

Séminaire INFOLINGU du LIGM
14/05/2012 - Marne-la-Vallée

Nuages arborés et analyse textuelle

Philippe Gambette

LIGM

Université Paris-Est
Marne-la-Vallée



Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

Delphine Amstutz, Philippe Gambette (2010)

Utilisation de la visualisation en nuage arboré pour l'analyse littéraire, JADT'10, *Statistical Analysis of Textual Data*, p. 227-238

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




Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

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>



Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives



Philippe Gambette, Alain Guénoche, Nuria Gala, Alexis Nasr (2012)
Longueur de branches et arbres de mots,
colloque *La cooccurrence, du fait statistique au fait textuel* (Besançon)

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

Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

Nuages de tags

- Construits depuis un ensemble de tags
- Taille de police liée à la fréquence



Ce qui est habituellement cité comme le premier nuage de tags, dans *Microserfs* de D. Coupland, HarperCollins, Toronto, 1995

Nuages de tags/mots améliorés

Ajout d'informations provenant du texte :

- Couleur intense = tag récent dans Amazon
- Groupement sur une même ligne de tags cooccurents
Hassan-Montero & Herrero-Solana, InScit'06
- Optimisation des vides et proximité sémantique
Kaser & Lemire, WWW'07
- “Topigraphy”: placement 2D en fonction de la cooccurrence
Fujimura, Fujimura, Matsubayashi, Yamada & Okuda, WWW'08

Nuages de tags/mots améliorés

Ajout d'informations provenant du texte :

- Couleur intense = tag récent dans Amazon
- Groupement sur une même ligne de tags cooccurents
Hassan-Montero & Herrero-Solana, InScit'06
- Optimisation des vides et proximité sémantique
Kaser & Lemire, WWW'07
- “Topigraphy” : placement 2D en fonction de la cooccurrence
Fujimura, Fujimura, Matsubayashi, Yamada & Okuda, WWW'08

Most Popular Tags (What's this?)

Welcome to the Amazon.com tag cloud. Tags are labels customers can use to classify a product. More frequently used tags are larger and more recently used tags will appear darker.

1080p action adventure american history animation anime art baby best cancelled tv shows
biography blu-ray book business canon children childrens books christian christianity
christmas classic classic movie classic rock classical music comedy comics cookbook cooking
defectivebydesign digital camera disney drama dvd erotica exercise family fantasy fiction fitness fun
games gift idea graphic novel harry potter hd dvd hdtv health hip hop historical fiction historical
romance history horror humor inspirational ipod jazz kids kindle love magic manga
meditation memoir metal movie mp3 player music mystery nonfiction paranormal
romance pc game philosophy photography playstation 3 poetry politics progressive rock psychology
reference religion rock romance rpg science science fiction self-help sex soundtrack
spirituality suspense thriller toys travel tv series vampire vampire romance video
games wii women world war ii xbox 360

Nuages de tags/mots améliorés

Ajout d'informations provenant du texte :

- Couleur intense = tag récent dans Amazon
- Groupement sur une même ligne de tags cooccurents
Hassan-Montero & Herrero-Solana, InScit'06
- Optimisation des vides et proximité sémantique
Kaser & Lemire, WWW'07
- “Topigraphy”: placement 2D en fonction de la cooccurrence
Fujimura, Fujimura, Matsubayashi, Yamada & Okuda, WWW'08



Nuages de tags/mots améliorés

Ajout d'informations provenant du texte :

- Couleur intense = tag récent dans Amazon
- Groupement sur une même ligne de tags cooccurents

Hassan-Montero & Herrero-Solana, InScit'06

- Optimisation des vides et proximité sémantique

Kaser & Lemire, WWW'07

- “Topigraphy”: placement 2D en fonction de la cooccurrence

Fujimura, Fujimura, Matsubayashi, Yamada & Okuda, WWW'08



Nuages de tags/mots améliorés

Ajout d'informations provenant du texte :

- Couleur intense = tag récent dans Amazon
- Groupement sur une même ligne de tags cooccurrents

Hassan-Montero & Herrero-Solana, InScit'06

- Optimisation des vides et proximité sémantique

Kaser & Lemire, WWW'07

- “Topigraphy”: placement 2D en fonction de la cooccurrence

Fujimura, Fujimura, Matsubayashi, Yamada & Okuda, WWW'08



Extraire l'information sémantique d'un texte

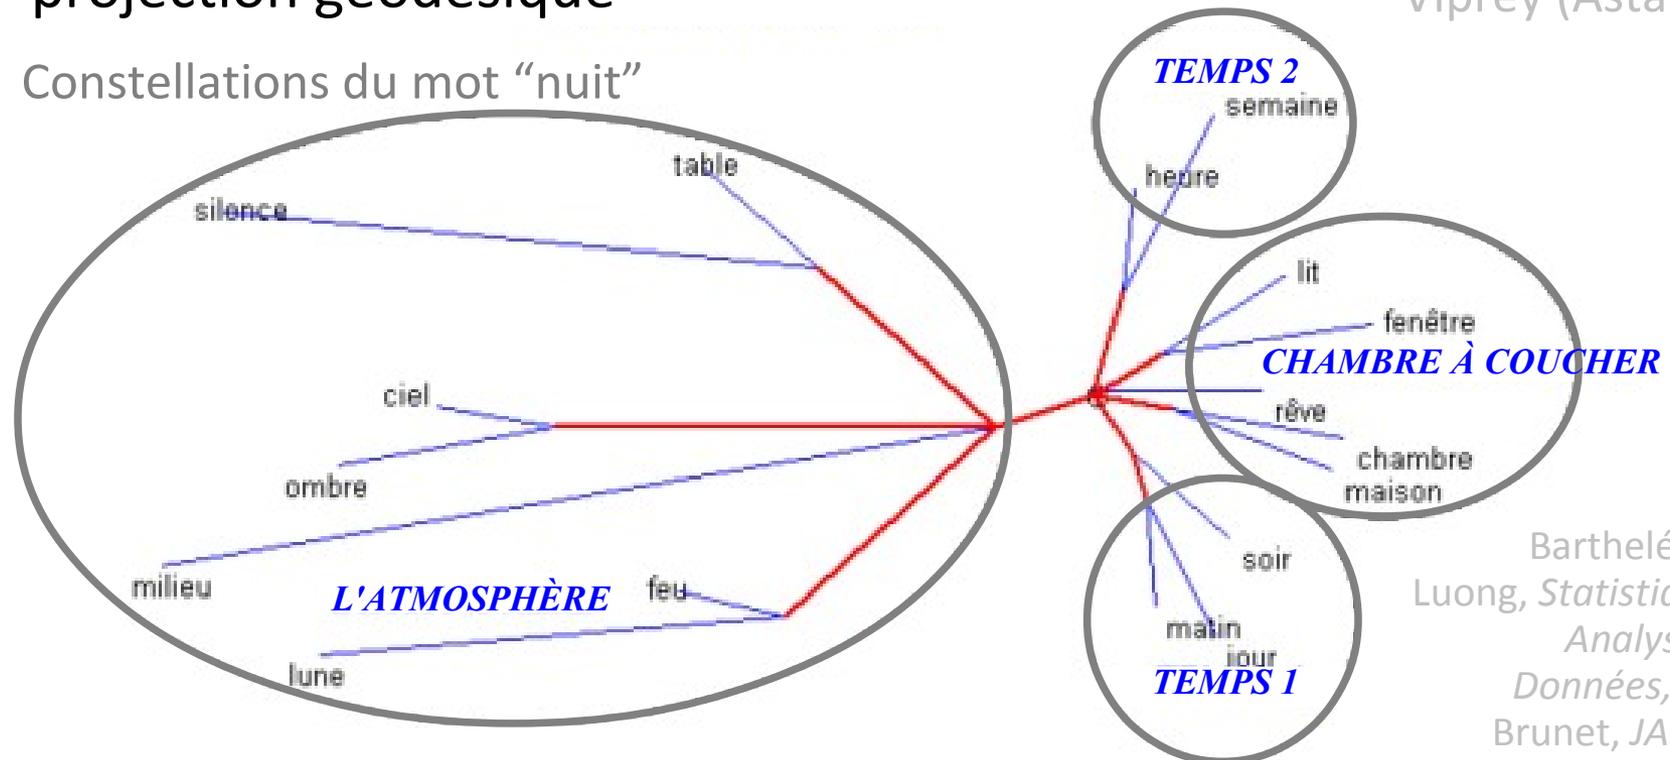
- analyse arborée Brunet (Hyperbase)
- graphe de cooccurrence Brunet (Hyperbase)
- graphe sémantique Grimmer (Wordmapper)
- lexicogramme récursif Martinez (Coocs)
- désambiguïisation lexicale Véronis (Hyperlex)
- réseau Phrasenet Viegas et al. (IBM Many Eyes)
- projection géodésique Viprey (Astartex)

Extraire l'information sémantique d'un texte

- analyse arborée
- graphe de cooccurrence
- graphe sémantique
- lexicogramme récursif
- désambiguïisation lexicale
- réseau Phrasenet
- projection géodésique

Brunet (Hyperbase)
Brunet (Hyperbase)
Grimmer (Wordmapper)
Martinez (Coocs)
Véronis (Hyperlex)
Viegas et al. (IBM Many Eyes)
Viprey (Astartex)

Constellations du mot "nuit"



Barthelémy &
Luong, *Statistique et
Analyse des
Données*, 1986
Brunet, *JADT'08*

Extraire l'information sémantique d'un texte

- analyse arborée
- graphe de cooccurrence
- graphe sémantique
- lexicogramme récursif
- désambiguïstation lexicale
- réseau Phrasenet
- projection géodésique

Brunet (Hyperbase)

Brunet (Hyperbase)

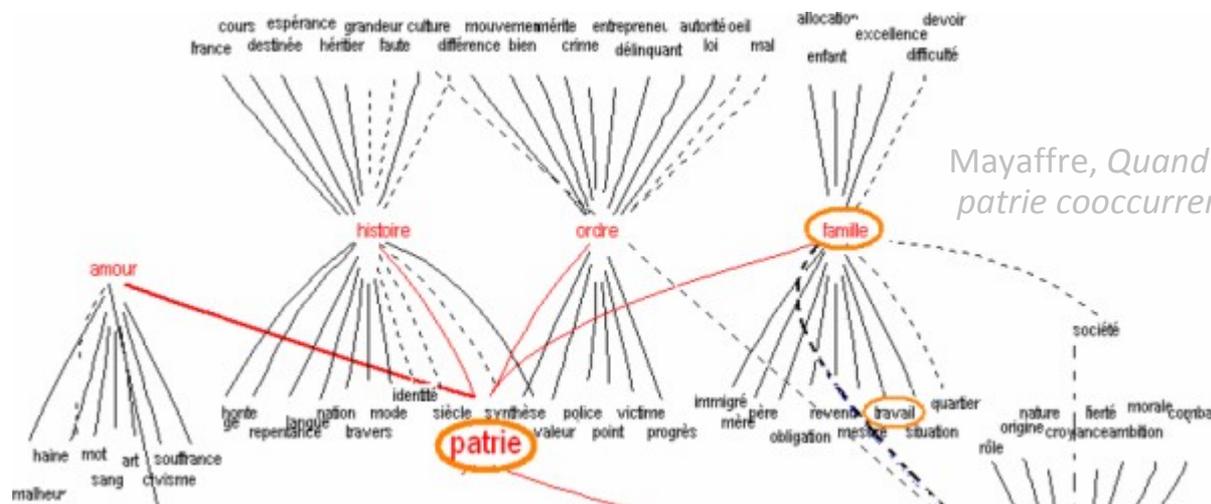
Grimmer (Wordmapper)

Martinez (Coocs)

Véronis (Hyperlex)

Viegas et al. (IBM Many Eyes)

Viprey (Astartex)



Mayaffre, *Quand travail, famille, et patrie cooccurrent dans le discours de Nicolas Sarkozy*, JADT'08

Extraire l'information sémantique d'un texte

- analyse arborée
- graphe de cooccurrence
- graphe sémantique
- lexicogramme récursif
- désambiguïstation lexicale
- réseau Phrasenet
- projection géodésique

Brunet (Hyperbase)

Brunet (Hyperbase)

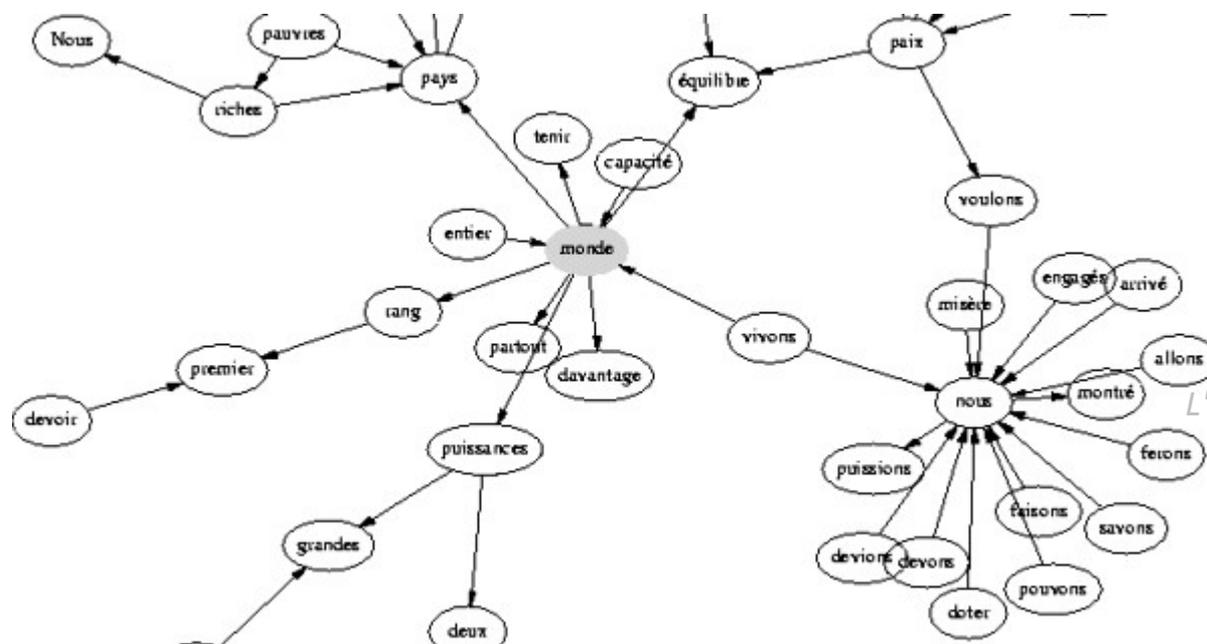
Grimmer (Wordmapper)

Martinez (Coocs)

Véronis (Hyperlex)

Viegas et al. (IBM Many Eyes)

Viprey (Astartex)



Leblanc, Martinez

*L'analyse contrastive des réseaux
de cooccurrence
JADT 2006.*

Extraire l'information sémantique d'un texte

- analyse arborée
- graphe de cooccurrence
- graphe sémantique
- lexicogramme récursif
- désambiguïisation lexicale
- réseau Phrasenet
- projection géodésique

Brunet (Hyperbase)

Brunet (Hyperbase)

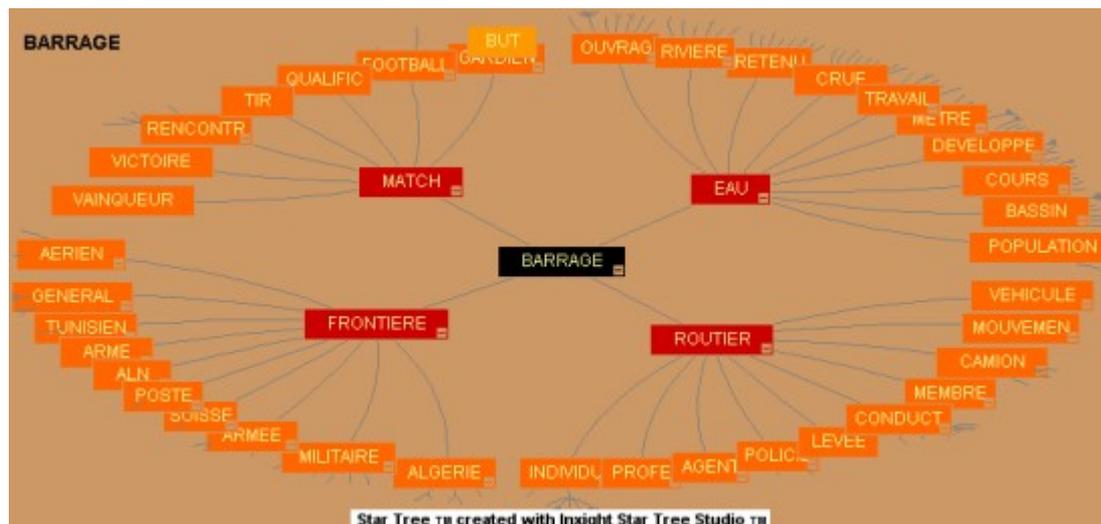
Grimmer (Wordmapper)

Martinez (Coocs)

Véronis (Hyperlex)

Viegas et al. (IBM Many Eyes)

Viprey (Astartex)



Désambiguïisation du mot
"barrage".

Véronis, *HyperLex:
Lexical Cartography for
Information Retrieval*, 2004

Plan

- Nuages de mots et nuages arborés
- **Caractéristiques du nuage arboré**
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

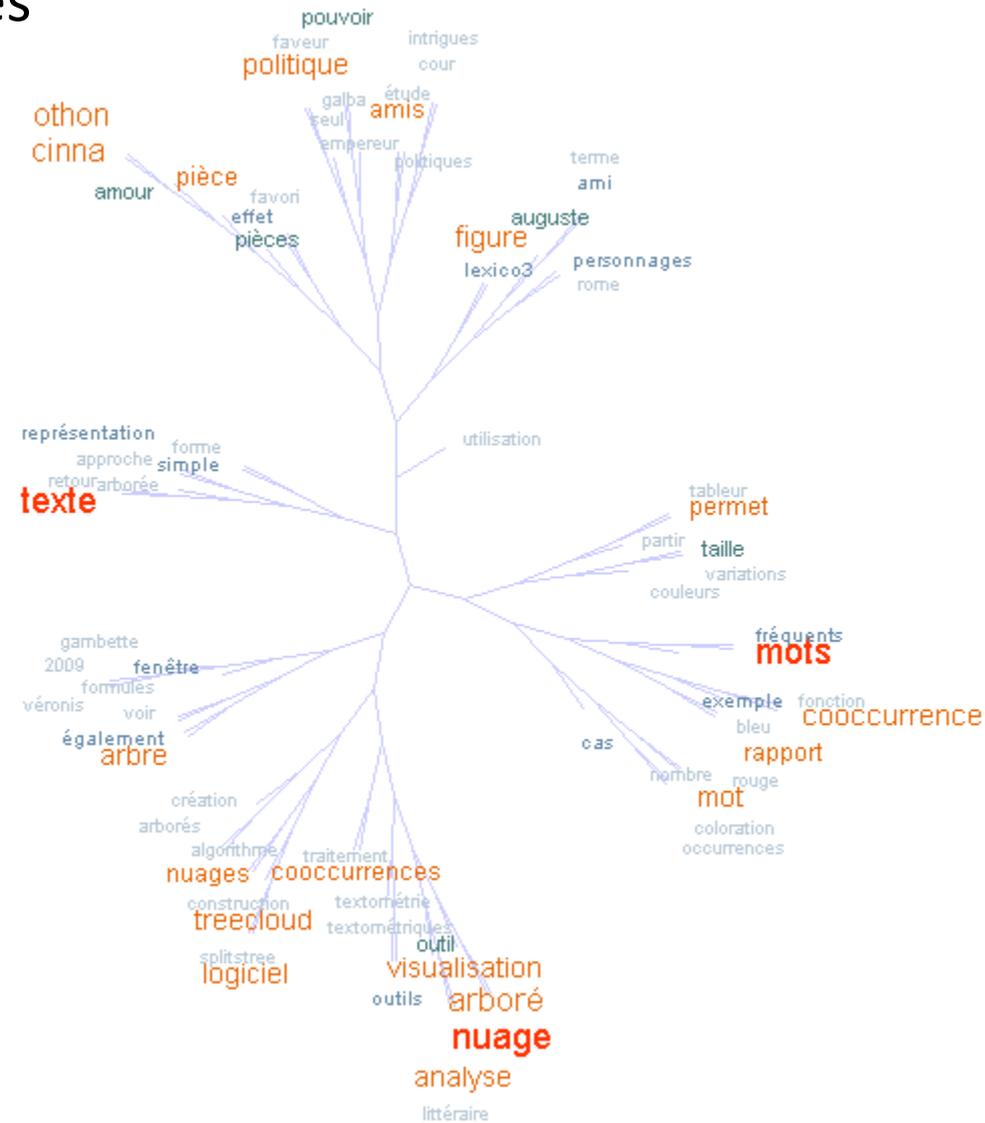
Des couleurs pour guider la lecture

- coloration selon les fréquences
- coloration chronologique
- coloration de la dispersion
- coloration ciblée sur un mot
- coloration grammaticale

Des couleurs pour guider la lecture

- coloration selon les fréquences
- coloration chronologique
- coloration de la dispersion
- coloration ciblée sur un mot
- coloration grammaticale

Nuage arboré des mots apparaissant 5 fois ou plus dans l'article d'Amstutz & Gambette, JADT 2010, distance Liddell, fenêtre de 20 mots, coloration Yahoo



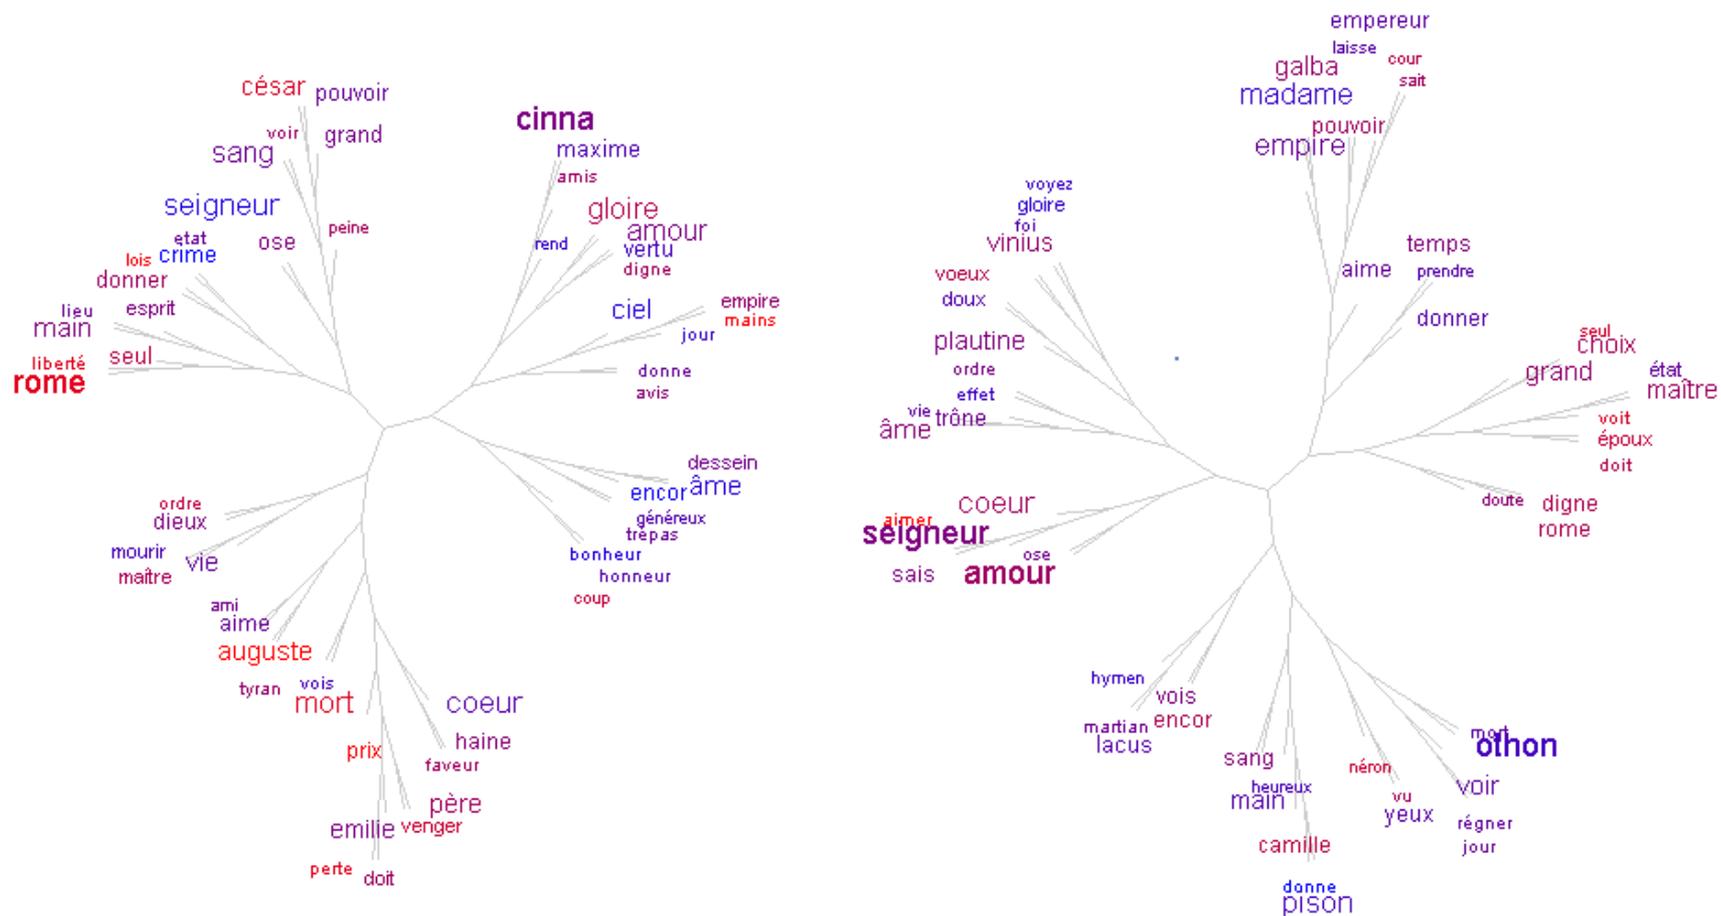
Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- **Utilisations du nuage arboré**
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

