforge.net/projects/nuagearbor/>

Développements supplémentaires avec d3.js par Deepak Srinivas

# Interface web

 TreeCloud.org Nuage Arboré  
Create! Downloads Gallery Credits FAQ  
Créer! Téléchargements Gallerie A propos FAQ

[www.treecloud.org](http://www.treecloud.org)

This website helps you to generate tree clouds. Words are arranged on a tree which reflects the semantic relations between them. The first tree cloud appeared on [Jean Véronis's website](#), or you can [create your own with this website](#), or with the [Java applet](#).

## Create your own tree cloud online

Ce site web vous permet de générer des nuages de mots. Les mots sont disposés autour d'un arbre qui reflète les relations sémantiques entre eux. Le premier nuage arboré est apparu sur le site de [Jean Véronis](#). Vous pouvez maintenant [créer les vôtres avec ce site](#).

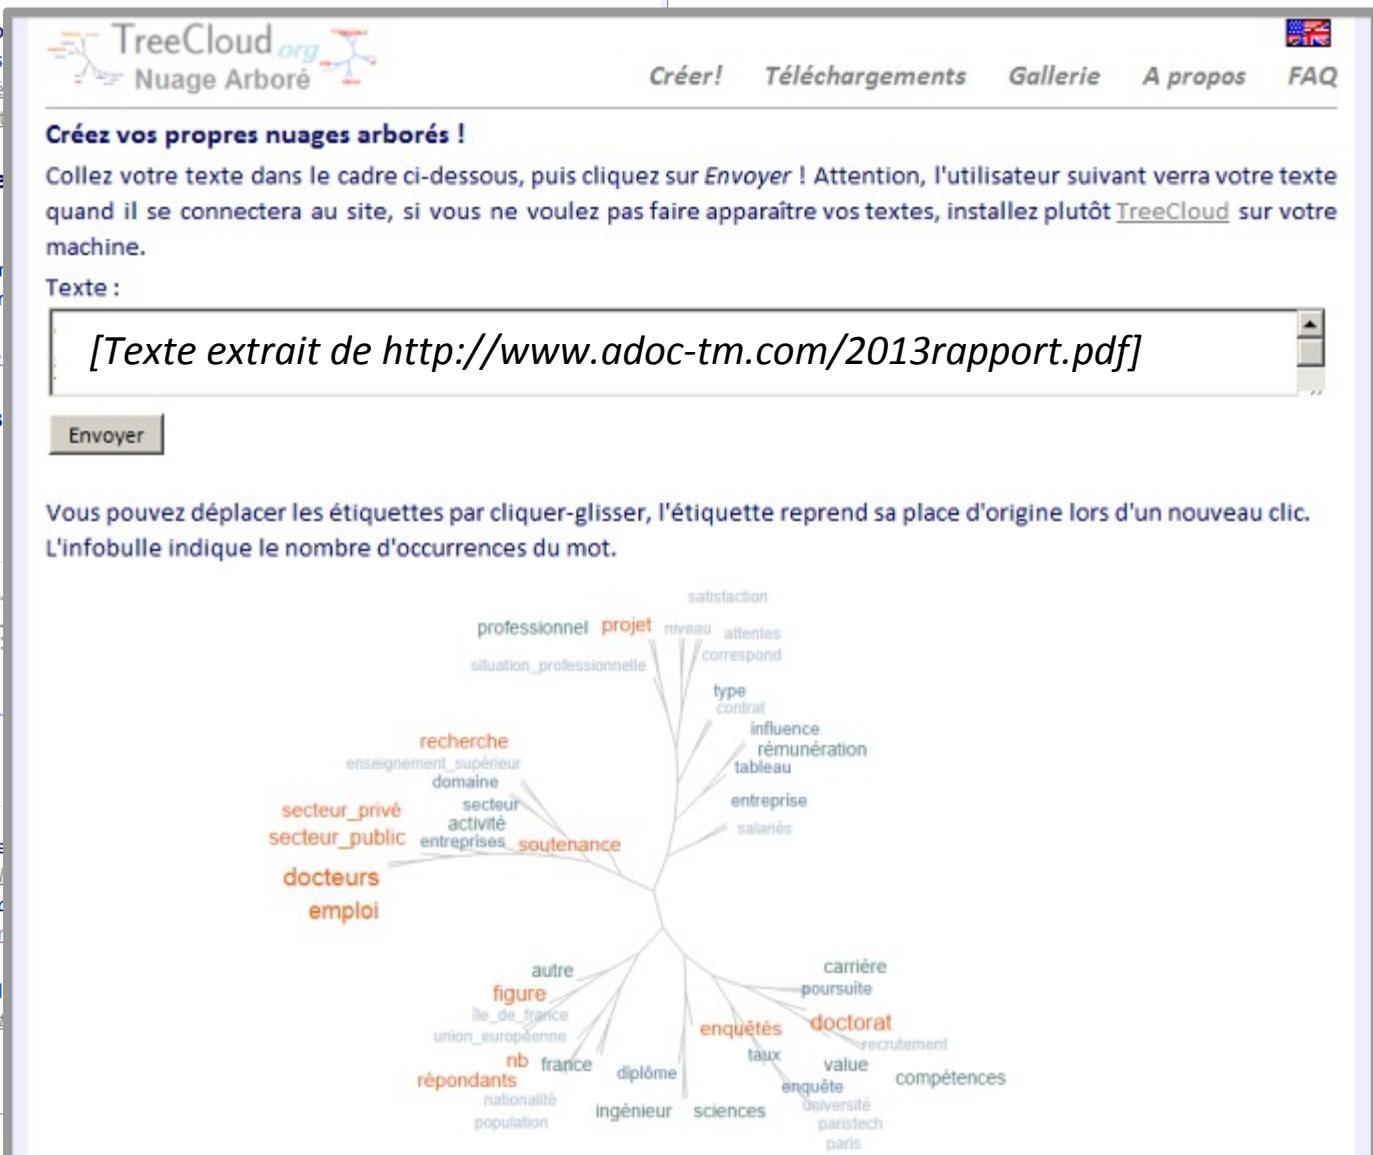
## Créez vos propres nuages arborés

### Documents :



If you use TreeCloud or this website, please cite Philippe Gambette et Jean Véronis: *Visual Classification as a Tool of Research*, Proc. of the International Conference on Societies, to appear, 2010 ([supplementary material](#)).

Pour des exemples d'utilisation de la visual classification, voir Delphine Amstutz et Philippe Gambette: *User-centered classification of concepts*, Proc. of JADT'10 (10th International Conference on Data Analysis for Decision Support), supplémentaire).



# Interface web

 TreeCloud.org Nuage Arboré  
Create! Downloads Gallery Credits FAQ  
Créer! Téléchargements Gallerie A propos FAQ

[www.treecloud.org](http://www.treecloud.org)

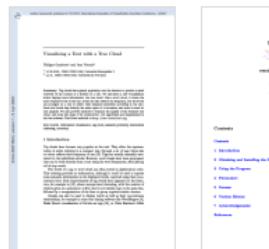
This website helps you to generate tree clouds.  
words are arranged on a tree which reflects  
The first tree cloud appeared on [Jean Véronis's website](#). You can  
create your own with this website, or with the software.

## Create your own tree cloud online

Ce site web vous permet de générer des nuages de mots. Des nuages de mots disposés autour d'un arbre. Le premier nuage arboré est apparu sur le site [Nuage Arboré](#). Vous pouvez maintenant créer les vôtres avec ce site.