Utilisations du nuage arboré

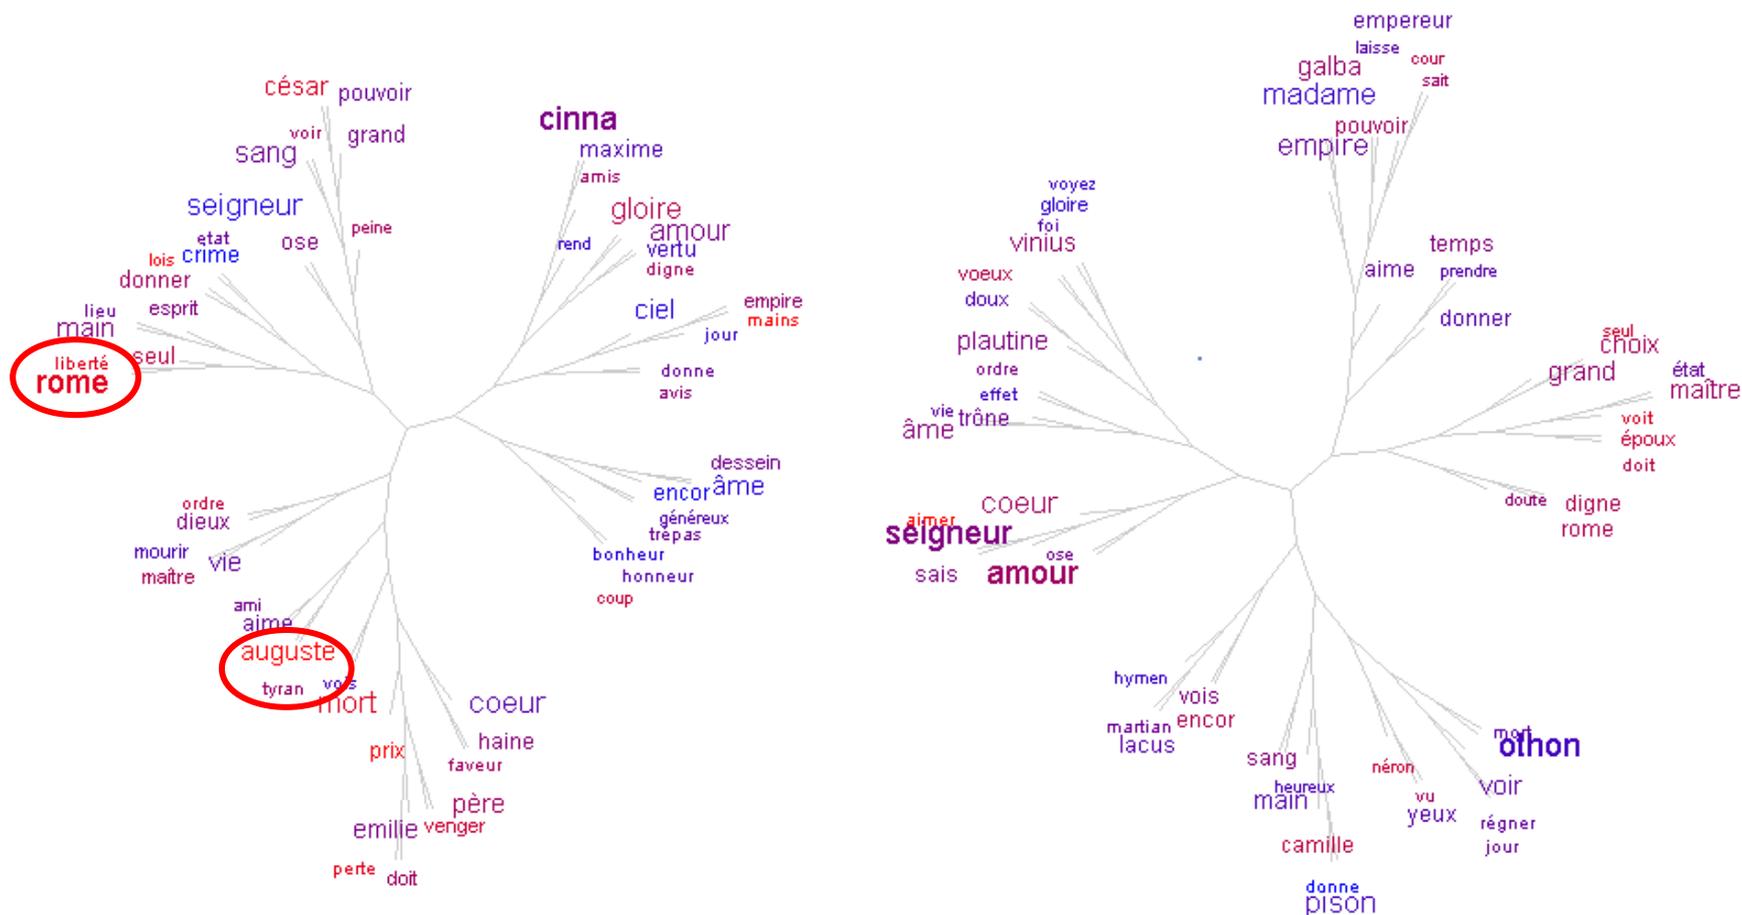
- **Résumé visuel** des thématiques d'un texte
- **Clarification** de rapports ou discours
- Analyse des **réponses aux questions ouvertes ?**
- En **analyse littéraire** :
 - susciter, formaliser et étayer des **hypothèses de travail**
 - **comparer des textes** selon leur représentation arborée
 - hiérarchiser l'utilisation d'**autres outils textométriques**
 - représenter les **résultats de l'analyse**

Illustration sur *Cinna* et *Othon*



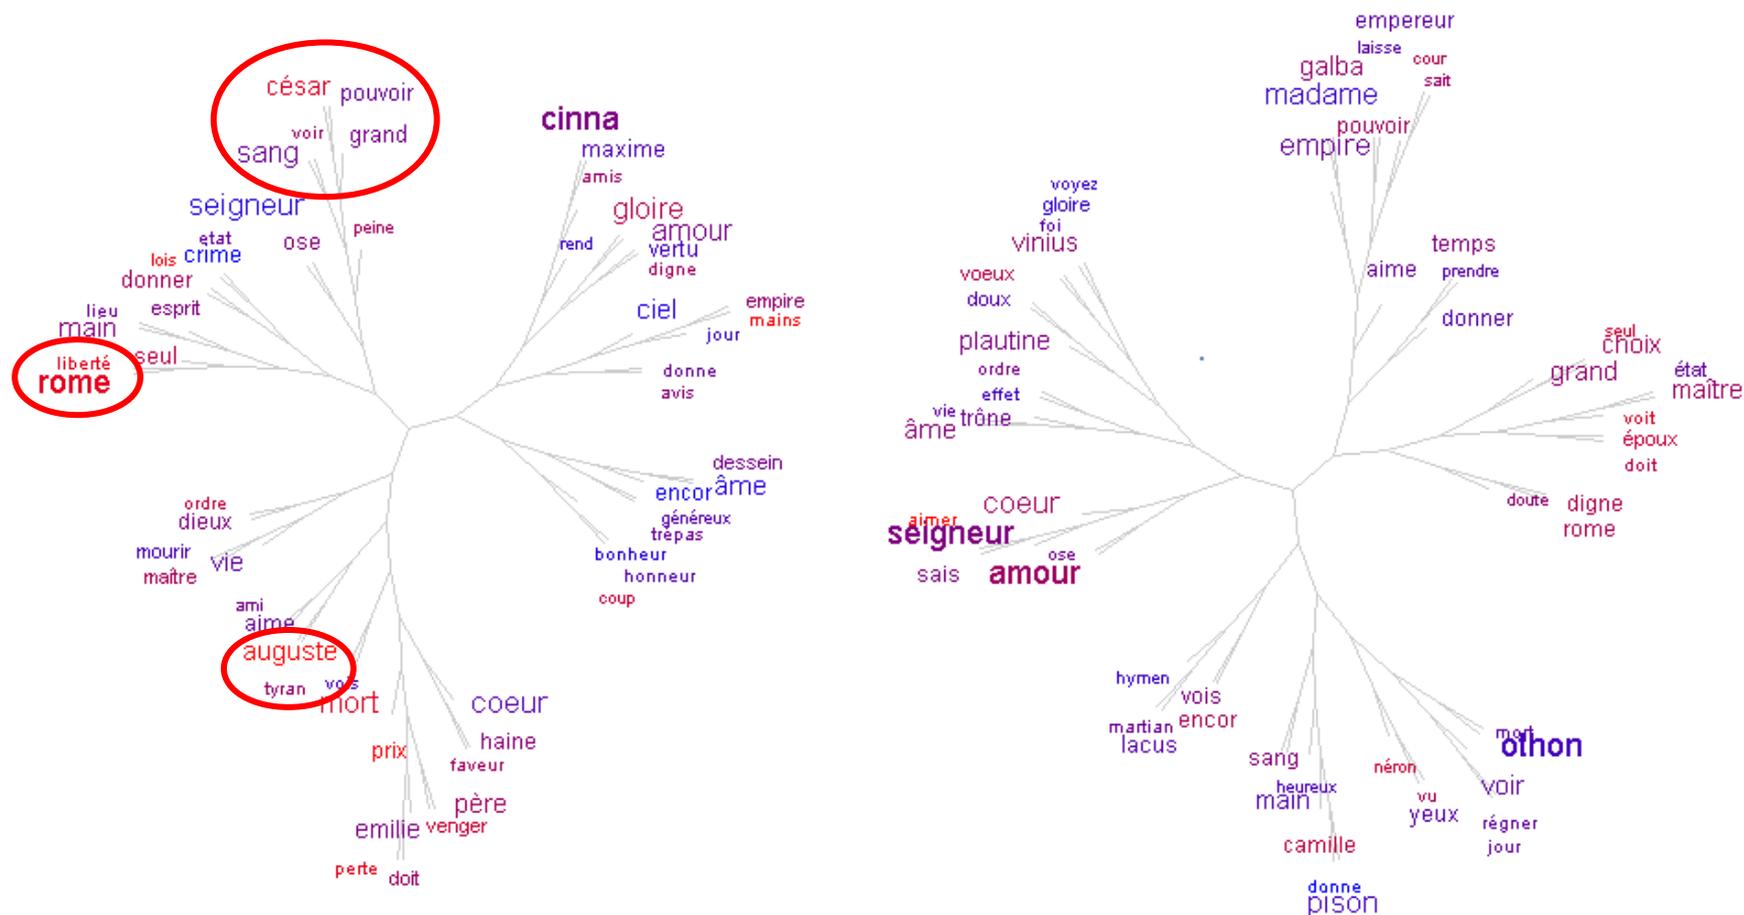
Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Illustration sur *Cinna* et *Othon*



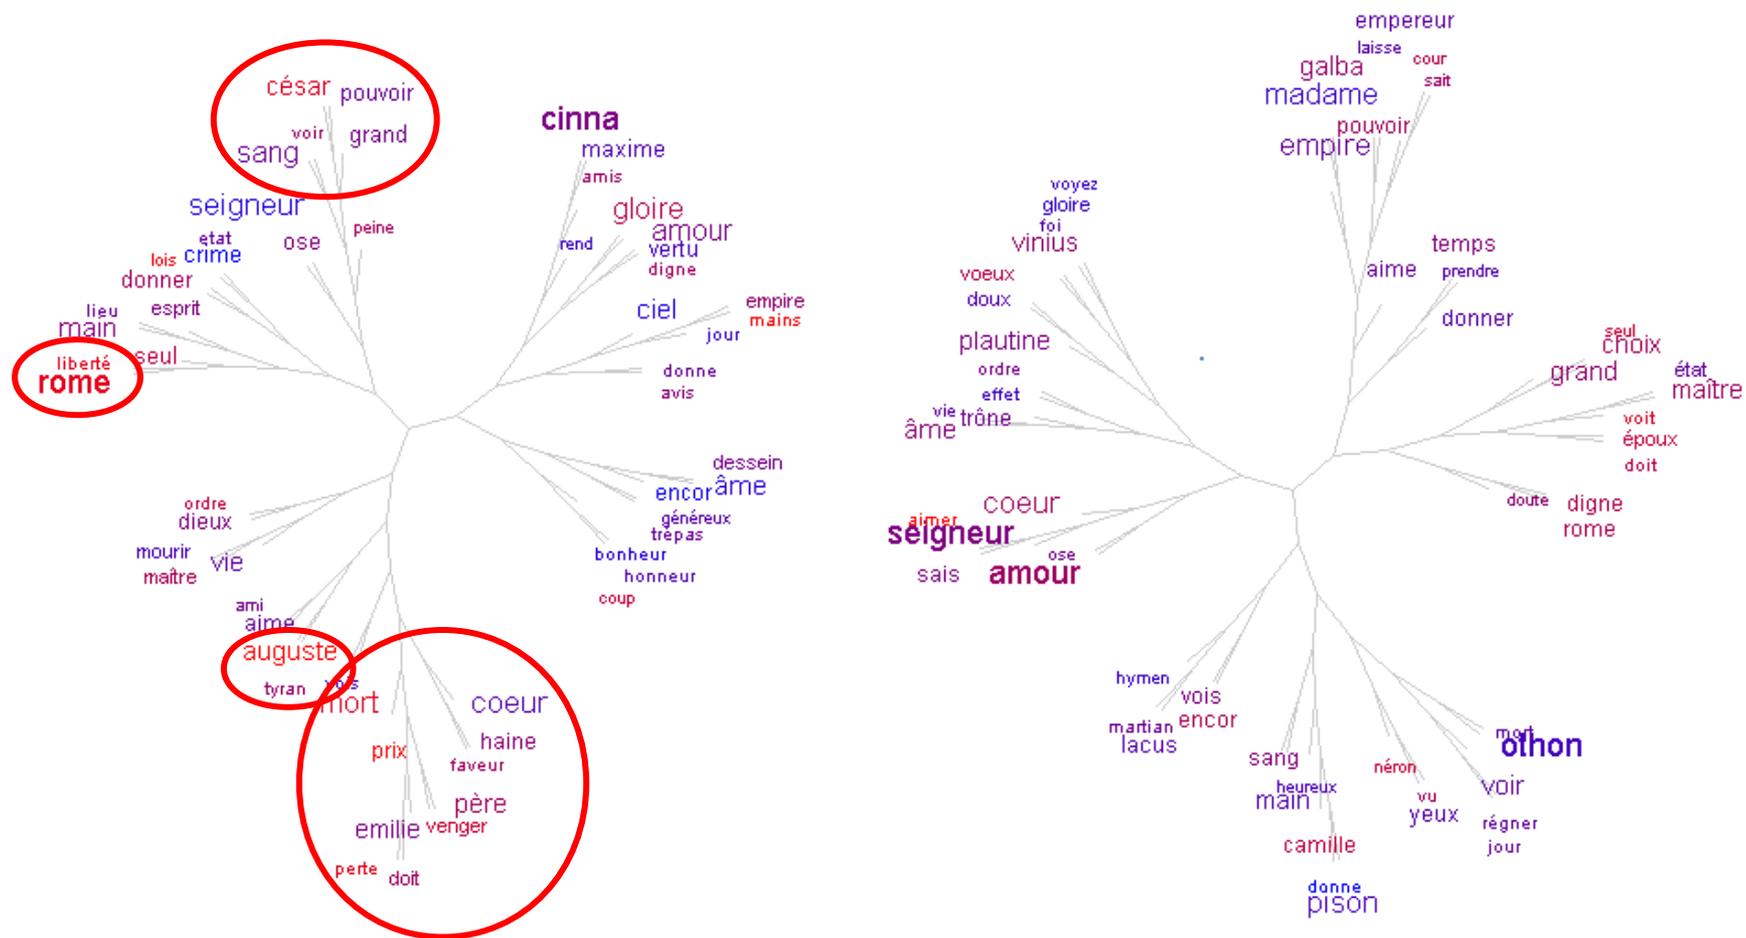
Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Illustration sur *Cinna* et *Othon*



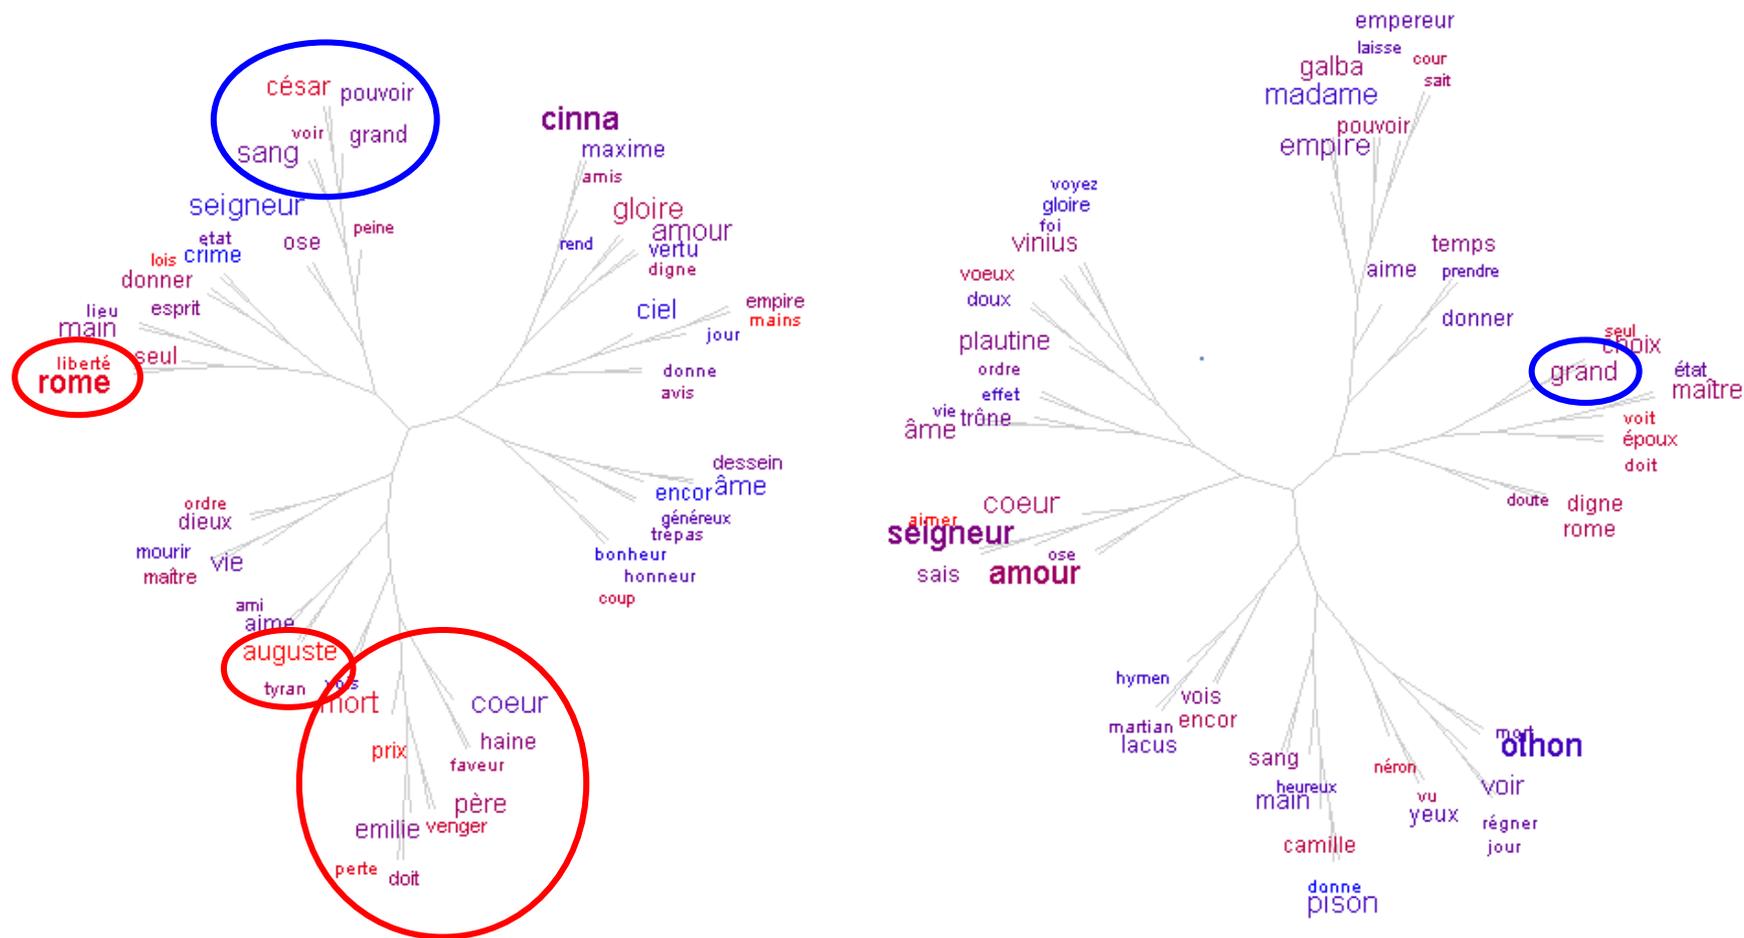
Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Illustration sur *Cinna* et *Othon*



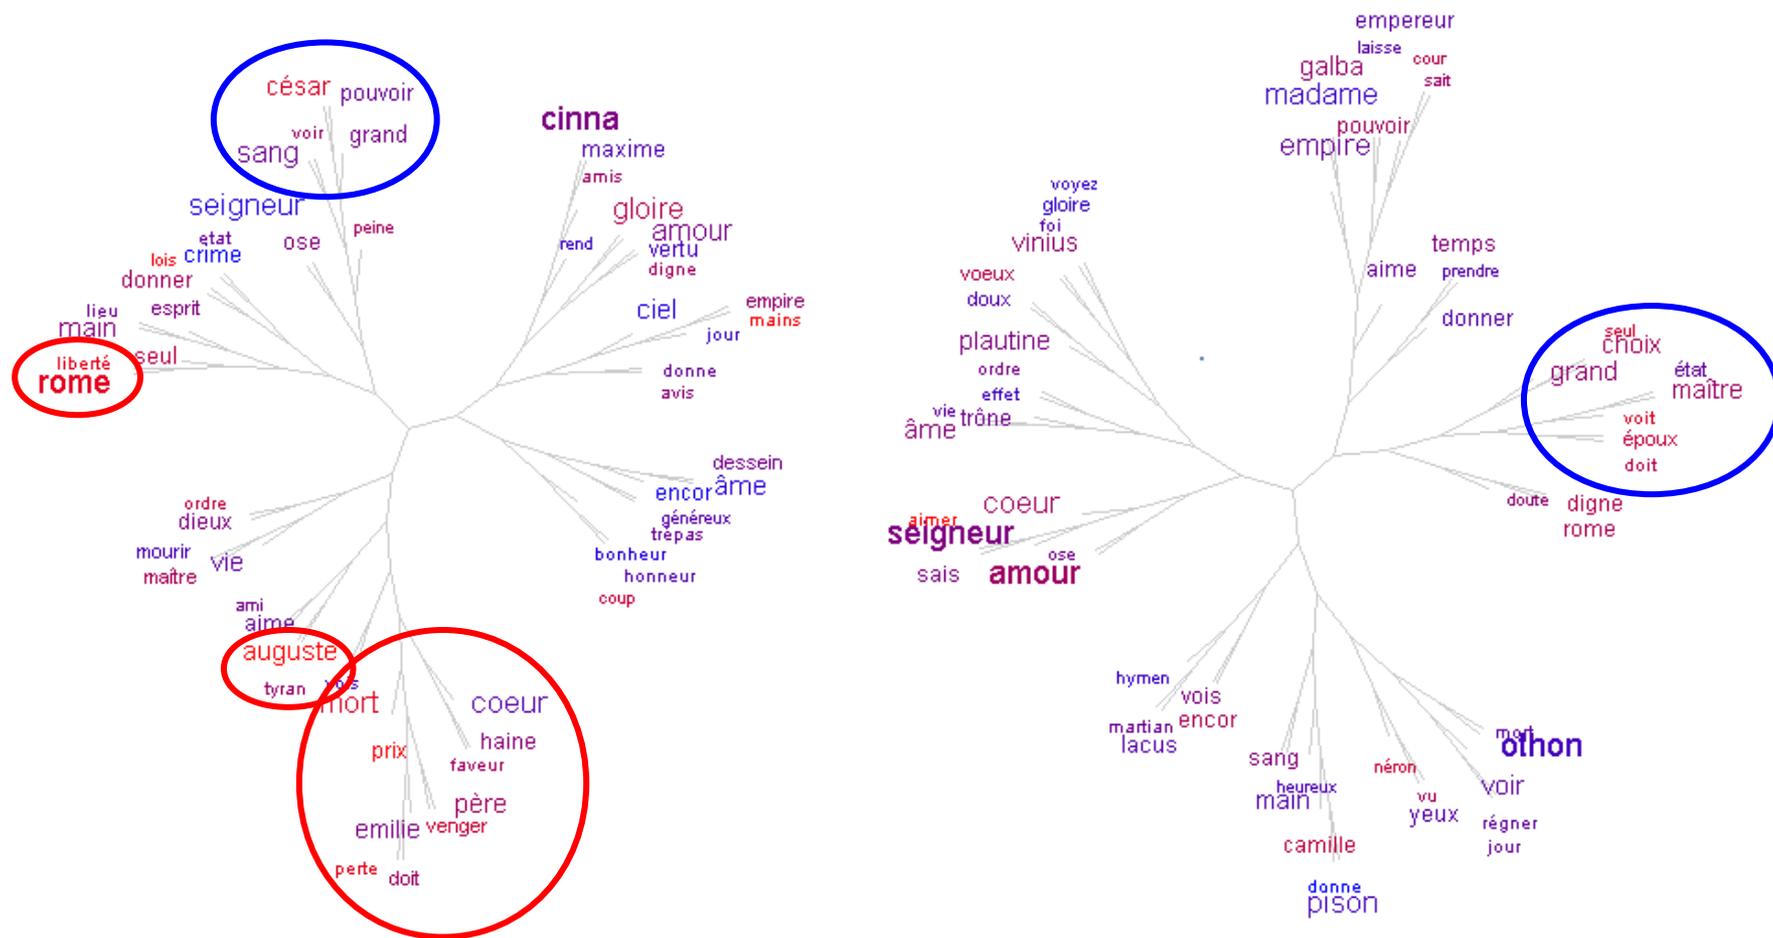
Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Illustration sur *Cinna* et *Othon*



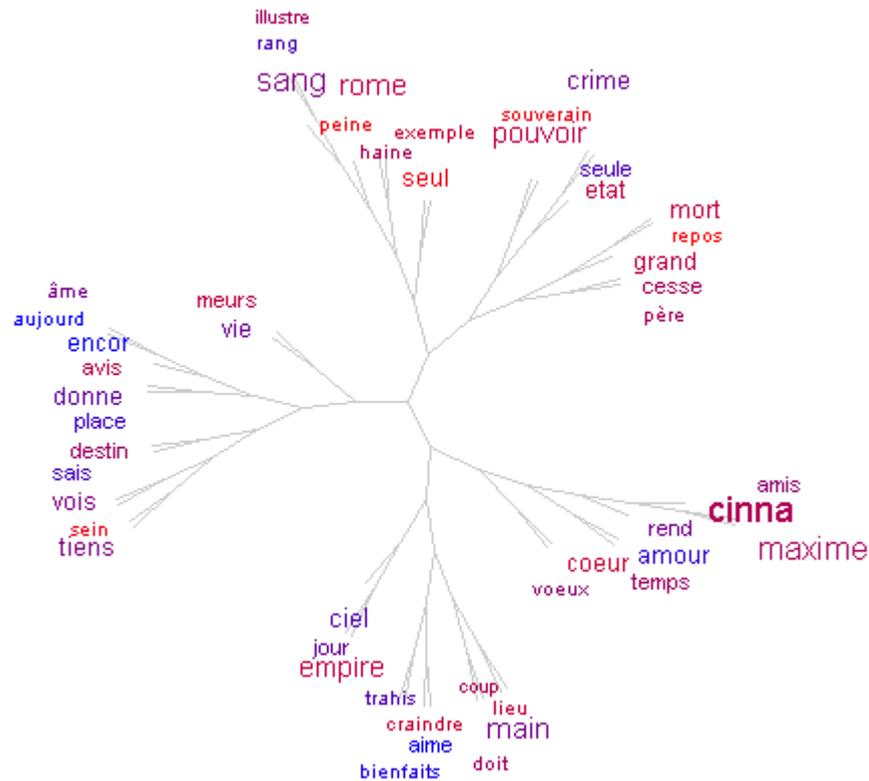
Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Illustration sur *Cinna* et *Othon*



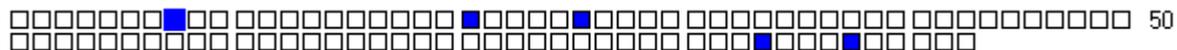
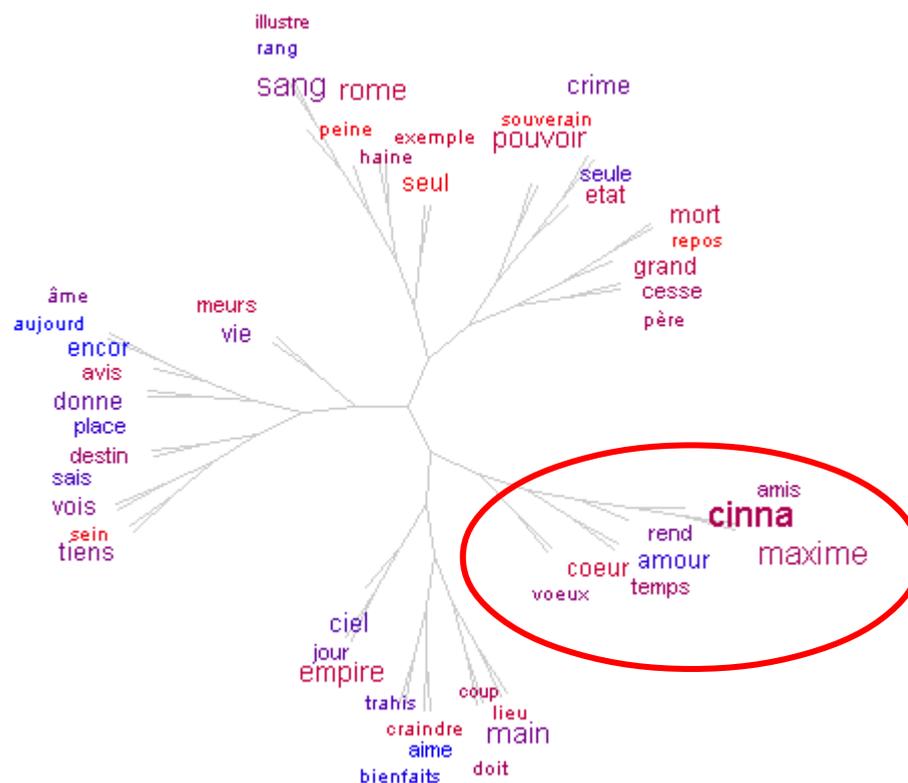
Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Illustration sur *Cinna* et *Othon*



Nuage arboré des 50 mots les plus fréquents des paroles d'Auguste dans Cinna

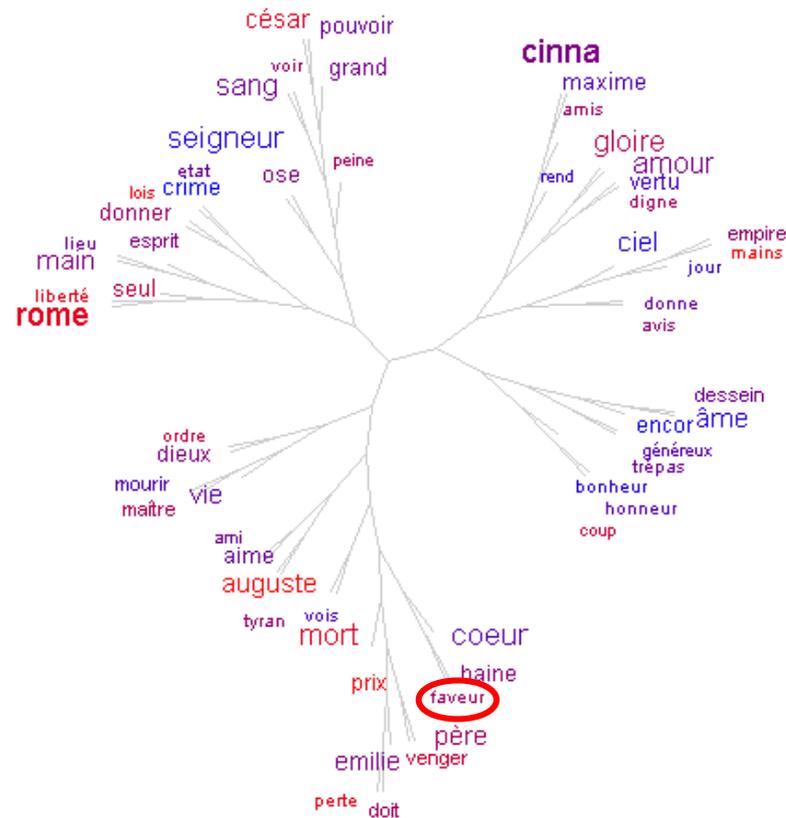
Illustration sur *Cinna* et *Othon*



Carte des sections Lexico3 et contextes de « amis » dans les paroles d'Auguste dans *Cinna*.

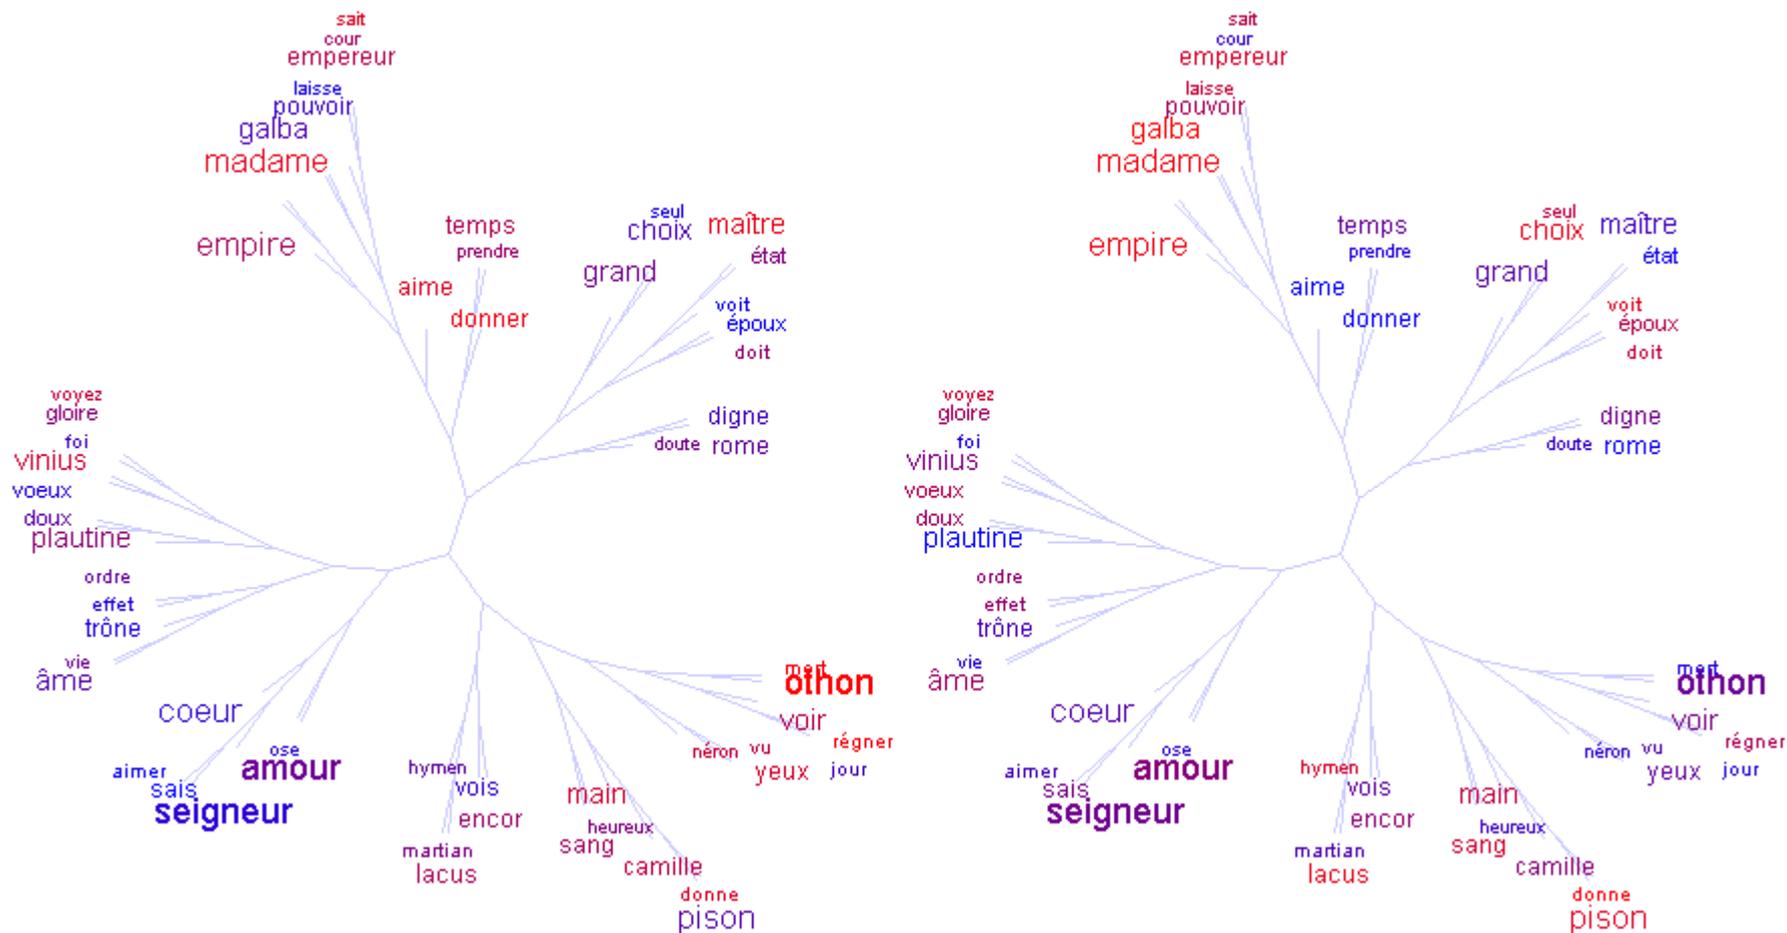
1. Voilà, mes chers **amis**, ce qui me met en peine.
2. Quoi ! mes plus chers **amis** ! quoi ! Cinna ! quoi ! Maxime !
3. Reprenez le pouvoir que vous m'avez commis, Si donnant des sujets il ôte les **amis**
4. Soyons **amis**, Cinna, c'est moi qui t'en convie
5. Il nous a trahis tous ; mais ce qu'il a commis Vous conserve innocents, et me rend mes **amis**.

Illustration sur *Cinna* et *Othon*



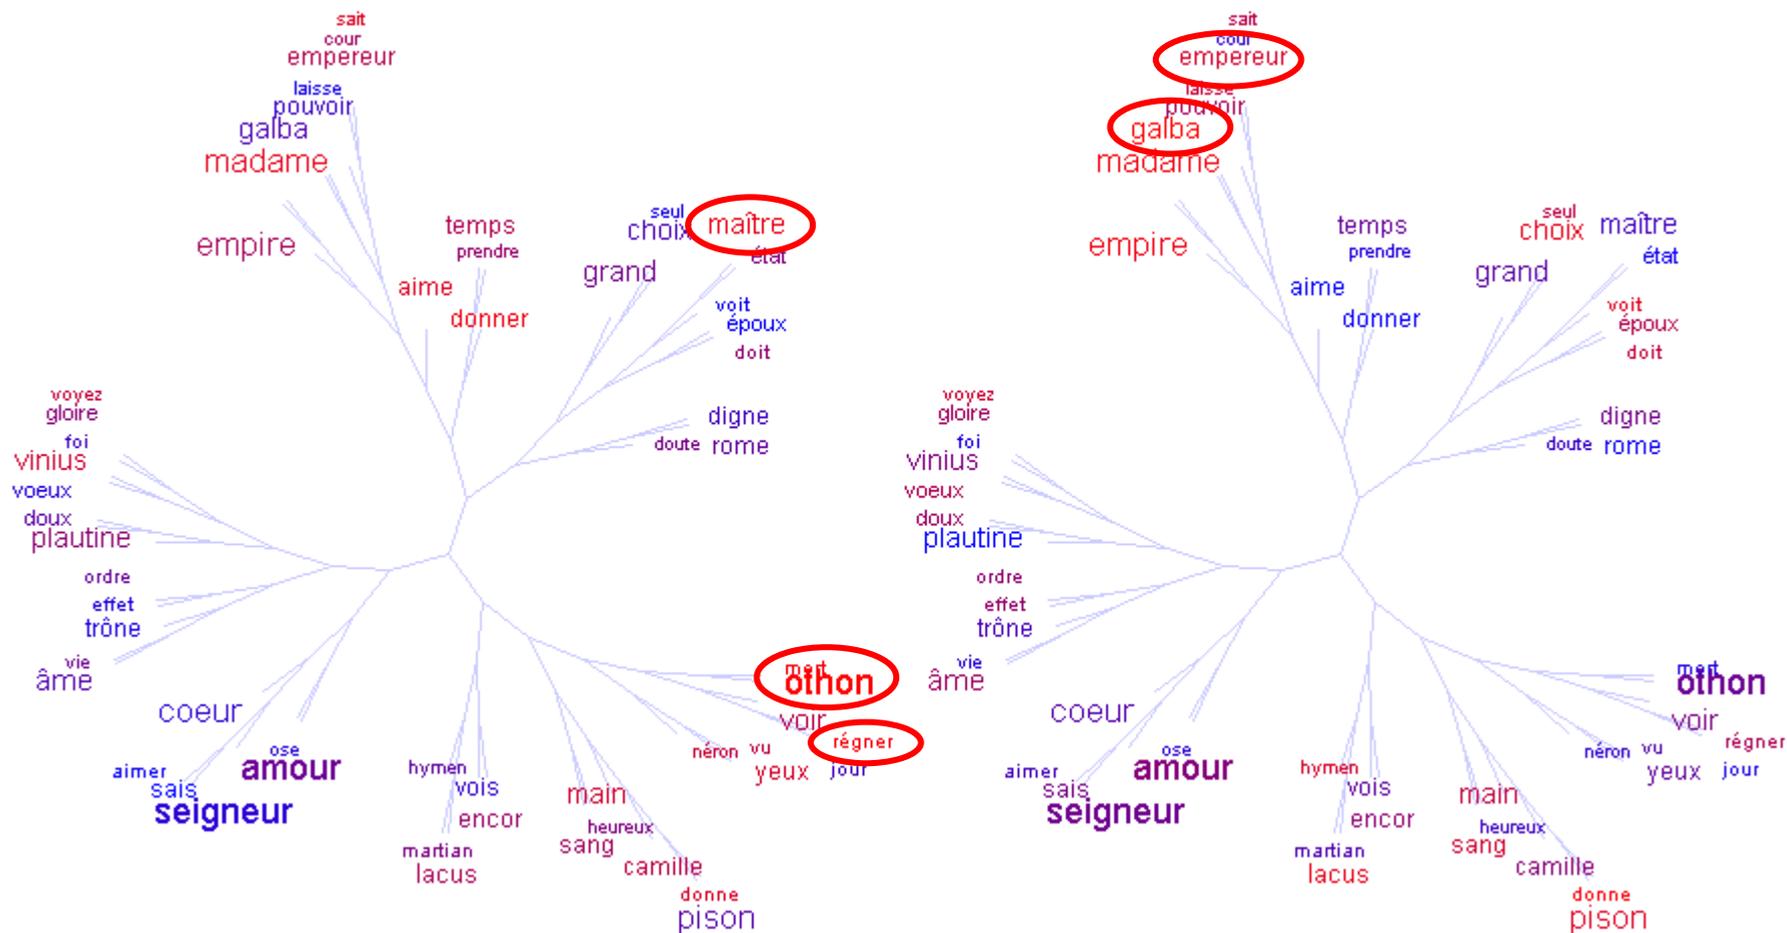
Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Illustration sur *Cinna* et *Othon*



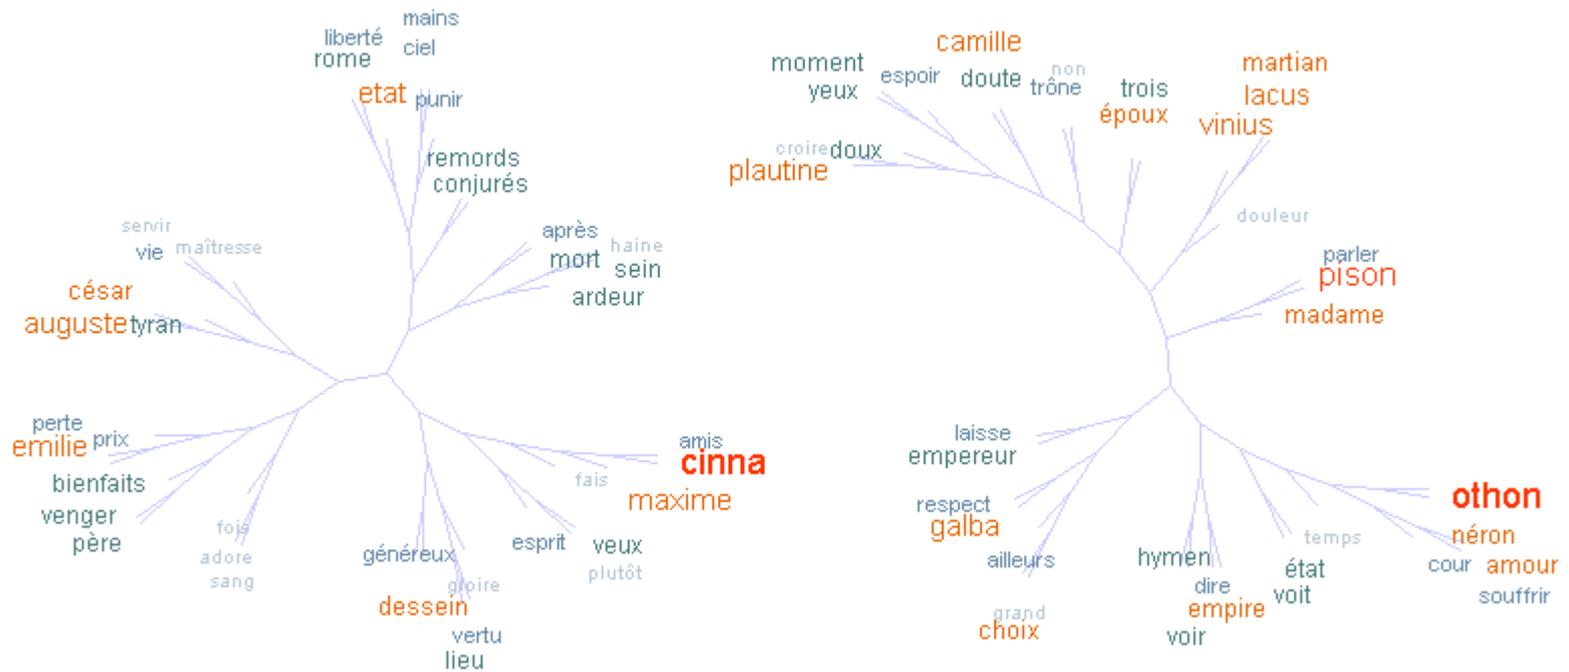
Nuage arboré des 30 mots les plus fréquents de la pièce Othon, coloré à gauche par rapport aux cooccurrences avec « Othon », à droite par rapport à celles avec « Galba »

Illustration sur *Cinna* et *Othon*



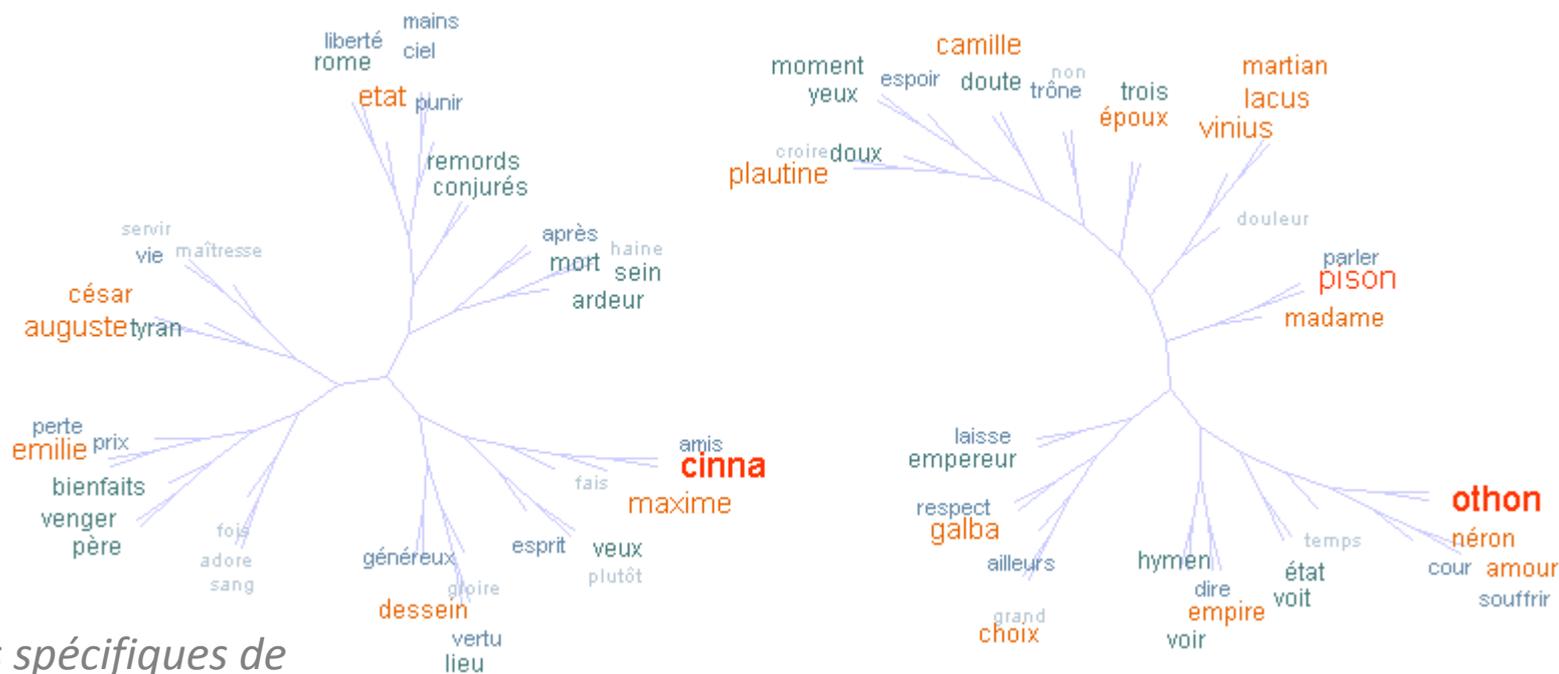
Nuage arboré des 30 mots les plus fréquents de la pièce *Othon*, coloré à gauche par rapport aux cooccurrences avec « Othon », à droite par rapport à celles avec « Galba »

Illustration sur *Cinna* et *Othon*



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

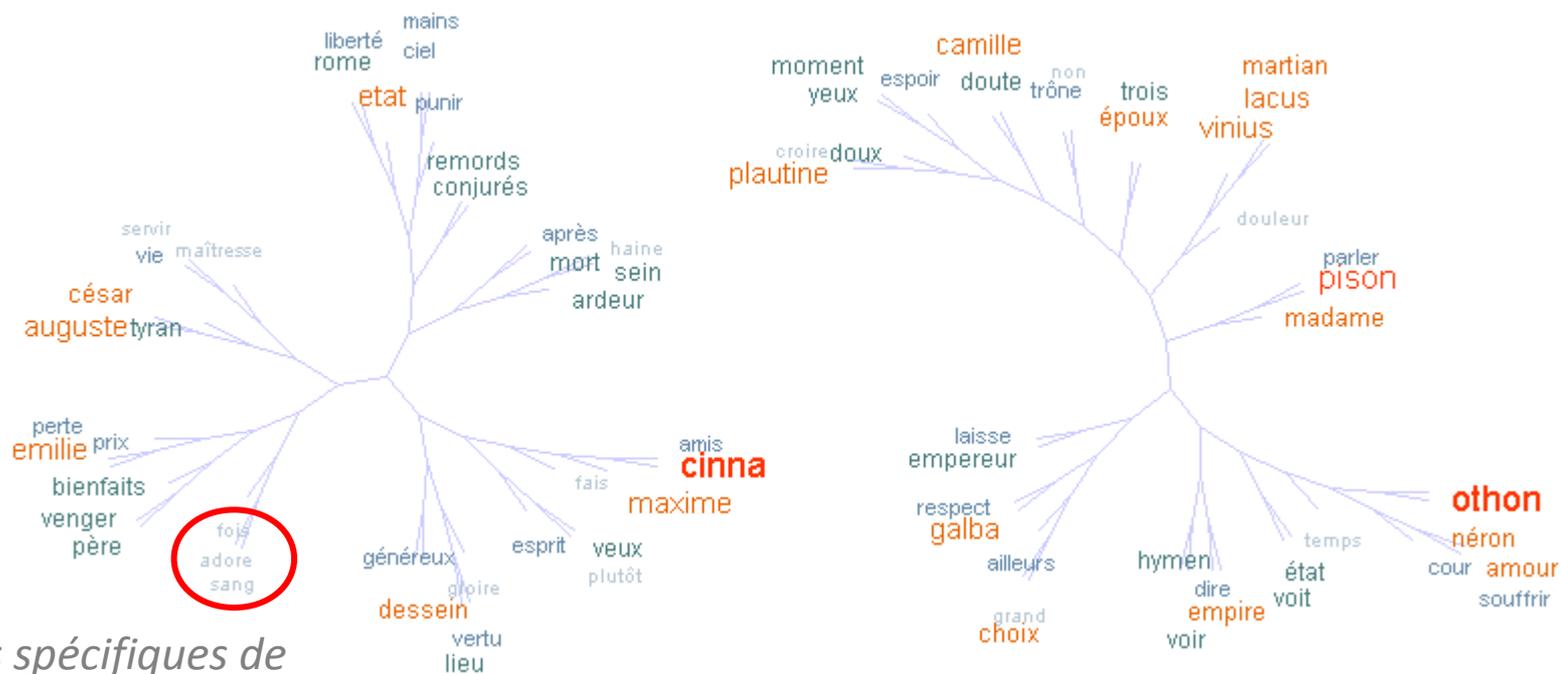
Illustration sur *Cinna* et *Othon*



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

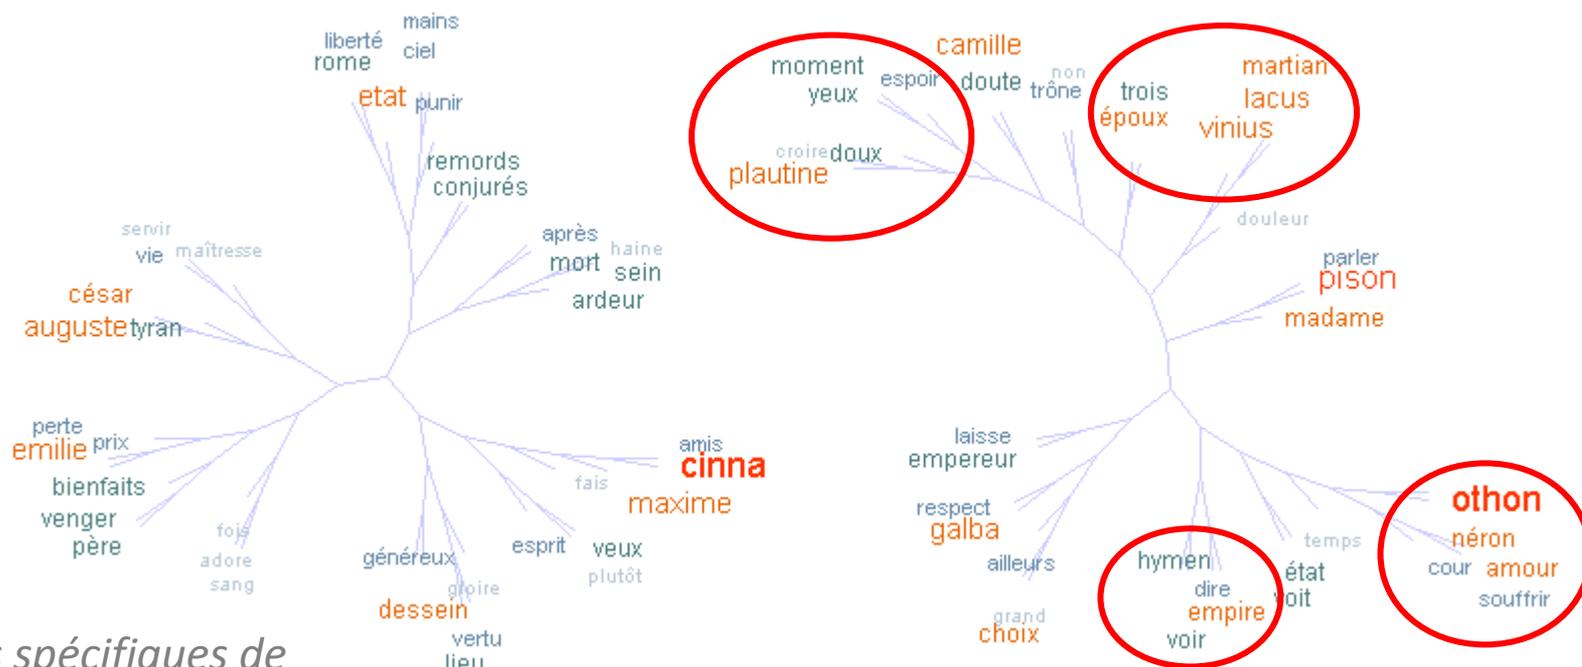
Illustration sur *Cinna* et *Othon*



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

Illustration sur *Cinna* et *Othon*



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

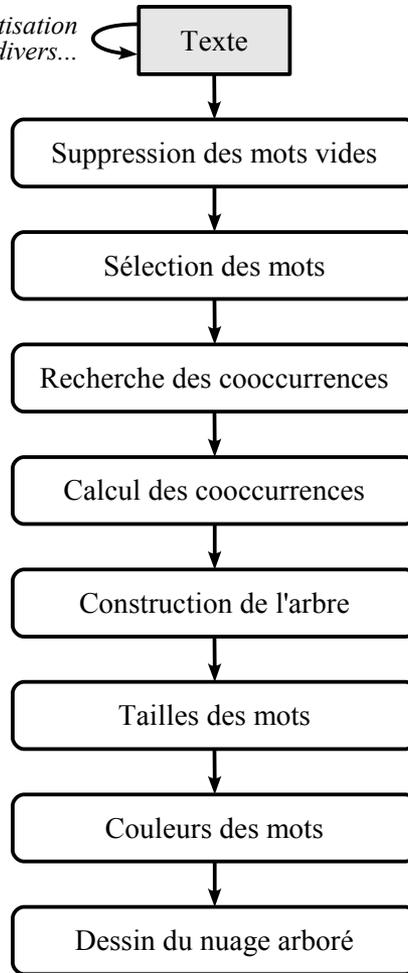
Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- **Construction d'un nuage arboré**
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