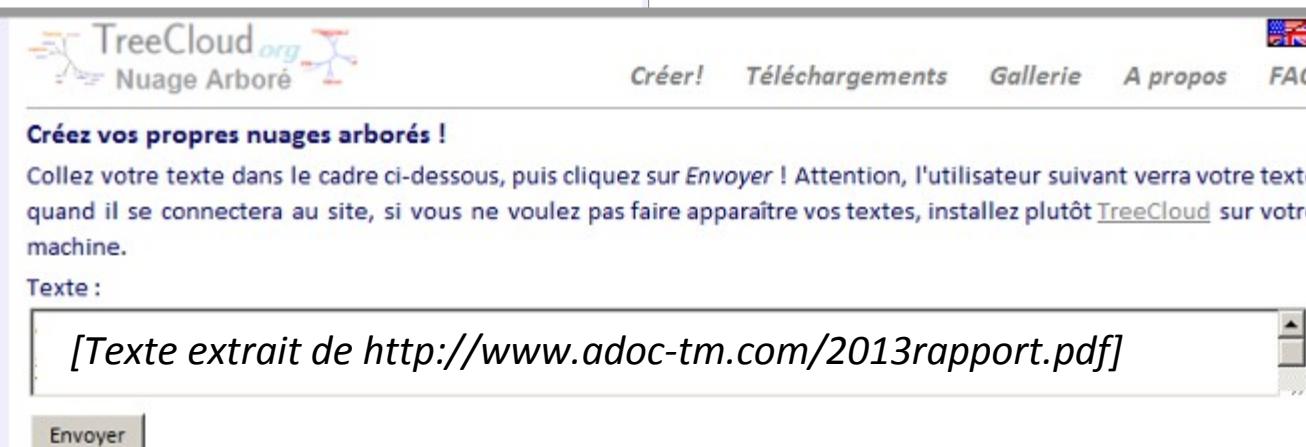
## Create your own tree clouds

### Documents :

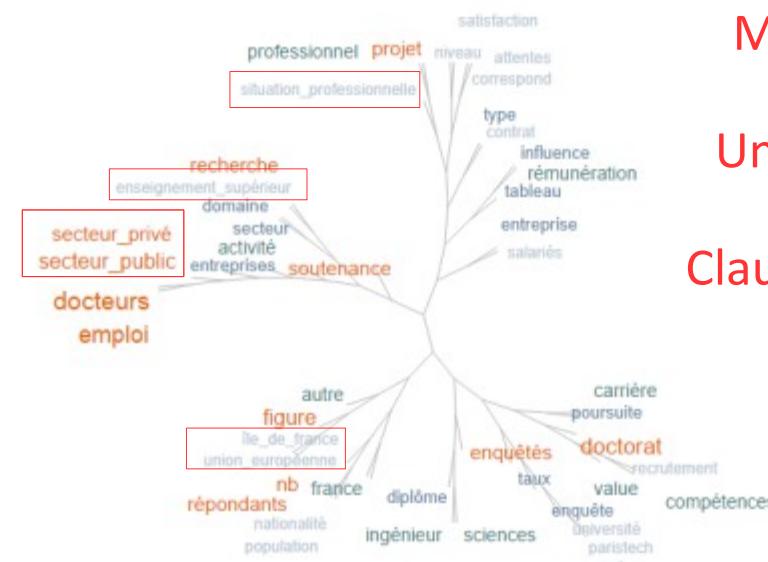


If you use TreeCloud or this website, please cite Philippe Gambette et Jean Véronis: *Visual Classification as a Tool of Research, Proc. of the International Conference on Societies*, to appear, 2010 ([supplementary material](#)).

Pour des exemples d'utilisation de la visual classification, voir Delphine Amstutz et Philippe Gambette: *Using TreeCloud to Classify Data*, Proc. of the *JADT'10 (10th International Conference on Data Analysis)* (supplémentaire).