Processus de construction

Import/export

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



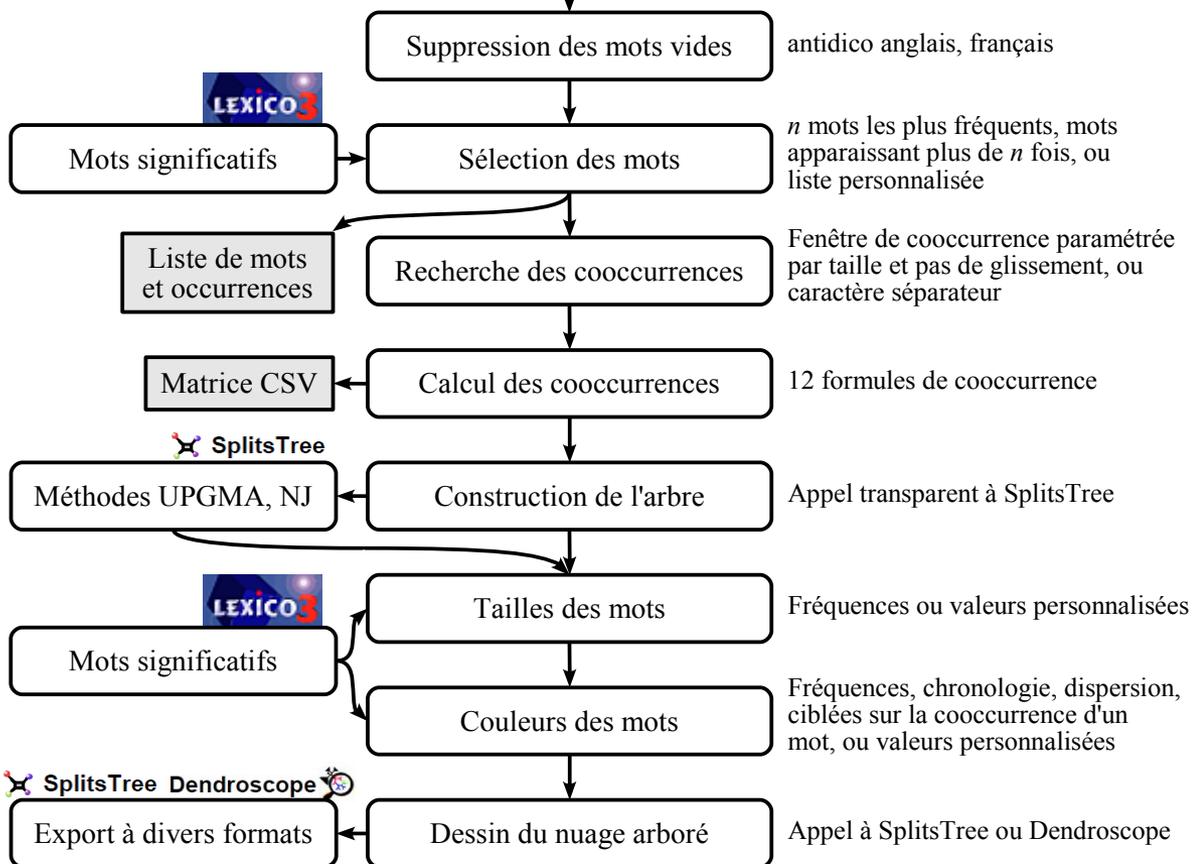
Processus de construction

Import/export

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

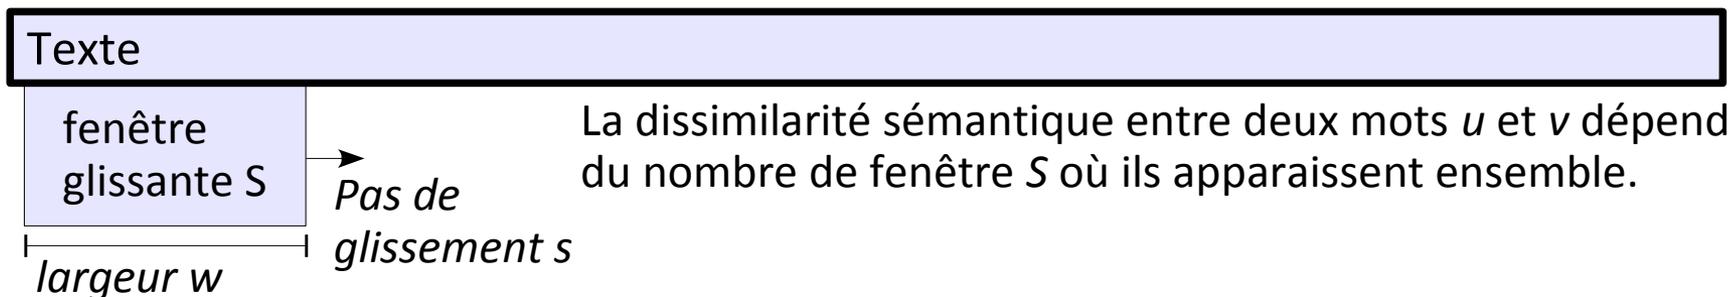
Texte

Proposé dans TreeCloud



Calcul des scores de cooccurrence

Calcul de la matrice de distance entre mots



matrices de cooccurrence

$O_{11}, O_{12}, O_{21}, O_{22}$

Pour 2 mots u et v	$v \in S$	$v \notin S$
$u \in S$	O_{11}	O_{12}
$u \notin S$	O_{21}	O_{22}



matrice de dissimilarité sémantique

chi squared, mutual information, liddel, dice, jaccard, gmean, hyperlex, minimum sensitivity, odds ratio, zscore, log likelihood, poisson-stirling...

Calcul des distances de cooccurrence

Les formules statistiques fournissent un score de similarité.

Comment obtenir des dissimilarités, dans l'intervalle $[0,1]$?

Calcul des distances de cooccurrence

Les formules statistiques fournissent un score de similarité.

Comment obtenir des dissimilarités, dans l'intervalle $[0,1]$?

$$\text{dissimilarité} = 1 - \text{similarité normalisée sur } [0,1]$$

Normalisation des scores de similarité sur $[0,1]$:

- normalisation linéaire pour les matrices positives
- normalisation affines pour les matrices contenant des valeurs négatives, afin d'obtenir des distances dans l'intervalle $[a,1]$ ($a=0.1$)

Construction de l'arbre

Plusieurs méthodes pour construire un arbre à partir d'une matrice de distances (classification hiérarchique) :

- Neighbor-Joining

Saitou & Nei, 1987



- Variantes d'Addtree

Barthelemy & Luong, 1987

- Heuristique des quadruplets

Cilibrasi & Vitanyi, 2007

Décoration de l'arbre

Tailles des mots :

- calculées directement à partir des **fréquences**
(avec un log!)
- calculées à partir des **rangs des fréquences**
(distribution exponentielle)
- **score de spécificité** par rapport à un corpus de référence
(TF-IDF, écart réduit...)

Dessin de l'arbre

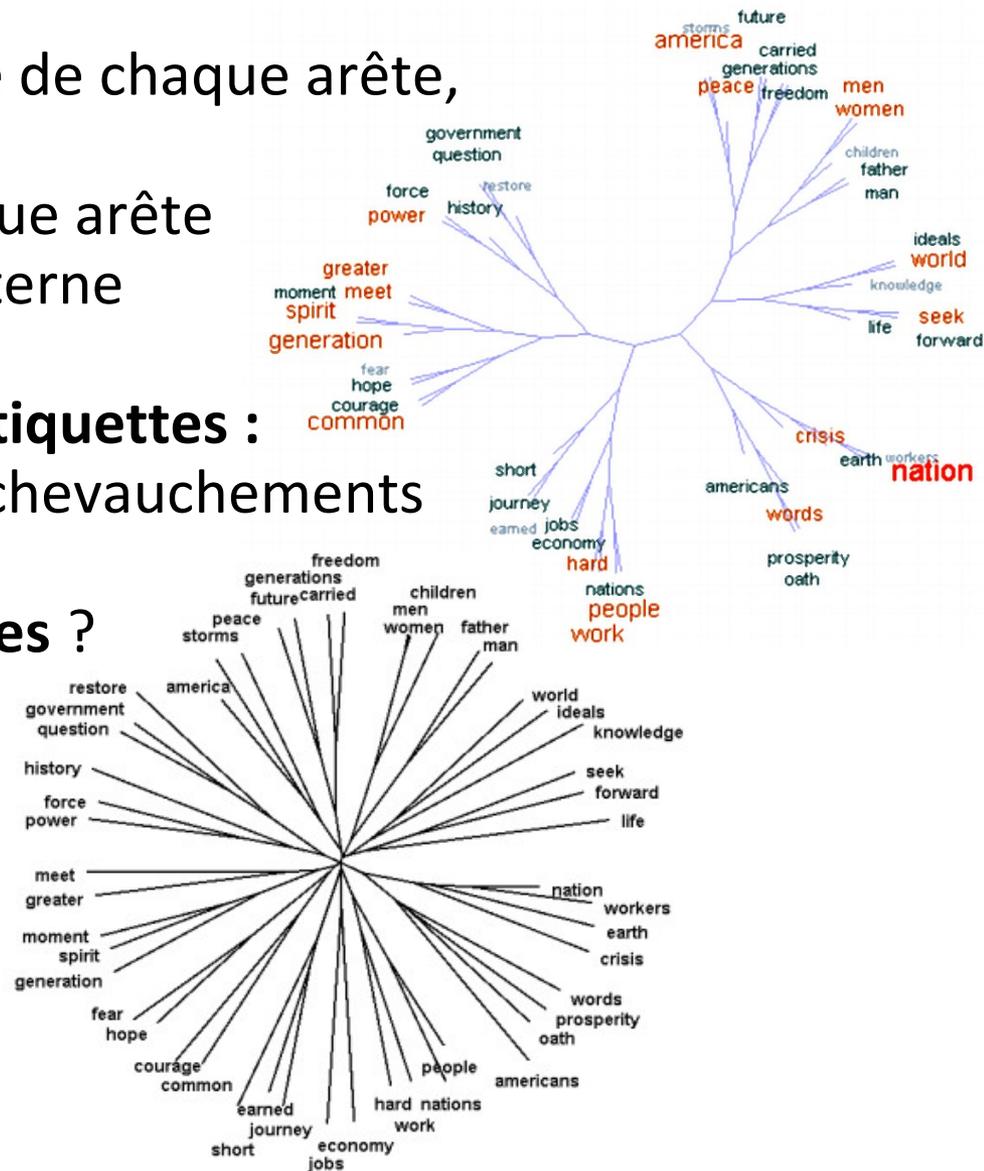
Algorithme "equal angle" :

- montant pour calculer l'angle de chaque arête, en partant des feuilles
- descendant pour placer chaque arête en partant d'un sommet interne

Placement automatique des étiquettes :

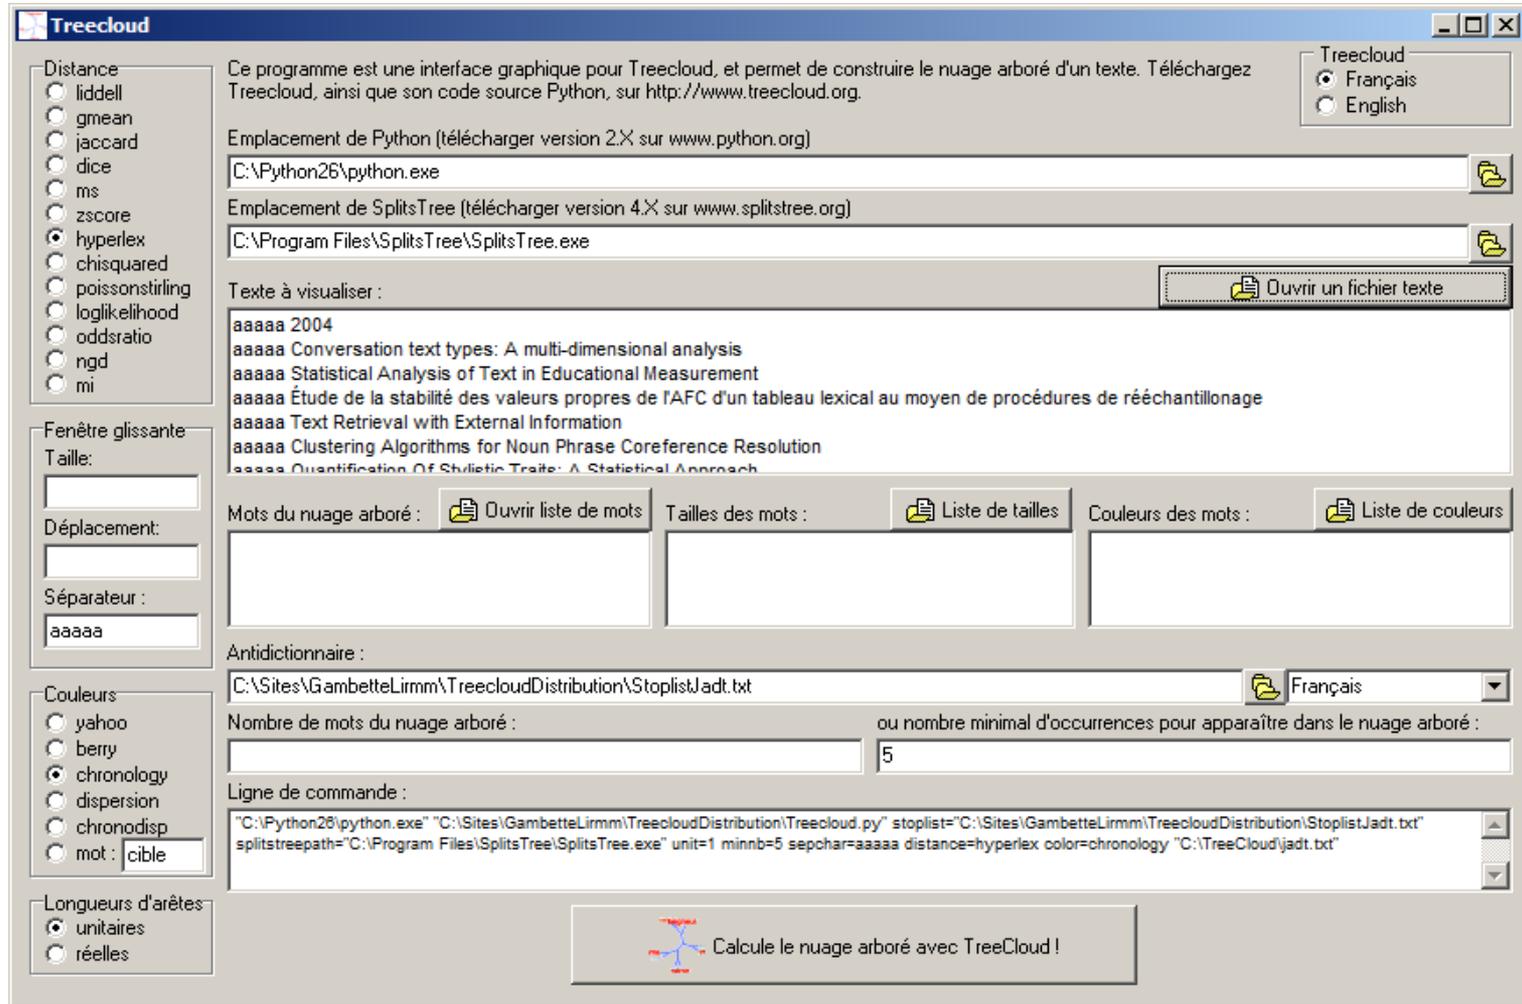
→ heuristique pour éviter les chevauchements

Question des longueurs d'arêtes ?



Implémentations

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



Interface web

www.treecloud.org



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

This website helps you to generate tree cloud words are arranged on a tree which reflects The first tree cloud appeared on [Jean Véron](#) create your own with this website, or with t

Create your own tree cloud online

Ce site web vous permet de générer des n des nuages de mots disposés autour d'un art Le premier nuage arboré est apparu sur le t pouvez maintenant [créer les vôtres avec ce s](#)

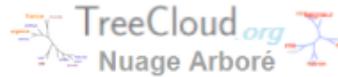
Créez vos propres nuages arborés

Documents :



If you use TreeCloud or this website, please Philippe Gambette et Jean Véronis: [Visualizing Classification as a Tool of Research, Proc. of Societies](#)), to appear, 2010 ([supplementary m](#)

Pour des exemples d'utilisation de la visuali Delphine Amstutz et Philippe Gambette: [Uti JADT'10 \(10th International Conference supplémentaire\)](#).



 Créer! Téléchargements Galerie A propos FAQ

Créez vos propres nuages arborés !

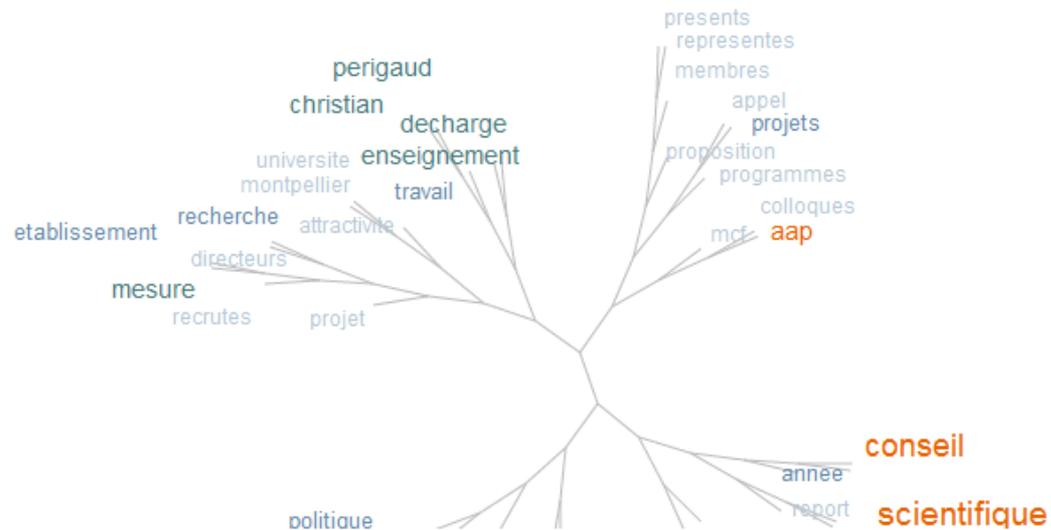
Collez votre texte dans le cadre ci-dessous, puis cliquez sur *Envoyer* ! Attention, l'utilisateur suivant verra votre texte quand il se connectera au site, si vous ne voulez pas faire apparaître vos textes, installez plutôt [TreeCloud](#) sur votre machine.

Texte :

conseil
scientifique
projet
proces
verbal

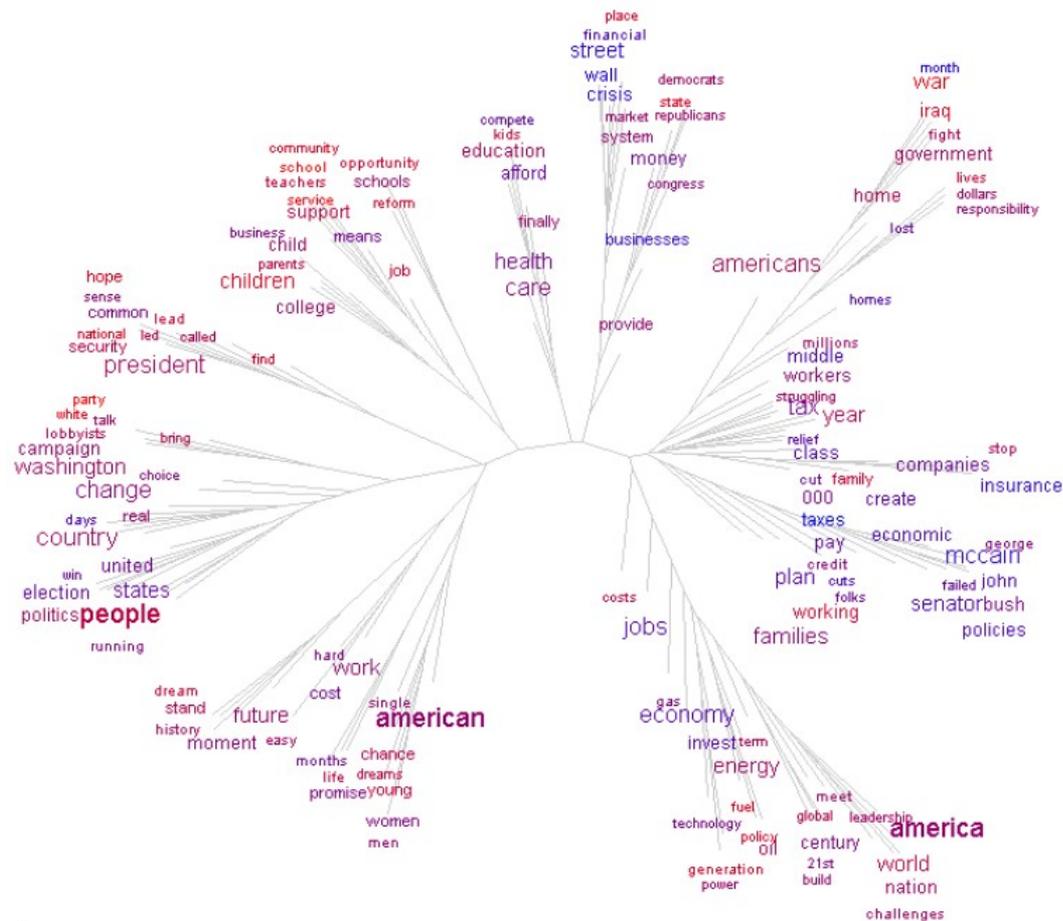
Envoyer

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.



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)

Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- **Évaluation de la robustesse de l'arbre**
- Calcul des longueurs d'arêtes de l'arbre
- Perspectives

Contrôle qualité

Distances dans l'arbre = approximation des distances entre mots

Mesure objective de la qualité de l'arbre ?

Contrôle qualité

Distances dans l'arbre = approximation des distances entre mots

Mesure objective de la qualité de l'arbre ?

Variations du nuage de mots suite à l'altération du texte?

➔ **bootstrap** pour évaluer :

- **stabilité du résultat**
- **robustesse de la méthode**

Contrôle qualité

Distances dans l'arbre = approximation des distances entre mots

Mesure objective de la qualité de l'arbre ?

Variations du nuage de mots suite à l'altération du texte?

➔ **bootstrap** pour évaluer :

- **stabilité du résultat**
- **robustesse de la méthode**

Méthode directe ?

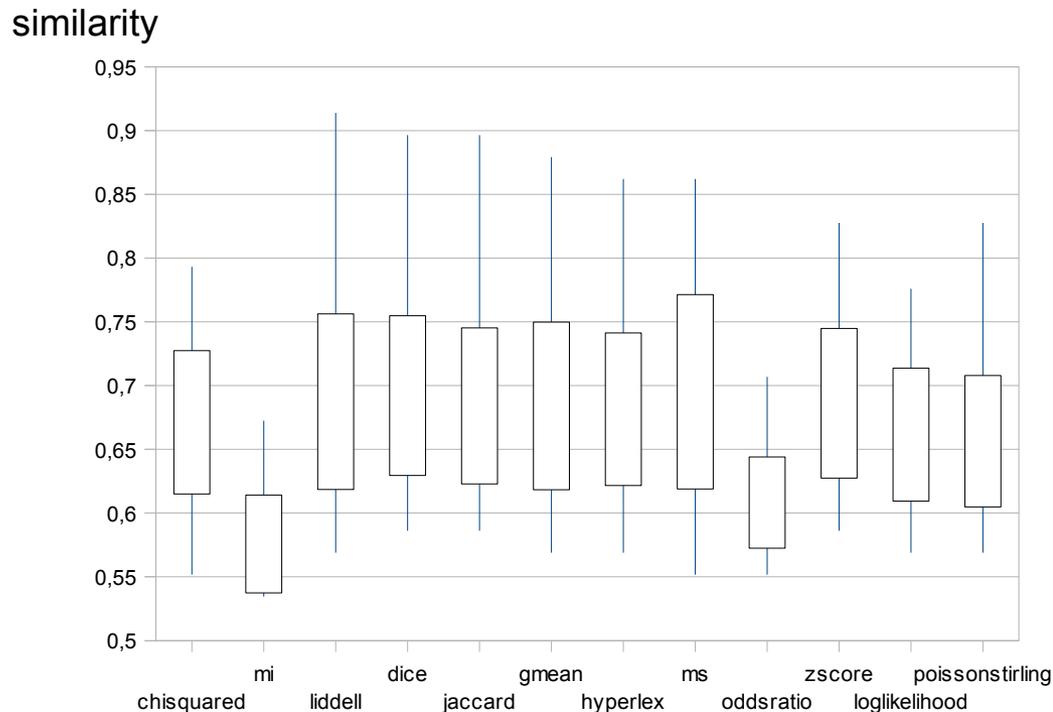
➔ **arboricité** pour mesurer à quel point la matrice de distance correspond à une distance d'arbre

Guénoche & Garreta, 2001

Guénoche & Darlu, 2009

Contrôle qualité - Bootstrap

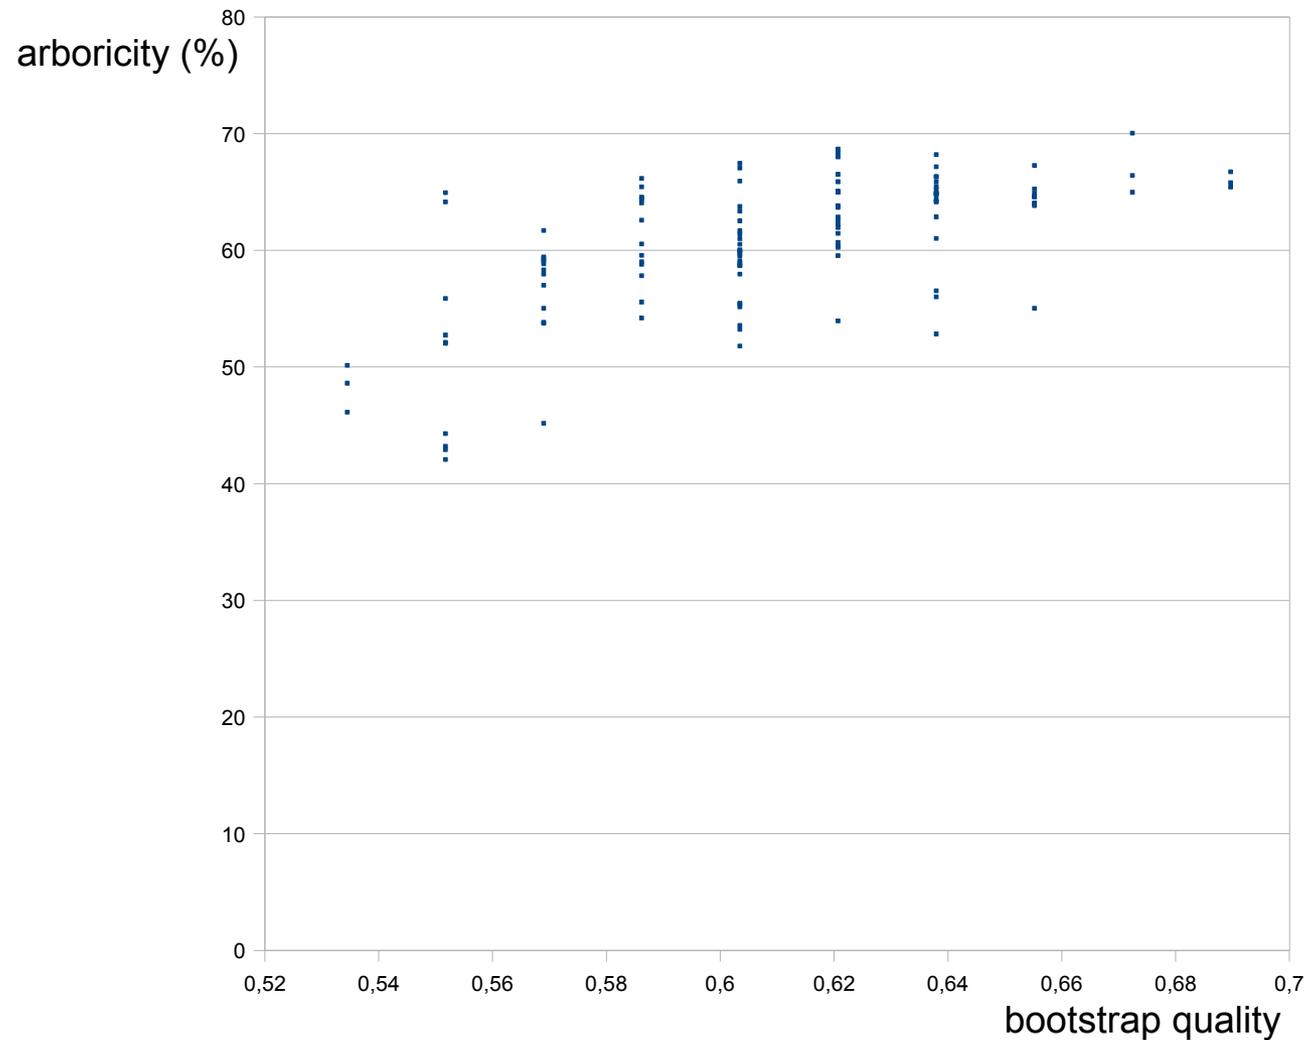
- Suppression des mots avec probabilité 50%.
- Construction du nuage arboré des textes original et altéré.
- Similarité des deux arbres (1-normalized RobinsonFoulds)



4 versions altérées de 10 discours d'Obama's, 3000 mots en moyenne, w=30, arbre NJ

Contrôle qualité - Arboricité

Relation entre “qualité bootstrap” et arboricité :

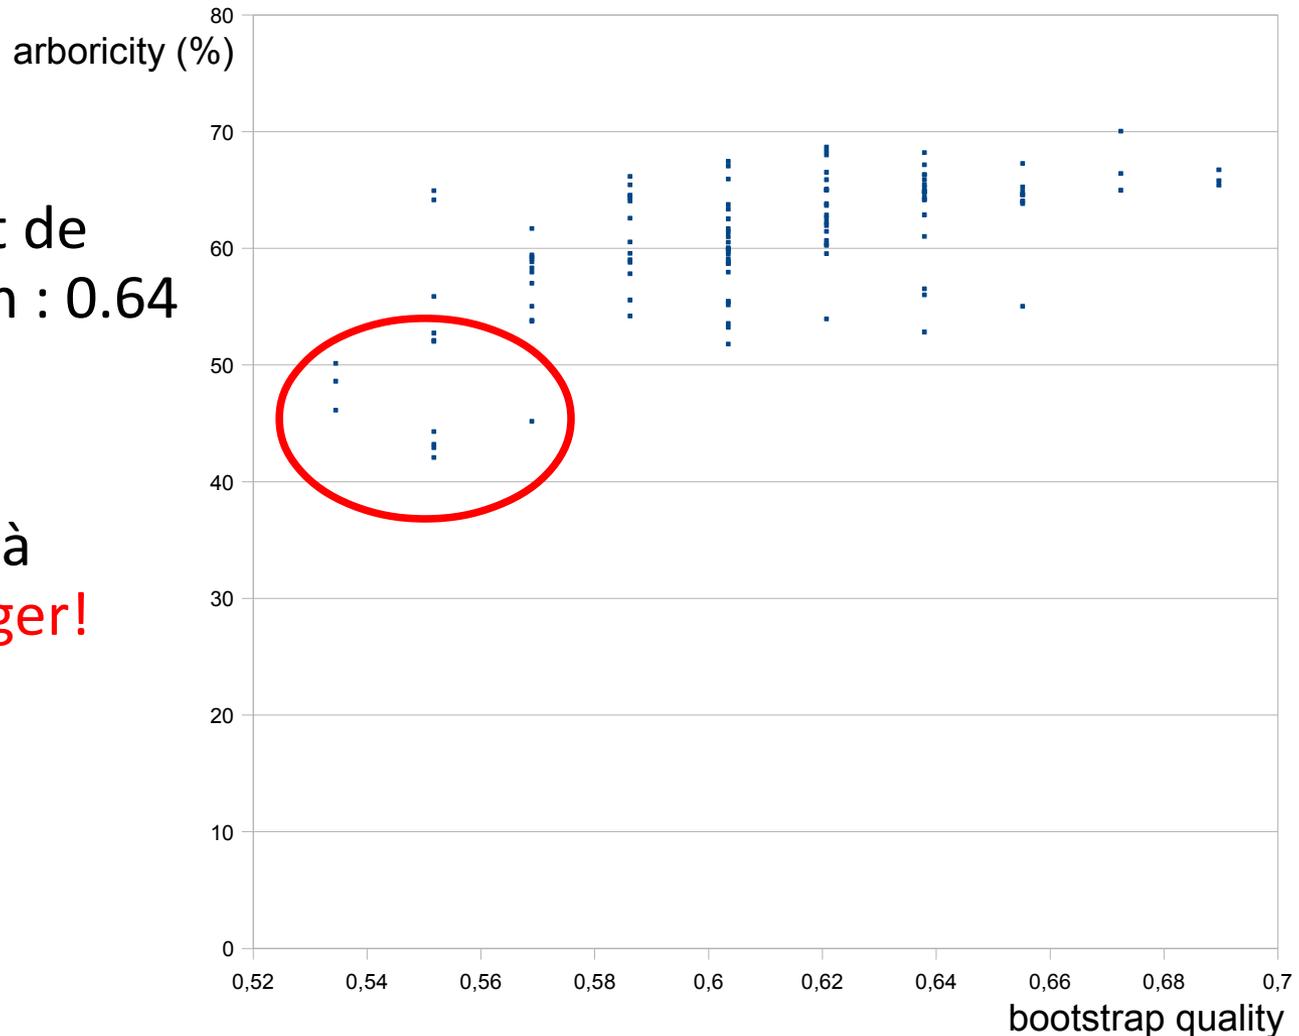


Contrôle qualité - Arboricité

Relation entre “qualité bootstrap” et arboricité :

coefficient de
corrélation : 0.64

arboricité
inférieure à
50% : **danger!**



Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- **Calcul des longueurs d'arêtes de l'arbre**
- Perspectives

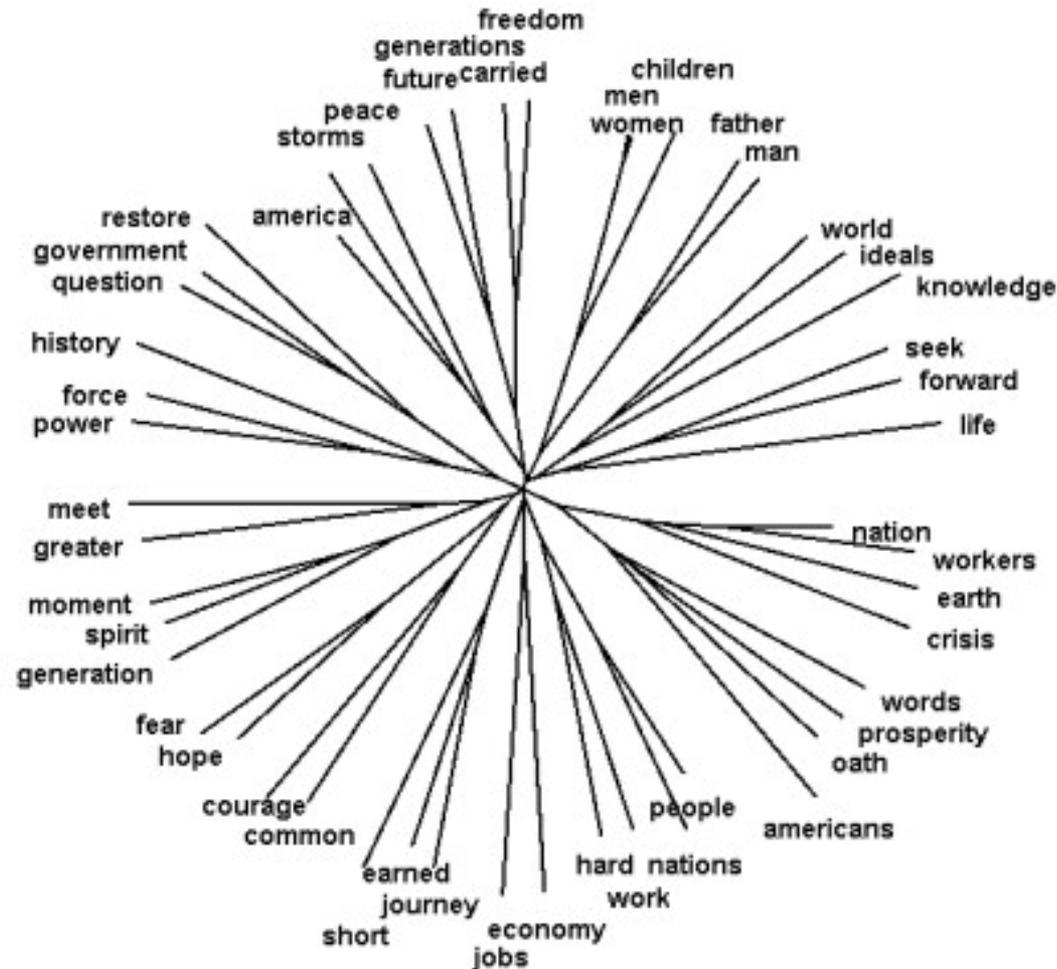
Calcul des longueurs d'arêtes

- Interprétation visuelle des longueurs d'arêtes
- Formules de longueurs d'arêtes
- Protocole d'évaluation
- Résultats
- Visualisations

Calcul des longueurs d'arêtes

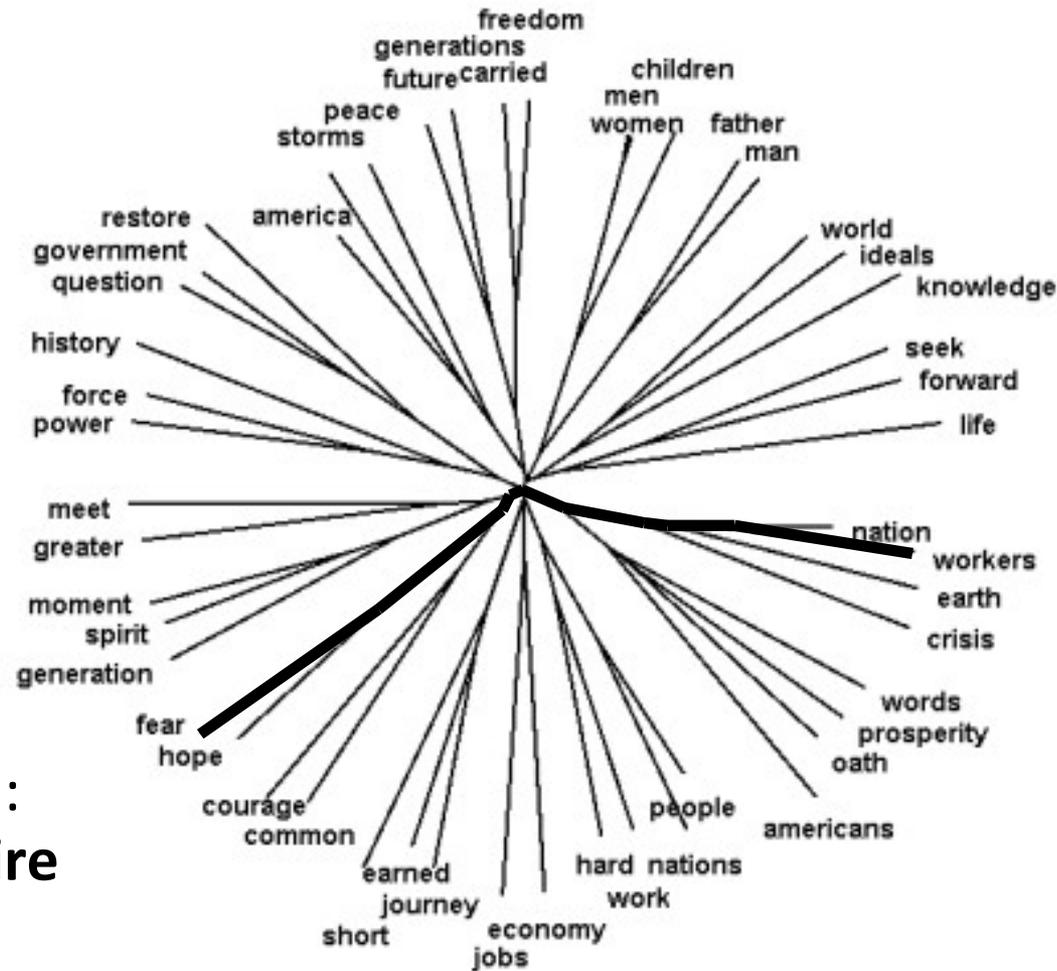
- Interprétation visuelle des longueurs d'arêtes
- Formules de longueurs d'arêtes
- Protocole d'évaluation
- Résultats
- Visualisations

Interprétation réelle



Les **distances** dans l'**arbre** entre deux mots reflètent *au mieux* le **degré de cooccurrence** entre ces deux mots

Interprétation réelle

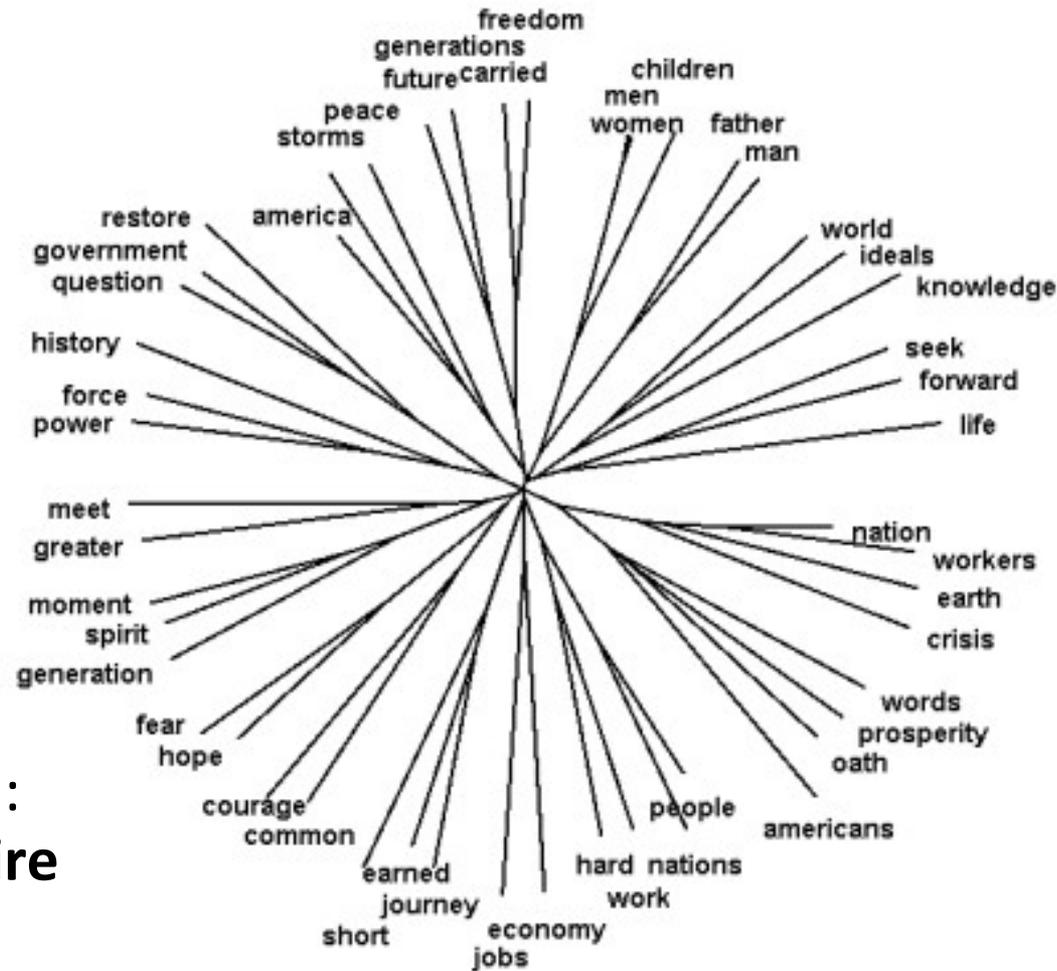


Problème 1 :
difficiles à lire



Les **distances** dans l'arbre entre deux mots reflètent *au mieux* le **degré de cooccurrence** entre ces deux mots

Interprétation réelle

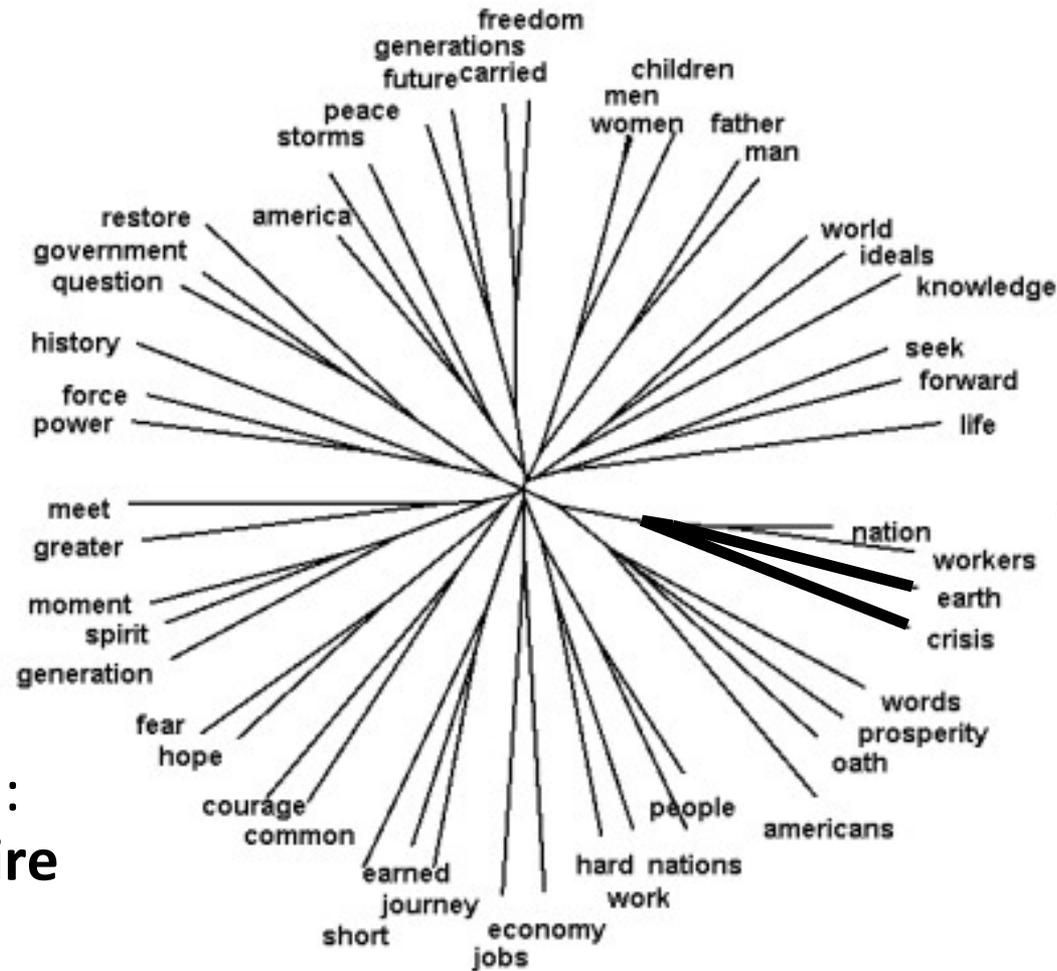


Problème 1 :
difficiles à lire

Problème 2 :
peu fiables

Les **distances dans l'arbre** entre deux mots reflètent *au mieux* le **degré de cooccurrence** entre ces deux mots

Interprétation réelle



Optimisation **globale**, pas de garanties locales de qualité

Problème 1 : **difficiles à lire**

Problème 2 : **peu fiables**

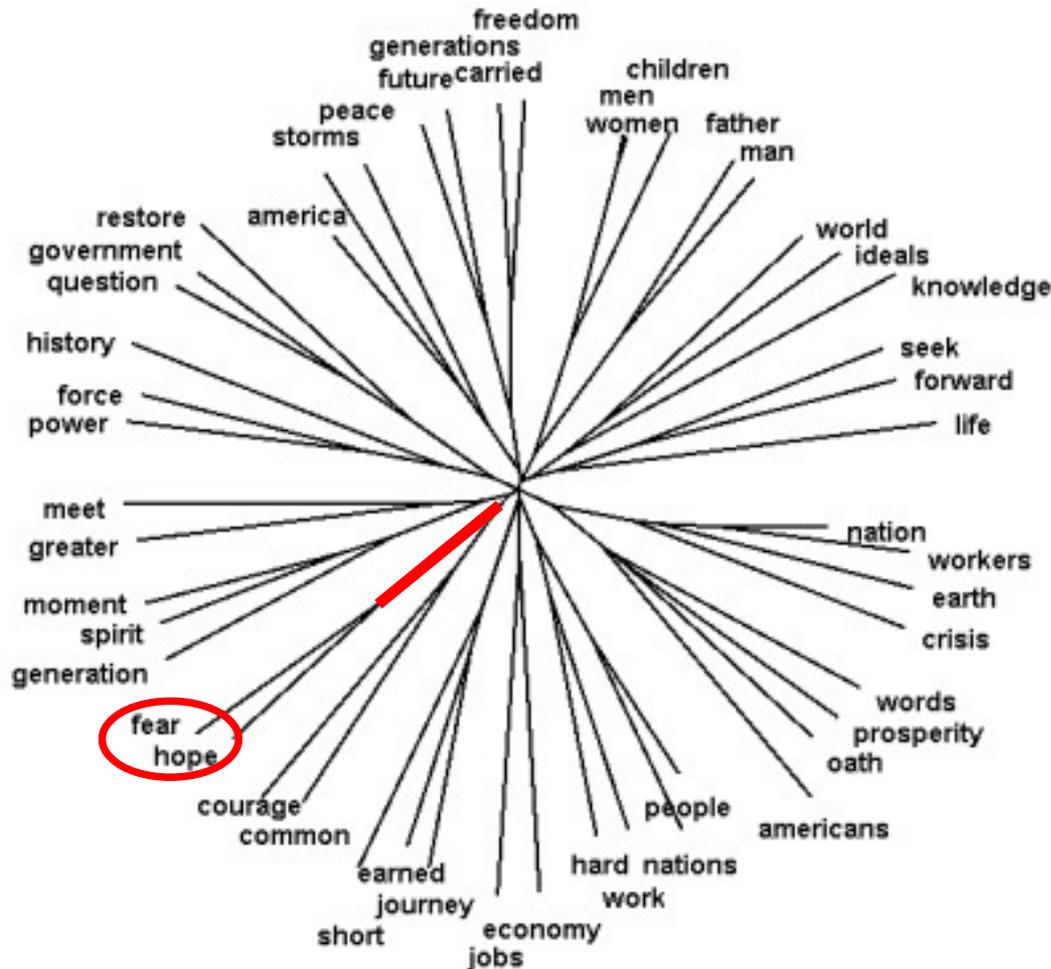
Les **distances dans l'arbre** entre deux mots reflètent *au mieux* le **degré de cooccurrence** entre ces deux mots

Interprétation pratique



arbre de distances
utilisé comme
classification

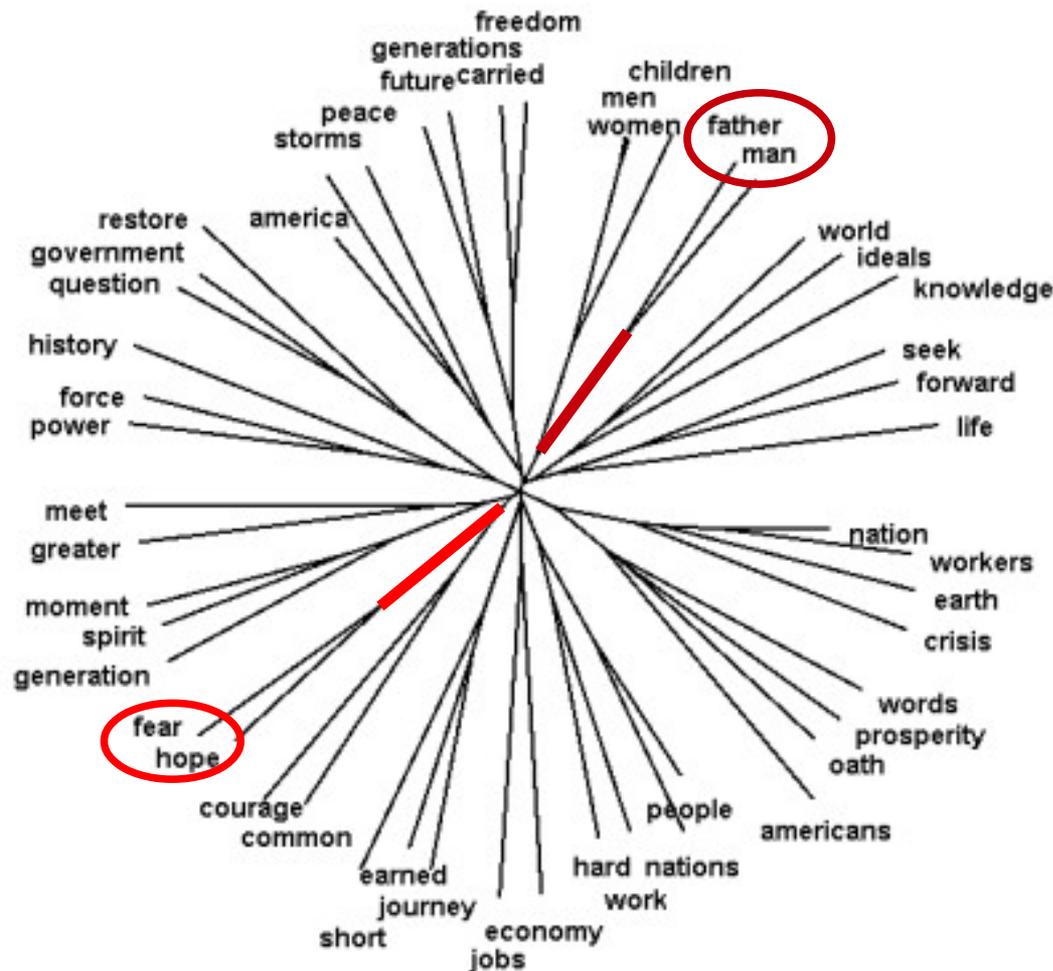
Interprétation pratique



arbre de distances
utilisé comme
classification

Les mots d'un **même sous-arbre** bien séparé du reste de l'arbre
constituent une classe de mots