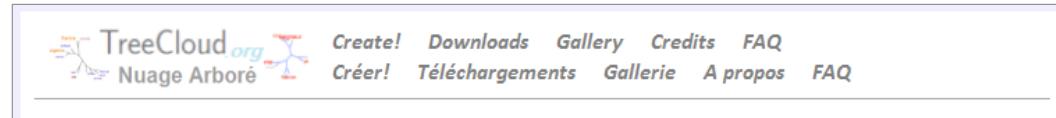


Vous pouvez déplacer les étiquettes par cliquer-glisser, l'étiquette reprend sa place d'origine lors d'un nouveau clic. L'infobulle indique le nombre d'occurrences du mot.



**Mots composés identifiés par Unitex, intégré à TreeCloud par Claude Martineau**

# Interface web



www.treecloud.org

This website helps you to generate tree clouds from a text, that is word clouds where the words are arranged on a tree which reflects their semantic relations.

The first tree cloud appeared on [Jean Véronis's blog](#), [create your own with this website](#), or [with the TreeCloud API](#).

**Create your own tree cloud online!**

Ce site web vous permet de générer des nuages arborés à partir d'un texte. Des nuages de mots disposés autour d'un arbre qui indiquent leur relation de sens. Le premier nuage arboré est apparu sur le [blog de Jean Véronis](#). Vous pouvez maintenant créer les vôtres avec ce site web, ou avec l'[API](#).

**Créez vos propres nuages arborés en ligne**

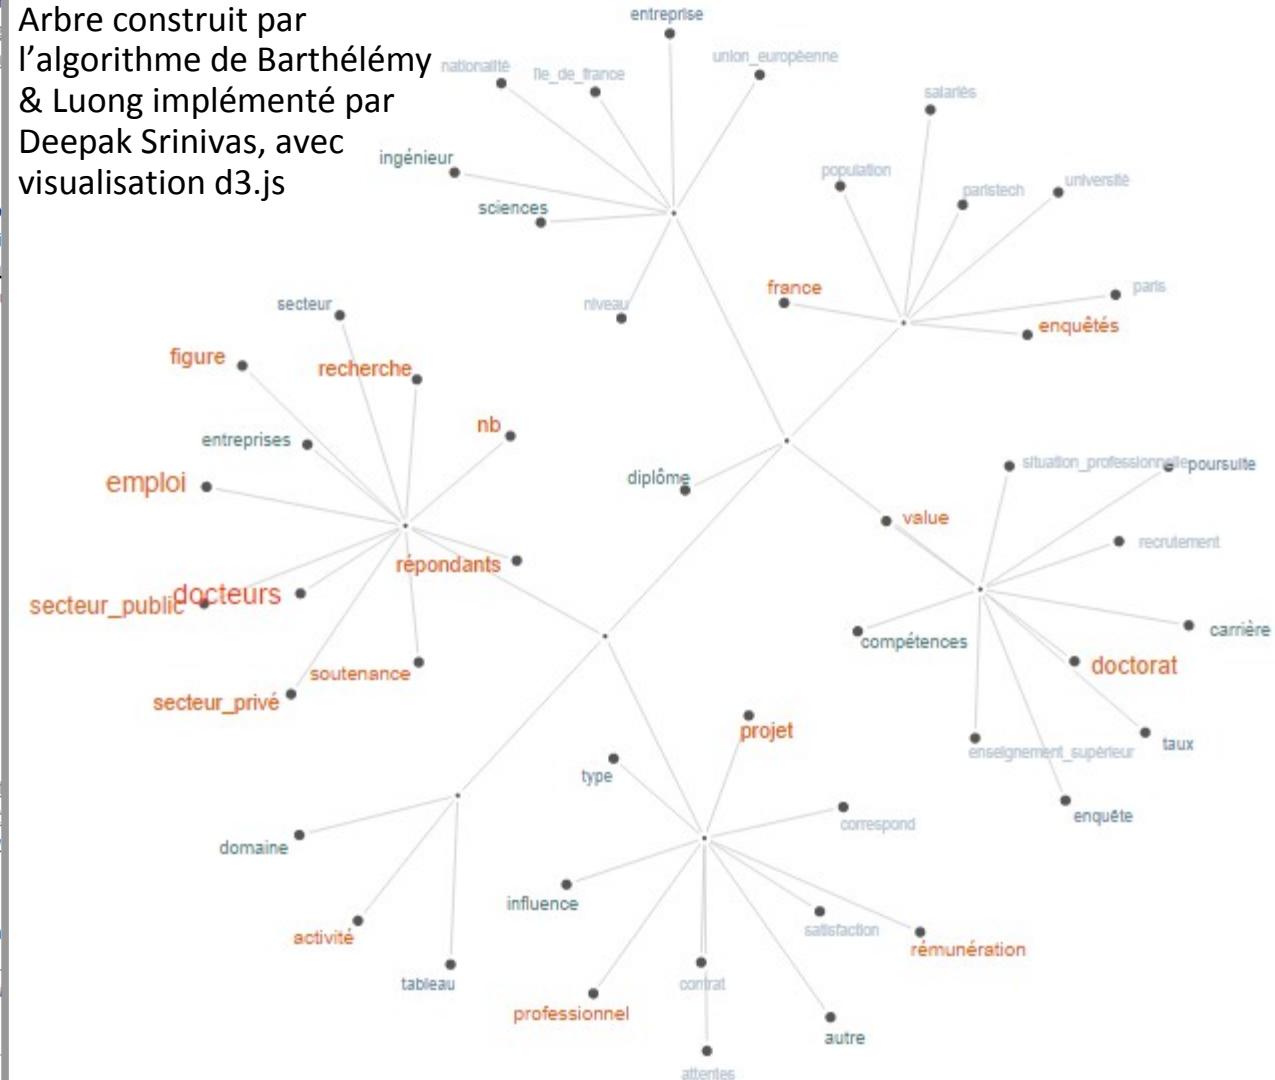
## Documents :



If you use TreeCloud or this website, please cite [www.treecloud.org](#).  
Philippe Gambette et Jean Véronis: *Visualising a Text Classification as a Tool of Research*, Proc. of *IFCS'09* (1 Societies), to appear, 2010 (supplementary material).

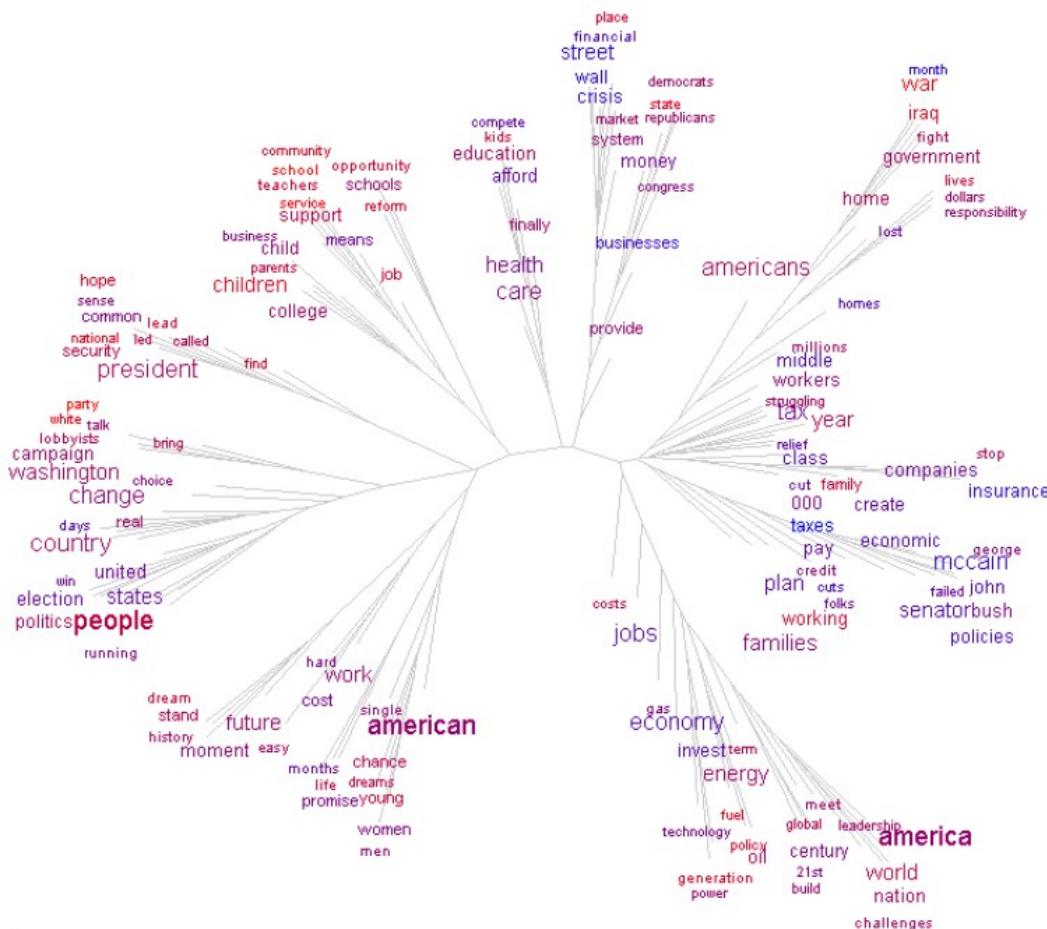
Pour des exemples d'utilisation de la visualisation en node-link, voir Delphine Amstutz et Philippe Gambette: *Utilisation de JADT'10* (10th International Conference on statistical data analysis and its applications).

Arbre construit par l'algorithme de Barthélémy & Luong implémenté par Deepak Srinivas, avec visualisation d3.js



# Temps d'exécution

Limites sur la taille du corpus pour utiliser TreeCloud ?



30 secondes pour la construction du nuage arboré de l'ensemble des discours de campagne de Barack Obama (>300 000 mots)

# Références (*treecloud.org*)

Philippe Gambette, Jean Véronis (2009)

**Visualising a Text with a Tree Cloud, IFCS'09, Studies in Classification, Data Analysis, and Knowledge Organization**  
40, p. 561-570

<http://www.slideshare.net/PhilippeGambette/visualising-a-text-with-a-tree-cloud>

Delphine Amstutz & Philippe Gambette (2010)

**Utilisation de la visualisation en nuage arboré pour l'analyse littéraire**, JADT'10 (Proceedings of the 10th International Conference on statistical analysis of textual data),  
Statistical Analysis of Textual Data, p. 227-238

<http://www.slideshare.net/PhilippeGambette/utilisation-de-la-visualisation-en-nuage-arbor-pour-lanalyse-littraire>

Philippe Gambette, Nuria Gala & Alexis Nasr (2012)

**Longueur de branches et arbres de mots**, *Corpus* 11:129-146

<http://www.slideshare.net/PhilippeGambette/longueur-de-branches-et-arbres-de-mots>

William Martinez & Philippe Gambette (2013)

**L'affaire du Médiator au prisme de la textométrie**, *Texto!* XVIII(4)

<http://www.revue-texto.net/index.php?id=3318>

Philippe Gambette, Hilde Eggemont & Xavier Le Roux (2014)

**Temporal and geographical trends in the type of biodiversity research funded on a competitive basis in European countries**, rapport BiodivERSa

<http://www.biodiversa.org/700/download>

## Co-auteurs des travaux en cours :

- Edna Hernandez : méthodologie d'utilisation de TreeCloud pour les analyses exploratoires
- Claude Martineau : intégration de prétraitements Unitex dans TreeCloud
- Deepak Srinivas : visualisation avec bibliothèque d3.js