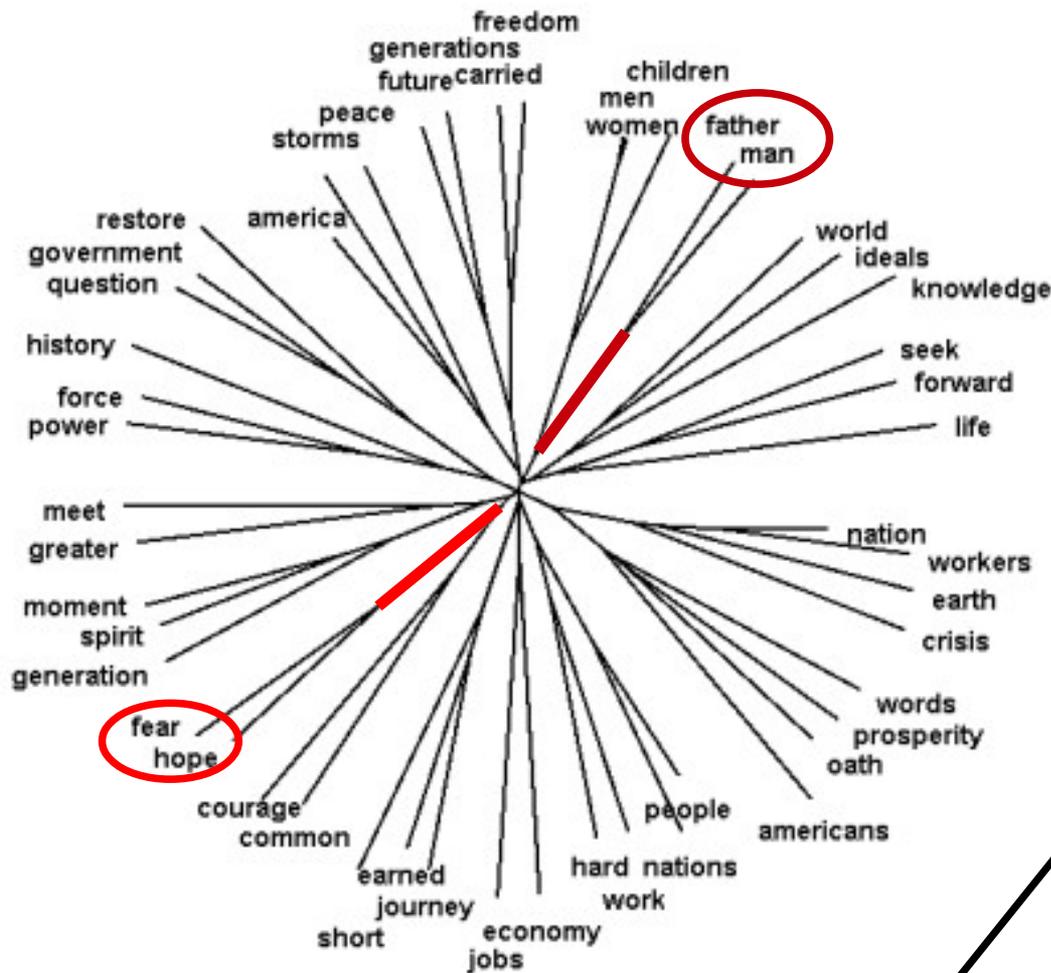
Interprétation pratique



arbre de distances
utilisé comme
classification

Les mots d'un **même sous-arbre** bien séparé du reste de l'arbre
constituent une classe de mots

Interprétation pratique



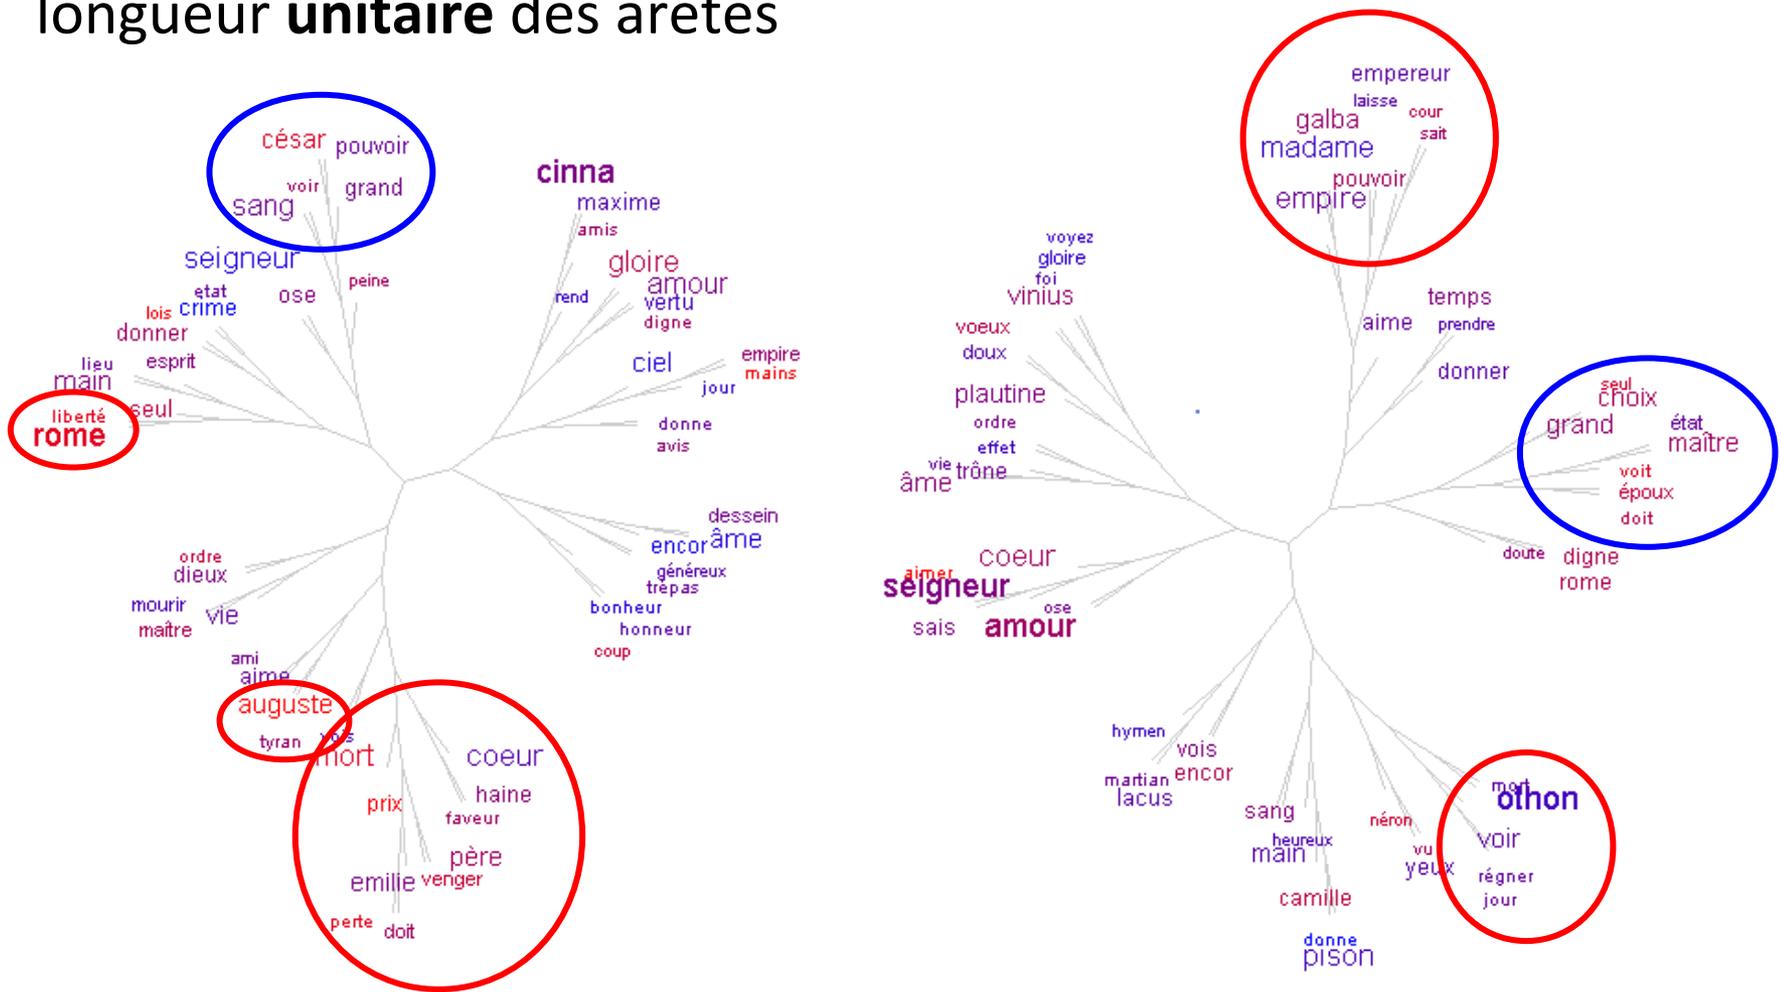
arbre de distances
utilisé comme
classification

Problème : **toujours
peu lisible** (longueur
des arêtes externes)
et **peu fiable**

Les mots d'un **même sous-arbre** bien séparé du reste de l'arbre
constituent une classe de mots

Interprétation pratique

Astuce de visualisation pour améliorer la lisibilité :
longueur **unitaire** des arêtes

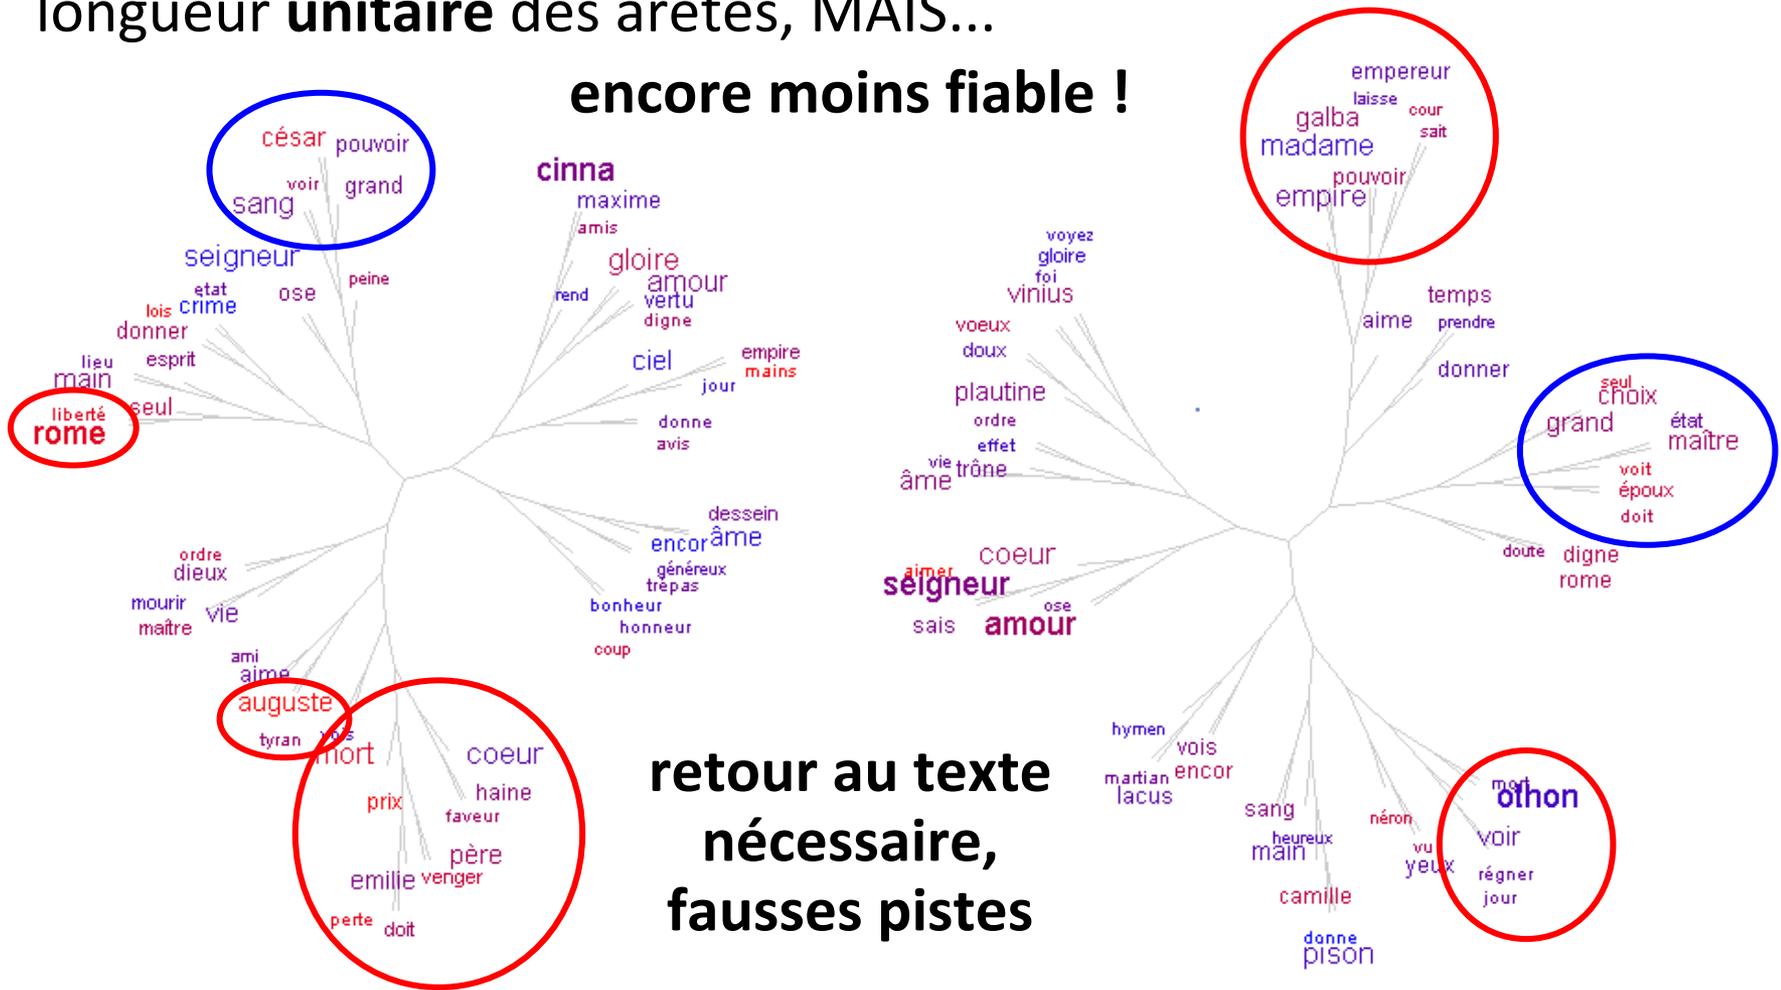


Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Interprétation pratique

Astuce de visualisation pour améliorer la lisibilité : longueur **unitaire** des arêtes, MAIS...

encore moins fiable !



Nuages arborés globaux des 60 mots les plus fréquents dans Cinna et Othon (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

Interprétation pratique

Problème :

Comment calculer les longueurs des arêtes de l'arbre pour une **interprétation fiable des classes** ?

Arête longue = classe de mots significative (proches les uns des autres, bien séparés du reste)

Arête courte = classe de mots peu significative

Calcul des longueurs d'arêtes

- Interprétation visuelle
- Formules de longueurs d'arêtes
- Protocole d'évaluation
- Résultats
- Visualisations
- Perspectives

Formules de longueurs d'arêtes

Post-calcul des longueurs d'arêtes après la construction de l'arbre,
pour que :

arêtes les plus longues \leftrightarrow classes de mots **les plus significatives**
 \leftrightarrow classes de mots **bien séparées**
d'après la **distance de cooccurrence**

Formules de longueurs d'arêtes

Post-calcul des longueurs d'arêtes après la construction de l'arbre, pour que :

arêtes les plus longues \leftrightarrow **classes de mots les plus significatives**
 \leftrightarrow classes de mots **bien séparées**
d'après la **distance de cooccurrence**

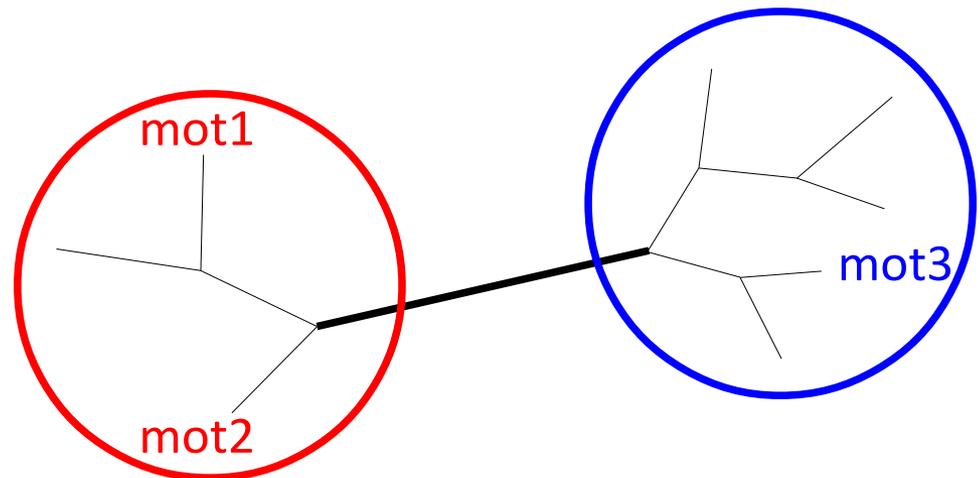
Formule du **ratio des bons triplets** (“triples”) :

Si **mot1** et **mot2** d'un côté de l'arête, **mot3** de l'autre côté,

“**bon triplet**” si

$\text{distance}(\text{mot1}, \text{mot2}) <$
 $\text{min}(\text{distance}(\text{mot1}, \text{mot3}),$
 $\text{distance}(\text{mot2}, \text{mot3}))$

ratio espéré proche de 1



Formules de longueurs d'arêtes

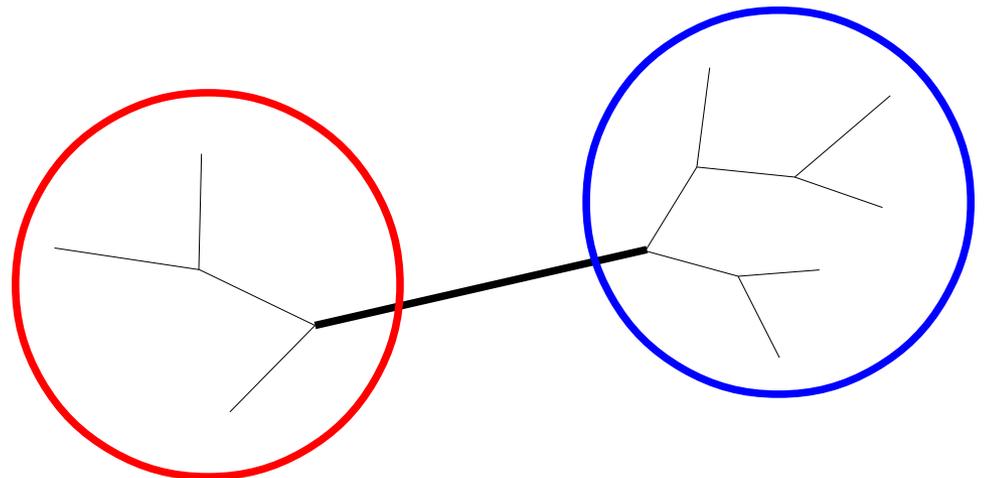
Post-calcul des longueurs d'arêtes après la construction de l'arbre, pour que :

arêtes les plus longues ↔ **classes de mots les plus significatives**
↔ **classes de mots bien séparées**
d'après la **distance de cooccurrence**

Formule du **ratio des distances moyennes** (“distanceRatio”) :

$$\frac{\text{moyenne}(\text{distances } \text{inter-classes})}{\text{moyenne}(\text{distances } \text{intra-classes})}$$

ratio espéré supérieur à 1



Formules de longueurs d'arêtes

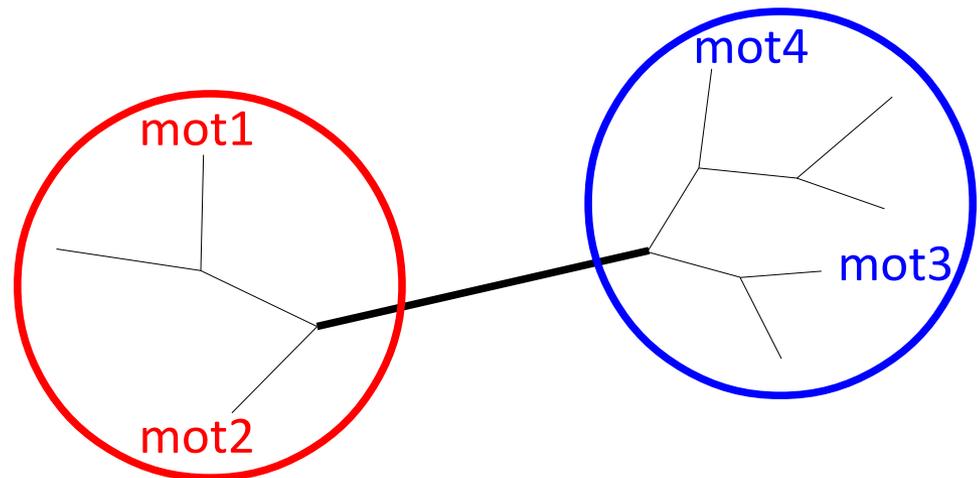
Post-calcul des longueurs d'arêtes après la construction de l'arbre, pour que :

arêtes les plus longues \leftrightarrow classes de mots les plus significatives
 \leftrightarrow classes de mots bien séparées
d'après la distance de cooccurrence

Formule du ratio des bons quadruplets (“quartets”) :

Si **mot1** et **mot2** d'un côté de l'arête, **mot3** et **mot4** de l'autre côté,

“bon quadruplet” si
 $\text{distance}(\text{mot1}, \text{mot2}) +$
 $\text{distance}(\text{mot2}, \text{mot3}) <$
 $\min(\text{distance}(\text{mot1}, \text{mot3}) +$
 $\text{distance}(\text{mot2}, \text{mot4}) +,$
 $\text{distance}(\text{mot1}, \text{mot4}) +$
 $\text{distance}(\text{mot2}, \text{mot3}))$



ratio espéré proche de 1

Calcul des longueurs d'arêtes

- Interprétation visuelle
- Formules de longueurs d'arêtes
- **Protocole d'évaluation**
- Résultats
- Visualisations
- Perspectives

Protocole d'évaluation

Post-calcul des longueurs d'arêtes après la construction de l'arbre, puis :

Vérification que les classes de mots **les mieux séparées**
(d'après ces longueurs) sont **significatives**

Protocole d'évaluation

Post-calcul des longueurs d'arêtes après la construction de l'arbre, puis :

Vérification que les classes de mots
les mieux séparées (d'après ces
longueurs) sont **significatives**



Partition obtenue en **découpant les
arêtes les plus longues** comparée
avec une partition de référence

Protocole d'évaluation

Post-calcul des longueurs d'arêtes après la construction de l'arbre, puis :

Vérification que les classes de mots
les mieux séparées (d'après ces
longueurs) sont **significatives**



Partition obtenue en **découpant les
arêtes les plus longues** comparée
avec une partition de référence,

quelles
données ?

Protocole d'évaluation

Base de données Polymots

Base lexicale de familles morpho-phonologiques

20 000 mots, 2000 familles

The screenshot displays the Polymots website interface. At the top, the word "POLYMOTS" is written in a stylized font. Below it, there are four search buttons: "Recherche", "Recherche alphabétique", "Recherche par sens", and "Recherche par type". A "Recherche simple" section follows, with a text input field containing "art" and a "Lancer" button. Below the search bar, a "Résultats" section shows a list of 15 words: art, art, artifice, artificiel, artificiellement, artificier, artillerie, artilleur, artisan (highlighted), artisanal, artisanalement, artisanat, artiste, artistique, and artistiquement. To the right, a "Fiche détaillée de 'artisan'" section provides details: "Mot base : art", "Type : transparent", "Nombre de mots dérivés contenant le mot base : 14", and "Productivité du mot base : 0.70 %". It also includes a "Sens" list (aider, art, artisanat, automatiser, compter, créateur, exercer, général, manuel, métier, personne, pratique, propre) and an "Affixes" list (an, is).

Protocole d'évaluation

Base de données Polymots

Base lexicale de familles morpho-phonologiques

20 000 mots, 2000 familles

+ **partitions sémantiques** des familles de 20 mots

(arbre, art, boule, carte, corde, dent, dict, fil, fusée, lune, meuble, mode, onde, paille, penser, pot, presse, tenir, terre, val).

Protocole d'évaluation

Base de données Polymots

Base lexicale de familles morpho-phonologiques

20 000 mots, 2000 familles

+ **partitions sémantiques** des familles de 20 mots

(arbre, art, boule, carte, corde, dent, dict, fil, fusée, lune, meuble, mode, onde, paille, penser, pot, presse, tenir, terre, val).

Exemple pour la famille de **art** :

{ {artifice, artificiel, artificiellement, artificier},
{artillerie, artilleur},
{artisan, artisanal, artisanalement, artisanat},
{artiste, artistique, artistiquement, art} }

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?

Distance utilisée pour le calcul de la représentation arborée ?

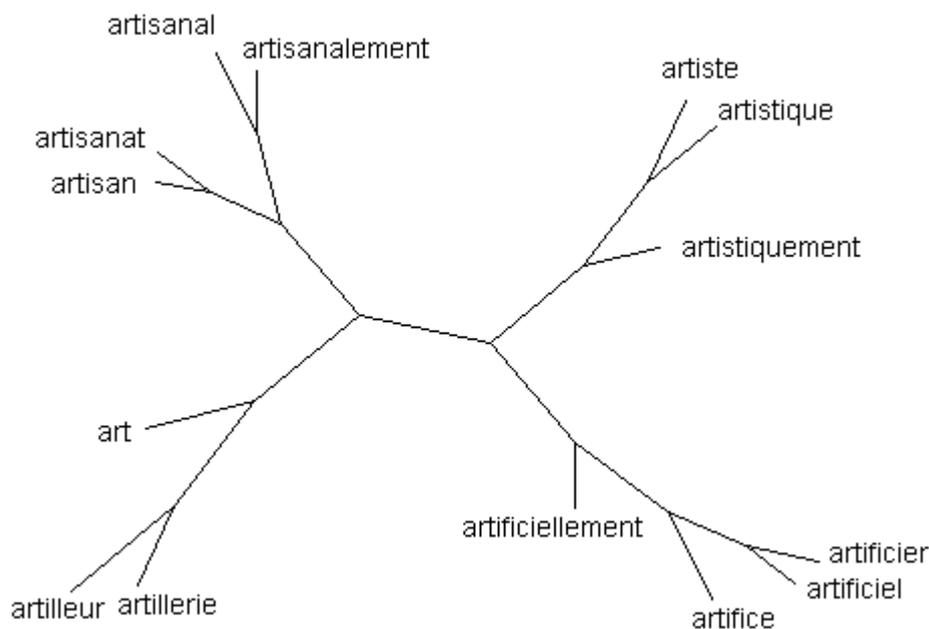
Distance composite entre :

- nombre d'affixes communs
- degré de cooccurrence dans **Le Trésor
de la Langue
Française
informatisé**

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir Pk
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

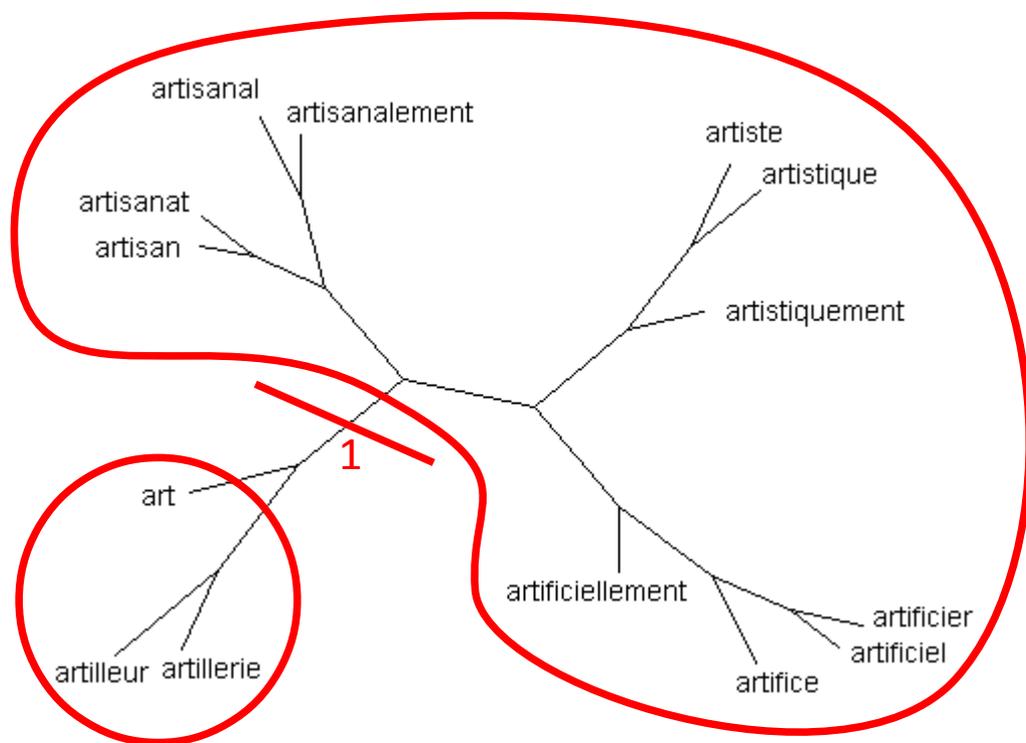
$P_0 = \{\{\text{artisan, artisanat, artisanal, artisanalelement, artiste, artistique, artistiquement, artificier, artificiel, artifice, artificiellement, artillerie, artilleur, art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalelement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

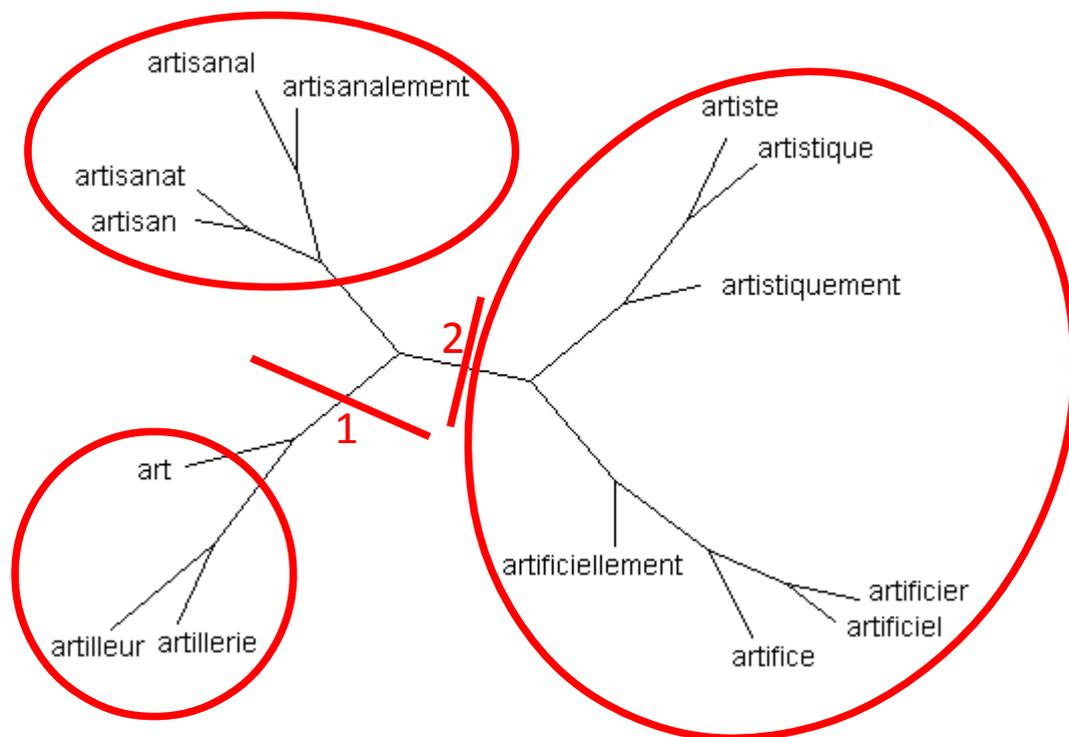
P1 = {{artisan, artisanat, artisanal, artisanalement, artiste, artistique, artistiquement, artificier, artificiel, artifice, artificiellement}, {artillerie, artilleur, art}}

Partition manuelle : **Pm** = {{artificier, artifice, artificiel, artificiellement}, {artillerie, artilleur}, {artisan, artisanal, artisanalement, artisanat}, {artiste, artistique, artistiquement, art}}

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

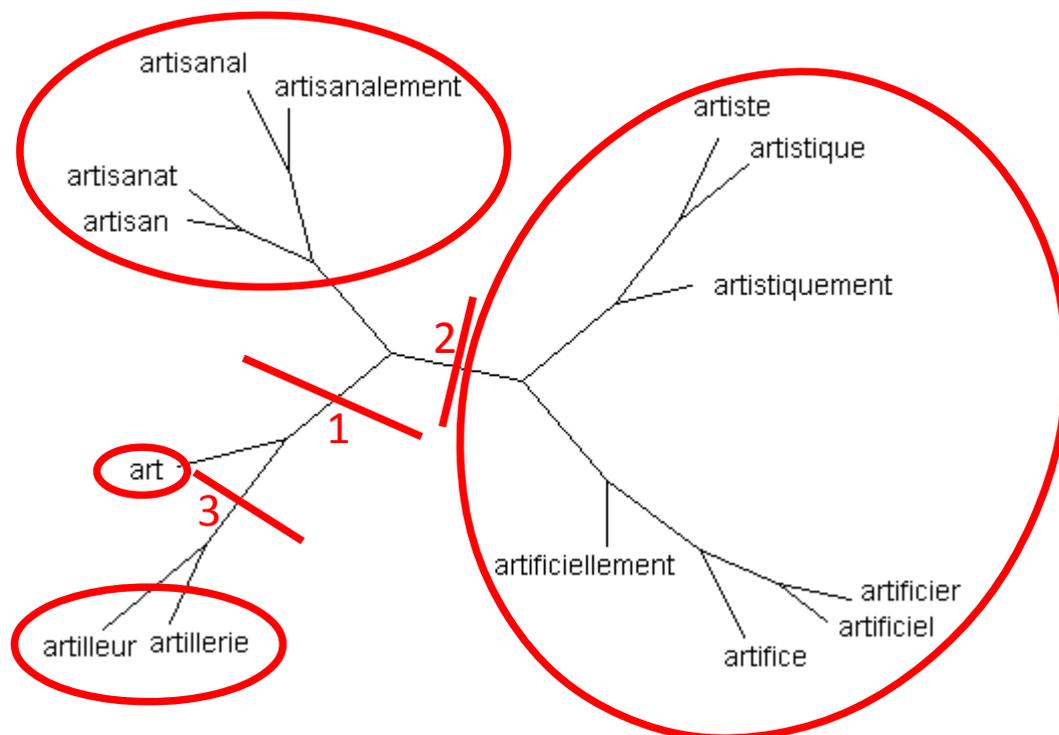
$P_2 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement, artificier, artificiel, artifice, artificiellement}\}, \{\text{artillerie, artilleur, art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

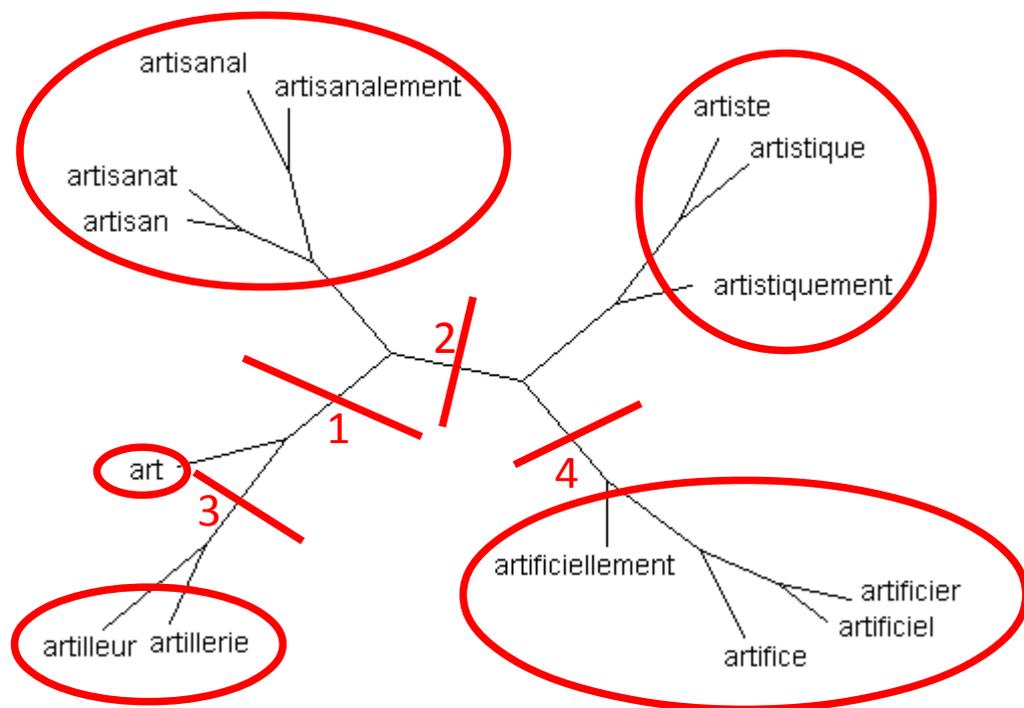
$P_3 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement, artificier, artificiel, artifice, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

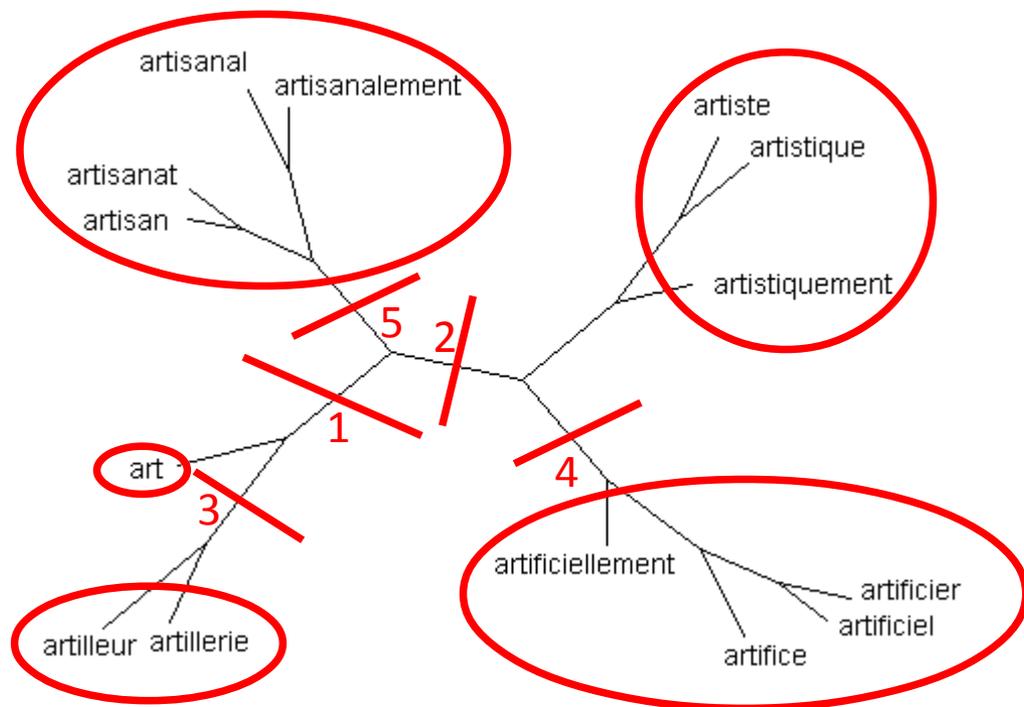
$P_4 = \{\{\text{artisan, artisanat, artisanal, artisanement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

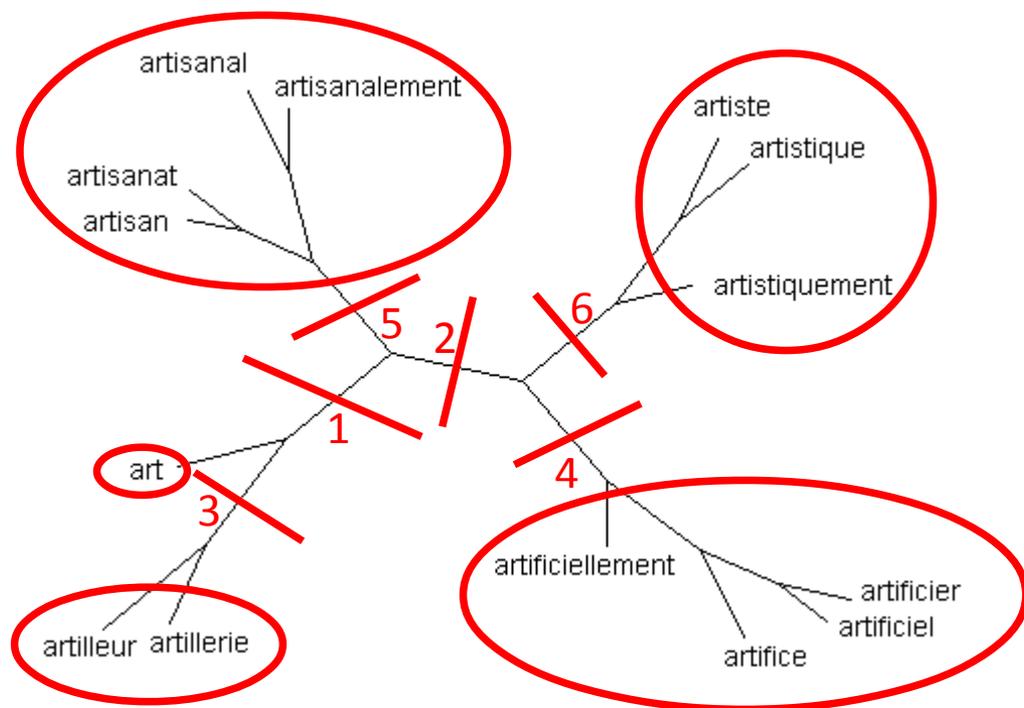
$P_5 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

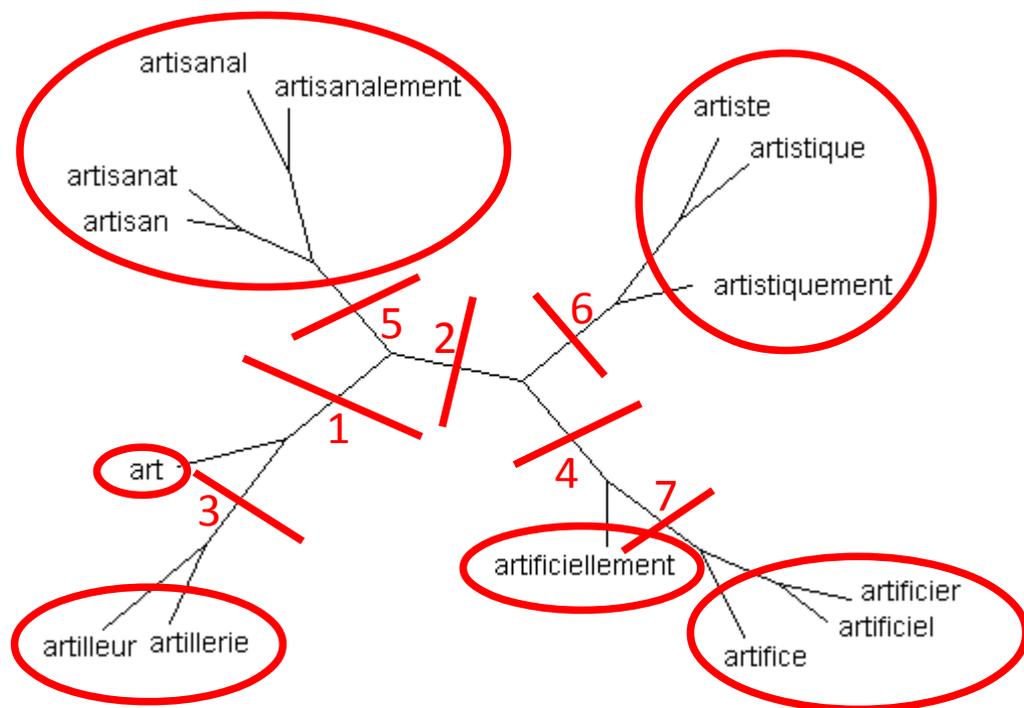
$P_6 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

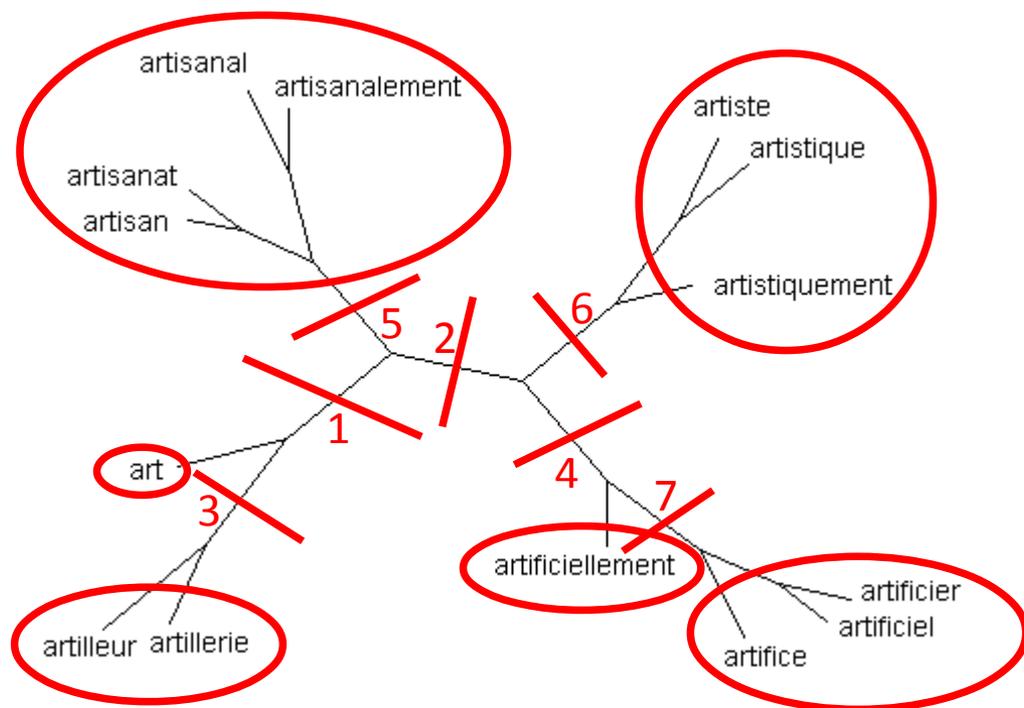
$P_7 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice}\}, \{\text{artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

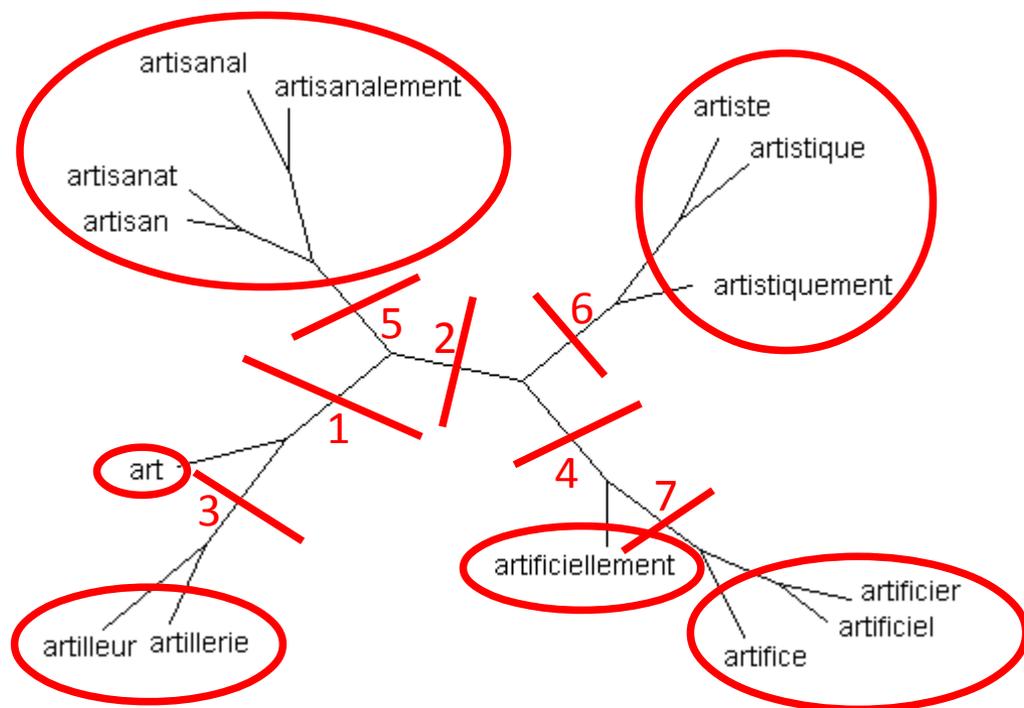
$P_7 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice}\}, \{\text{artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

$P_7 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice}\}, \{\text{artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

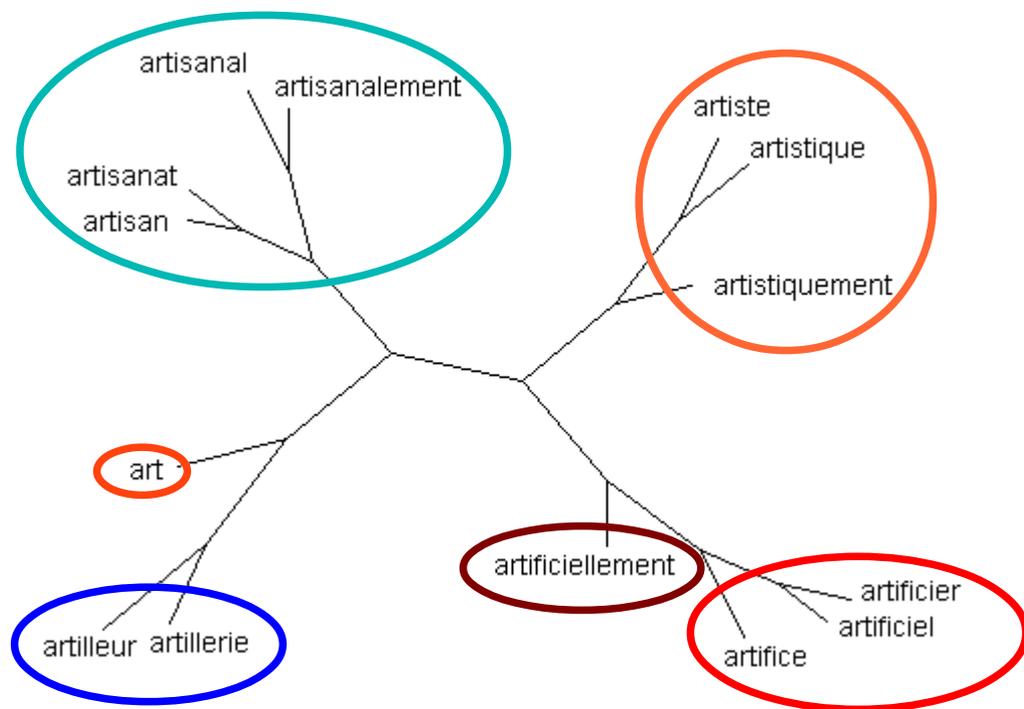
**Comparer les partitions !
(indice de Rand, Rand corrigé)**

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :
 $P_7 = \{\{\text{artisan, artisanat, artisanal, artisanalelement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice}\}, \{\text{artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

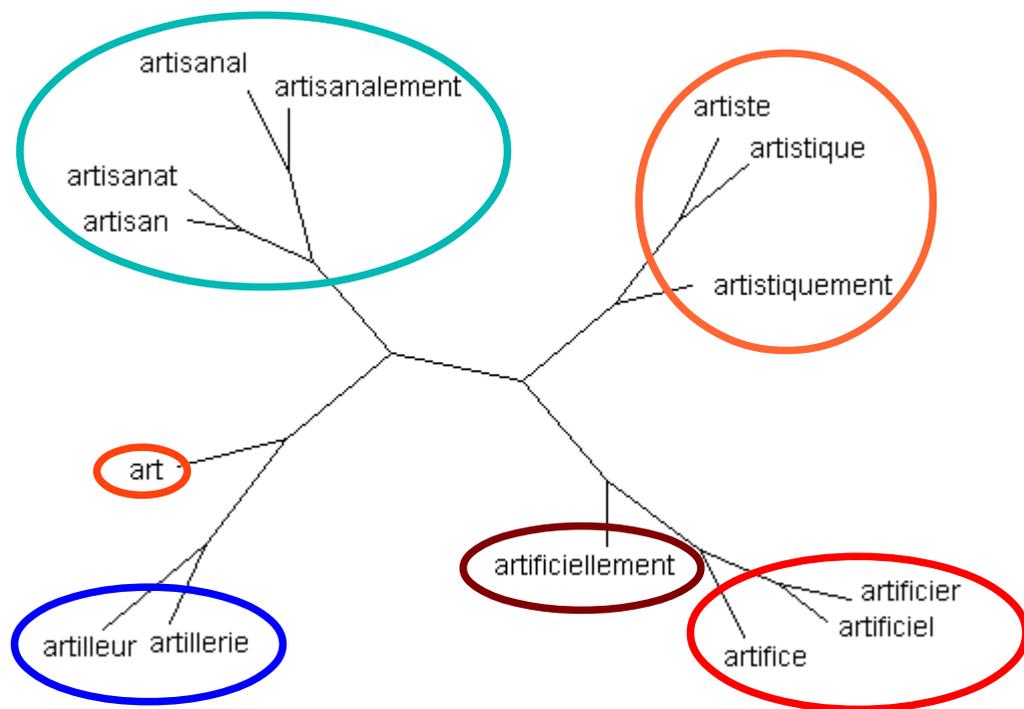
**Comparer les partitions !
(indice de Rand, Rand corrigé)**

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalelement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?



Partition automatique :

$P_7 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice}\}, \{\text{artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

$\text{rand}(P_m, P_7) = 0.934$

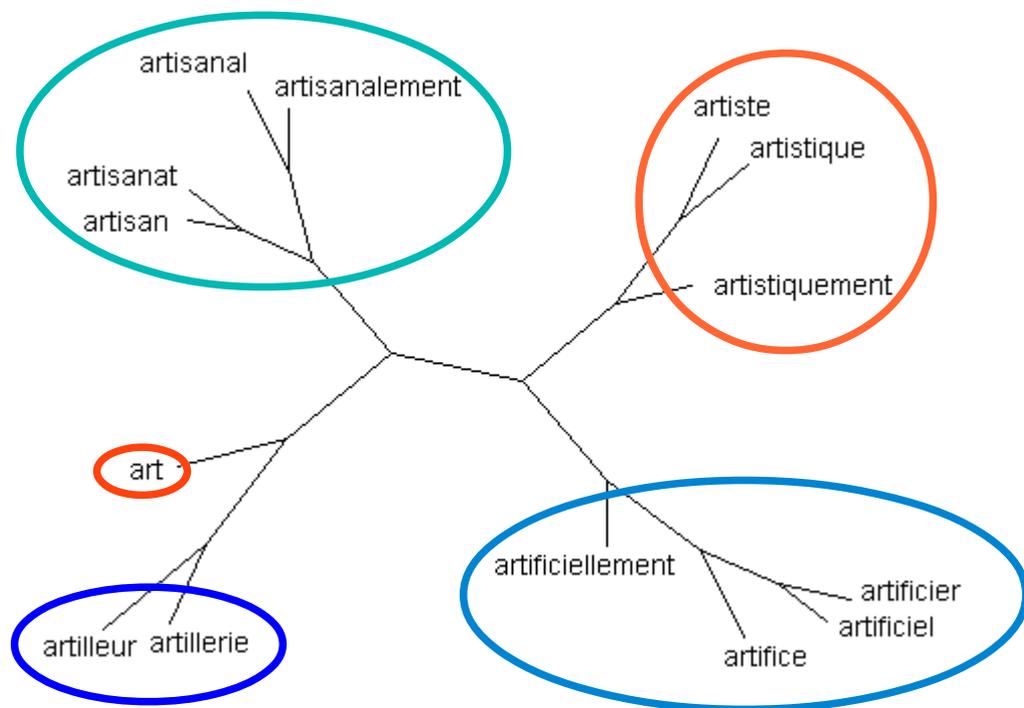
$\text{aRand}(P_m, P_7) = 0.774$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

Protocole d'évaluation

Idée :

- Construire une représentation arborée des mots de la famille
- Découper les k arêtes les plus longues de l'arbre pour obtenir P_k
- La partition obtenue est-elle proche de la partition "manuelle" ?

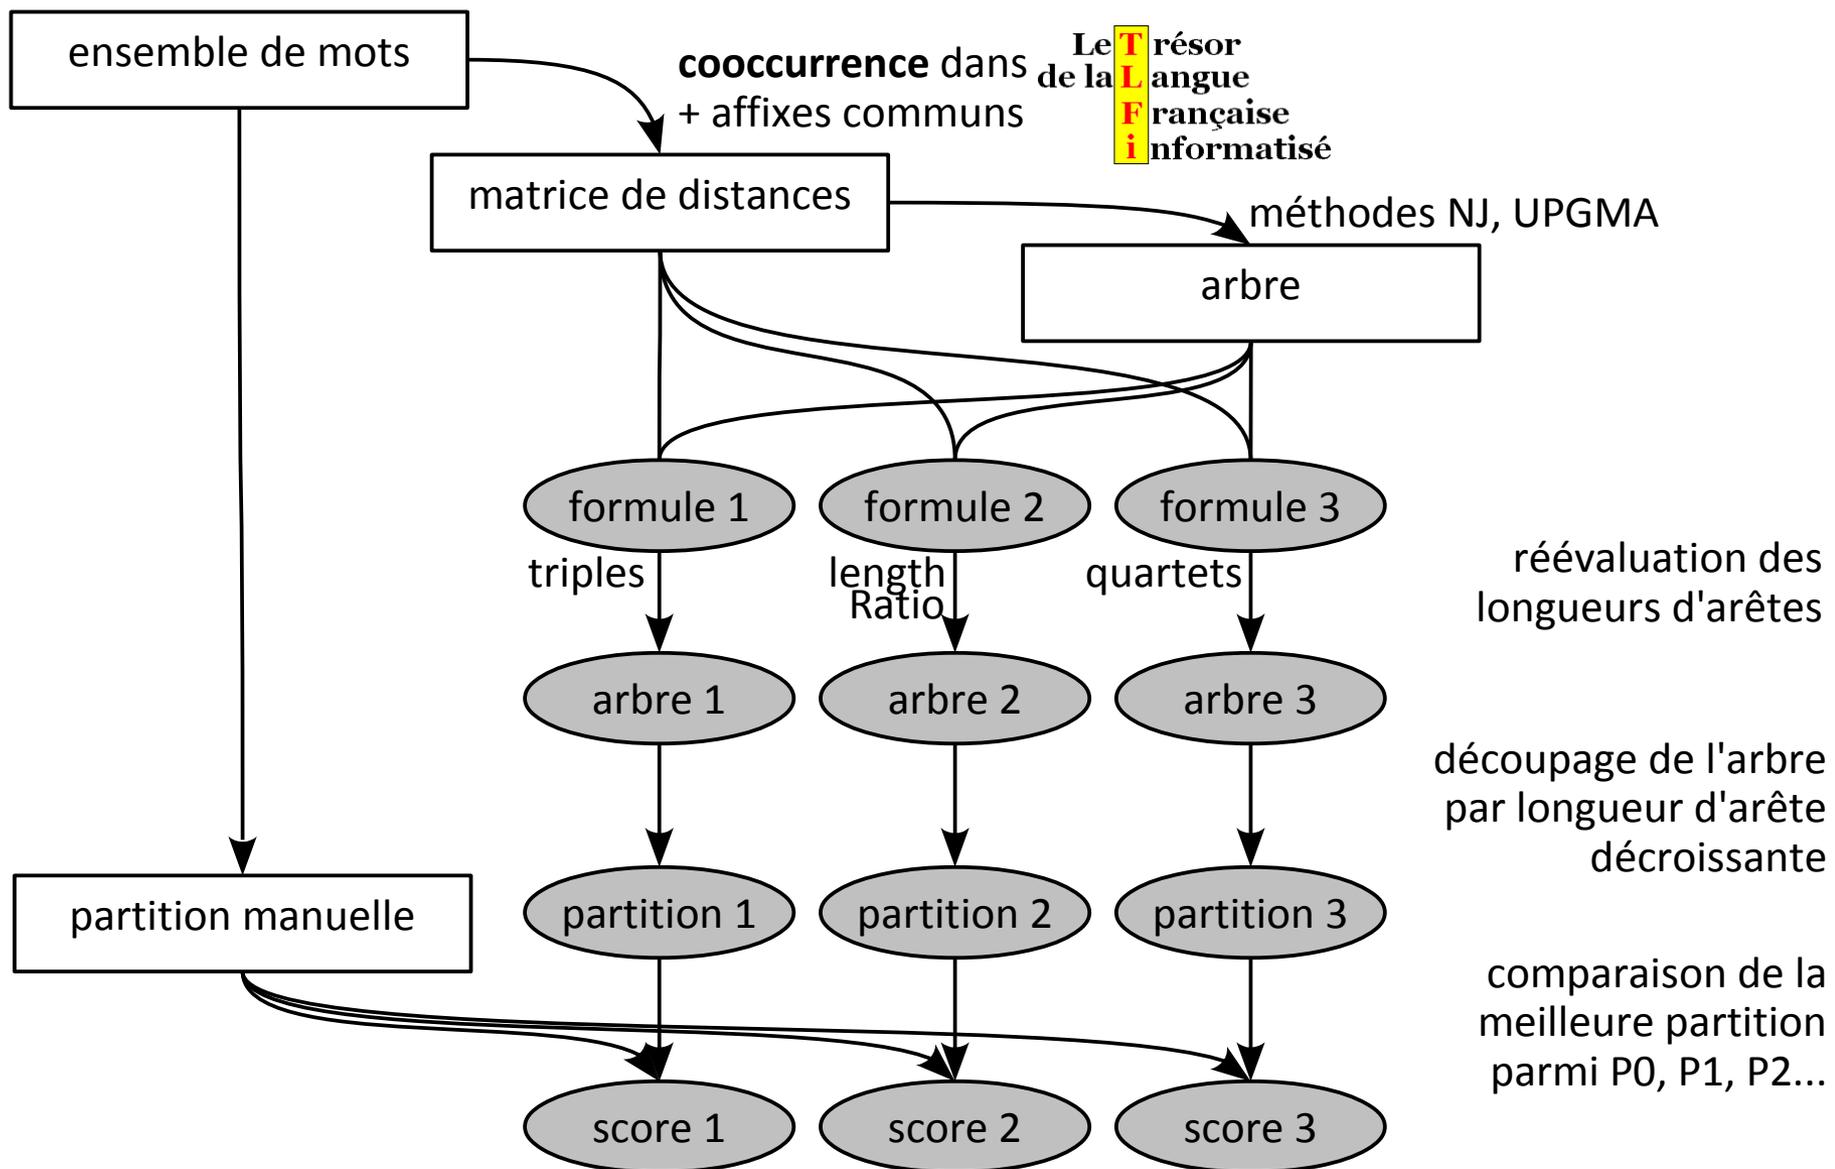


Partition automatique :
 $P_4 = \{\{\text{artisan, artisanat, artisanal, artisanalement}\}, \{\text{artiste, artistique, artistiquement}\}, \{\text{artificier, artificiel, artifice, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{art}\}\}$

$\text{rand}(P_m, P_4) = 0.967$
 $\text{aRand}(P_m, P_4) = 0.894$

Partition manuelle : $P_m = \{\{\text{artificier, artifice, artificiel, artificiellement}\}, \{\text{artillerie, artilleur}\}, \{\text{artisan, artisanal, artisanalement, artisanat}\}, \{\text{artiste, artistique, artistiquement, art}\}\}$

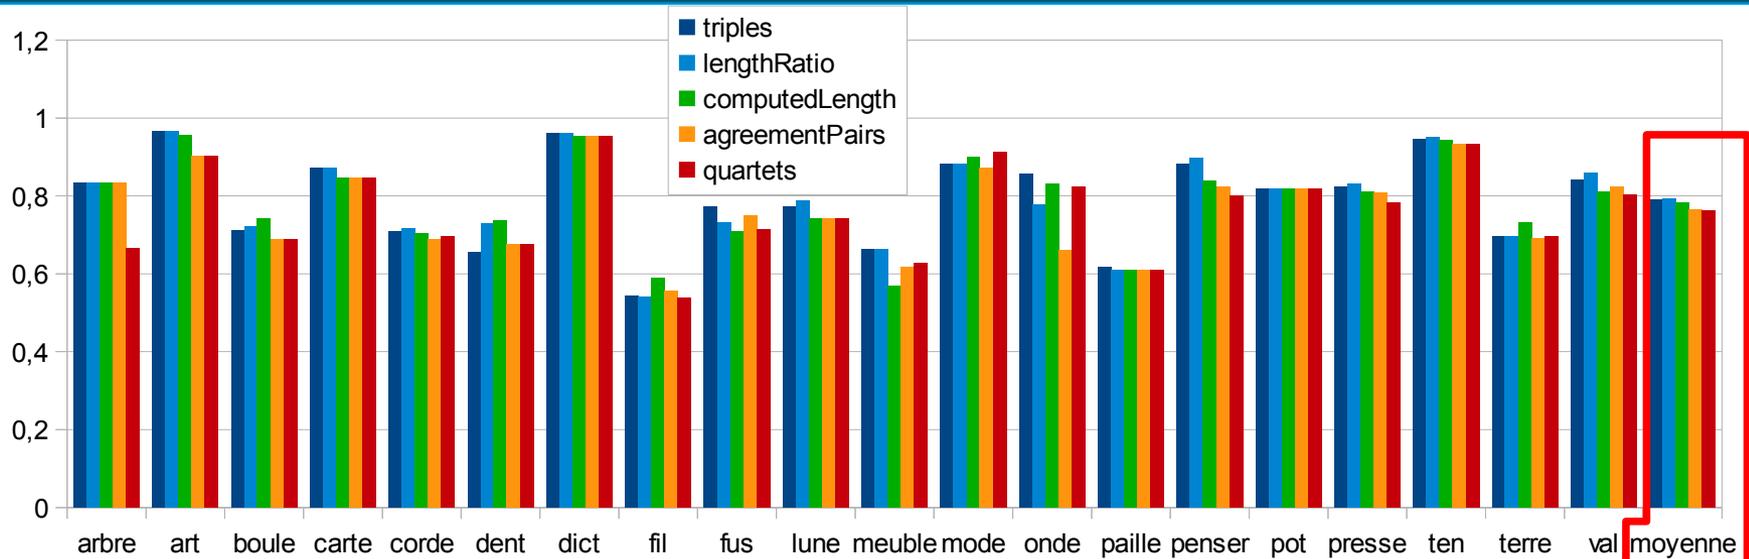
Protocole d'évaluation



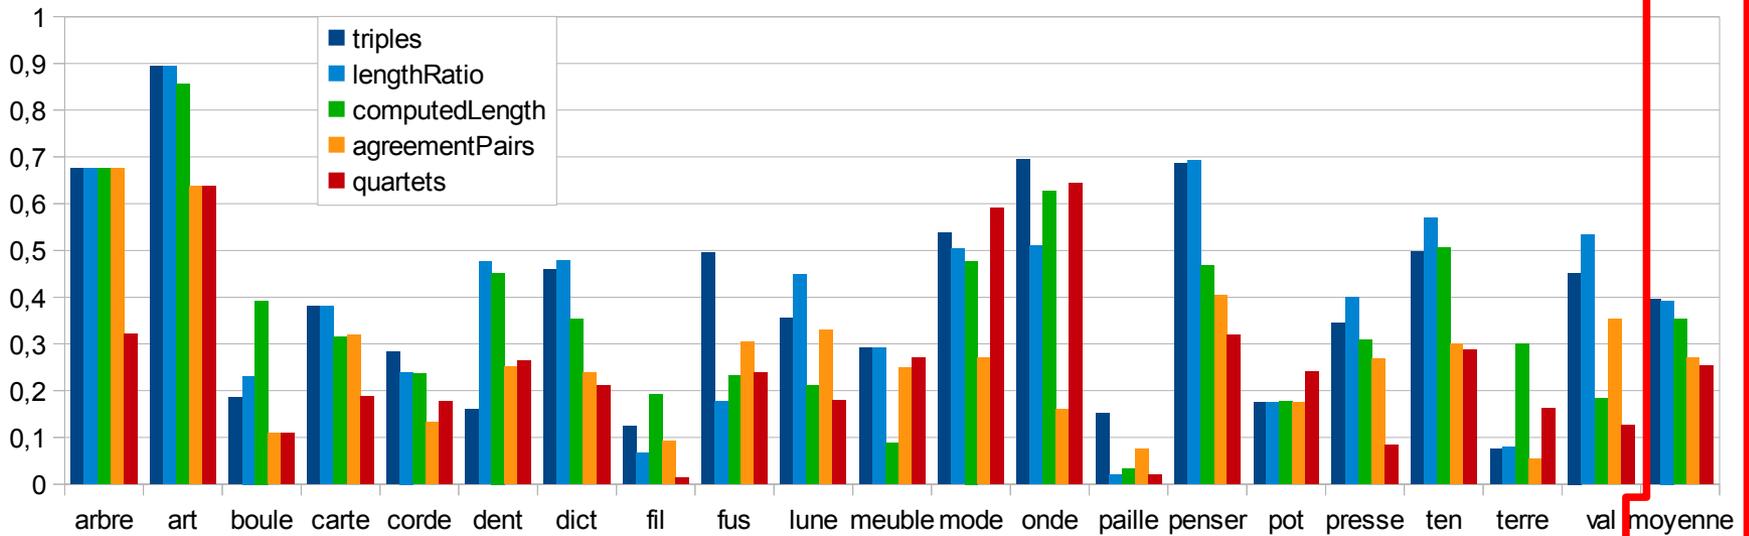
Calcul des longueurs d'arêtes

- Interprétation visuelle
- Formules de longueurs d'arêtes
- Protocole d'évaluation
- **Résultats**
- Visualisations
- Perspectives

Scores de chaque formule

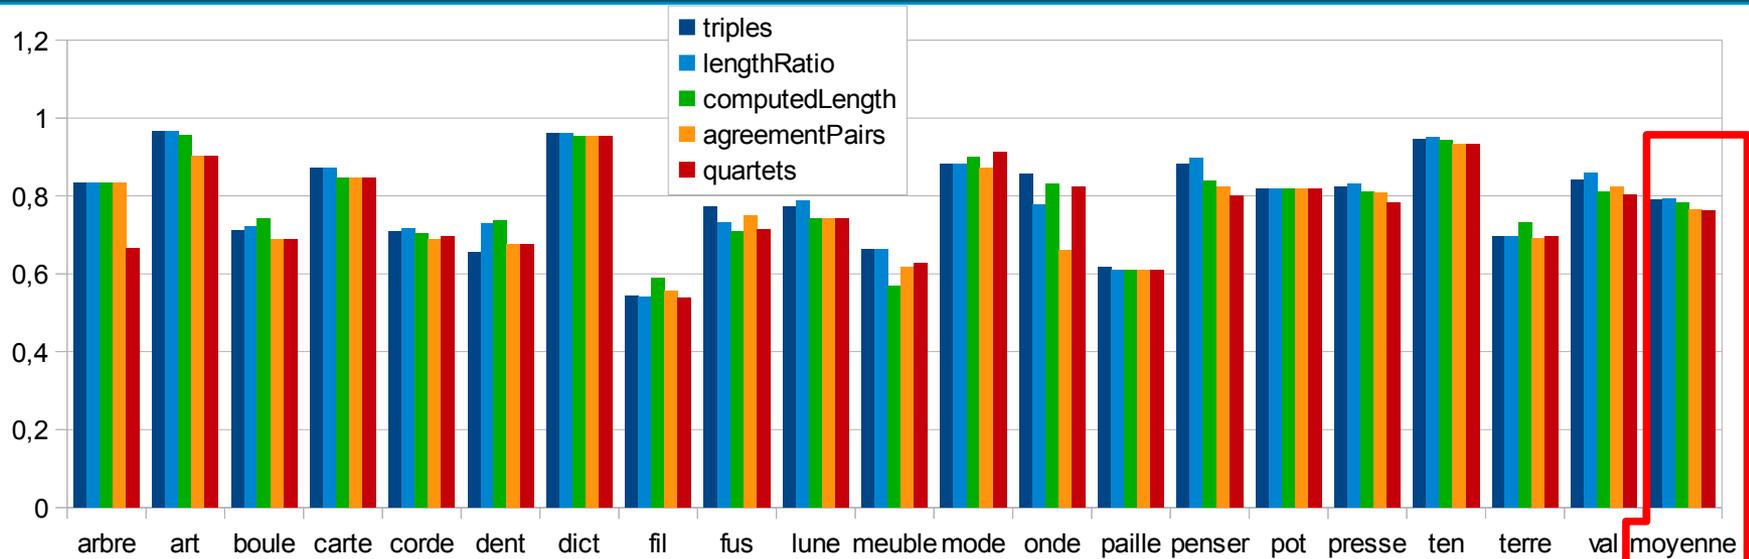


Score Rand de la meilleure partition trouvée automatiquement

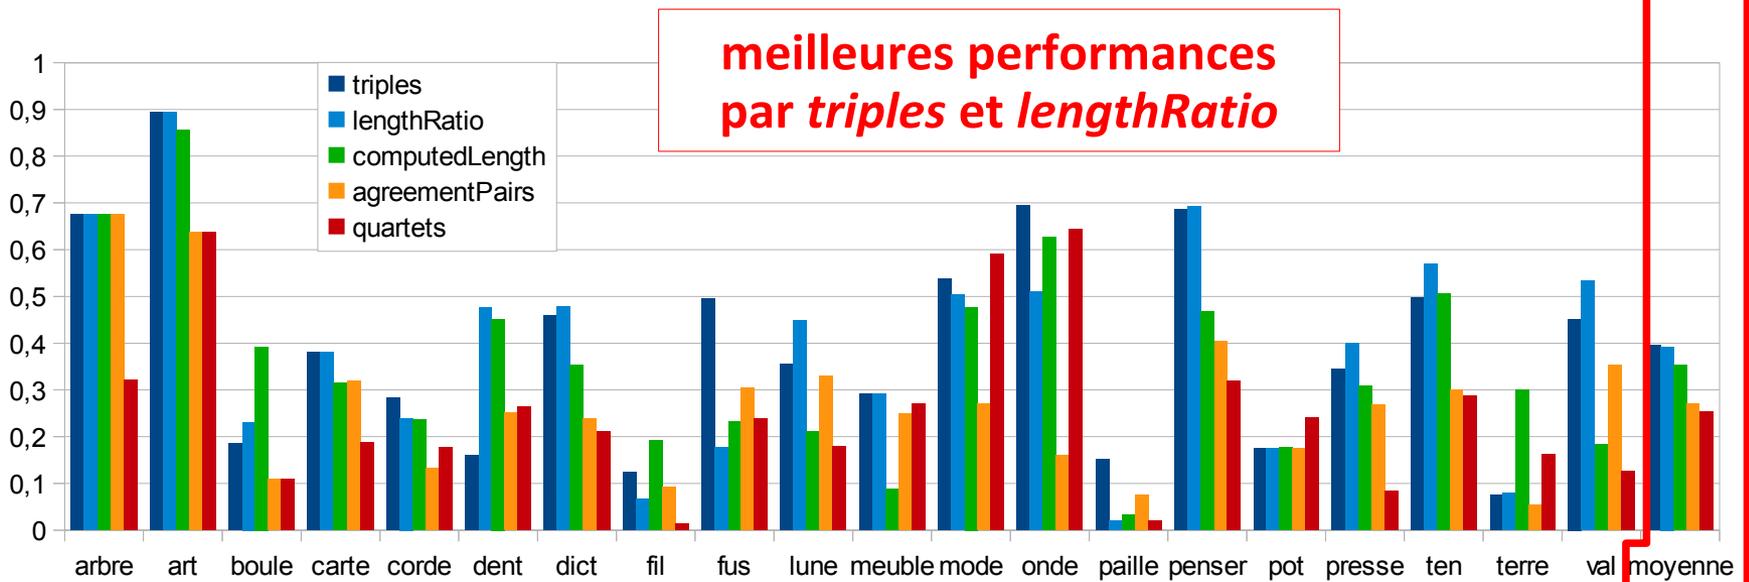


Score Rand corrigé de la meilleure partition trouvée automatiquement

Scores de chaque formule



Score Rand de la meilleure partition trouvée automatiquement



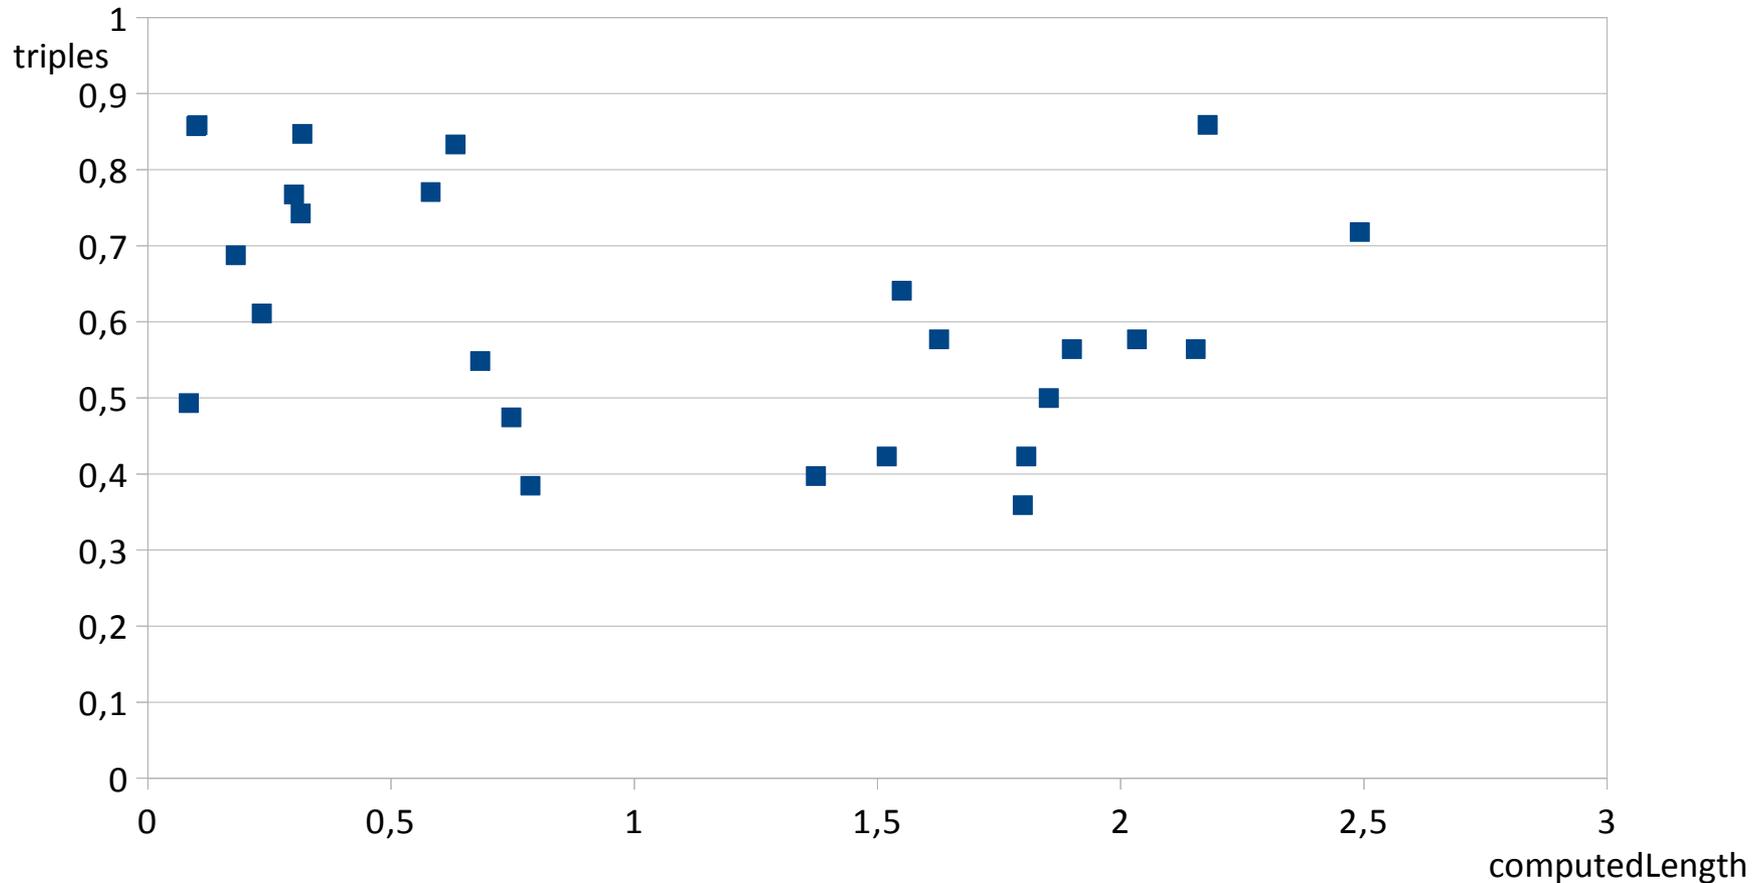
Score Rand corrigé de la meilleure partition trouvée automatiquement

Scores de chaque formule

Les formules de longueur d'arête sont-elles **cohérentes** ?

Scores de chaque formule

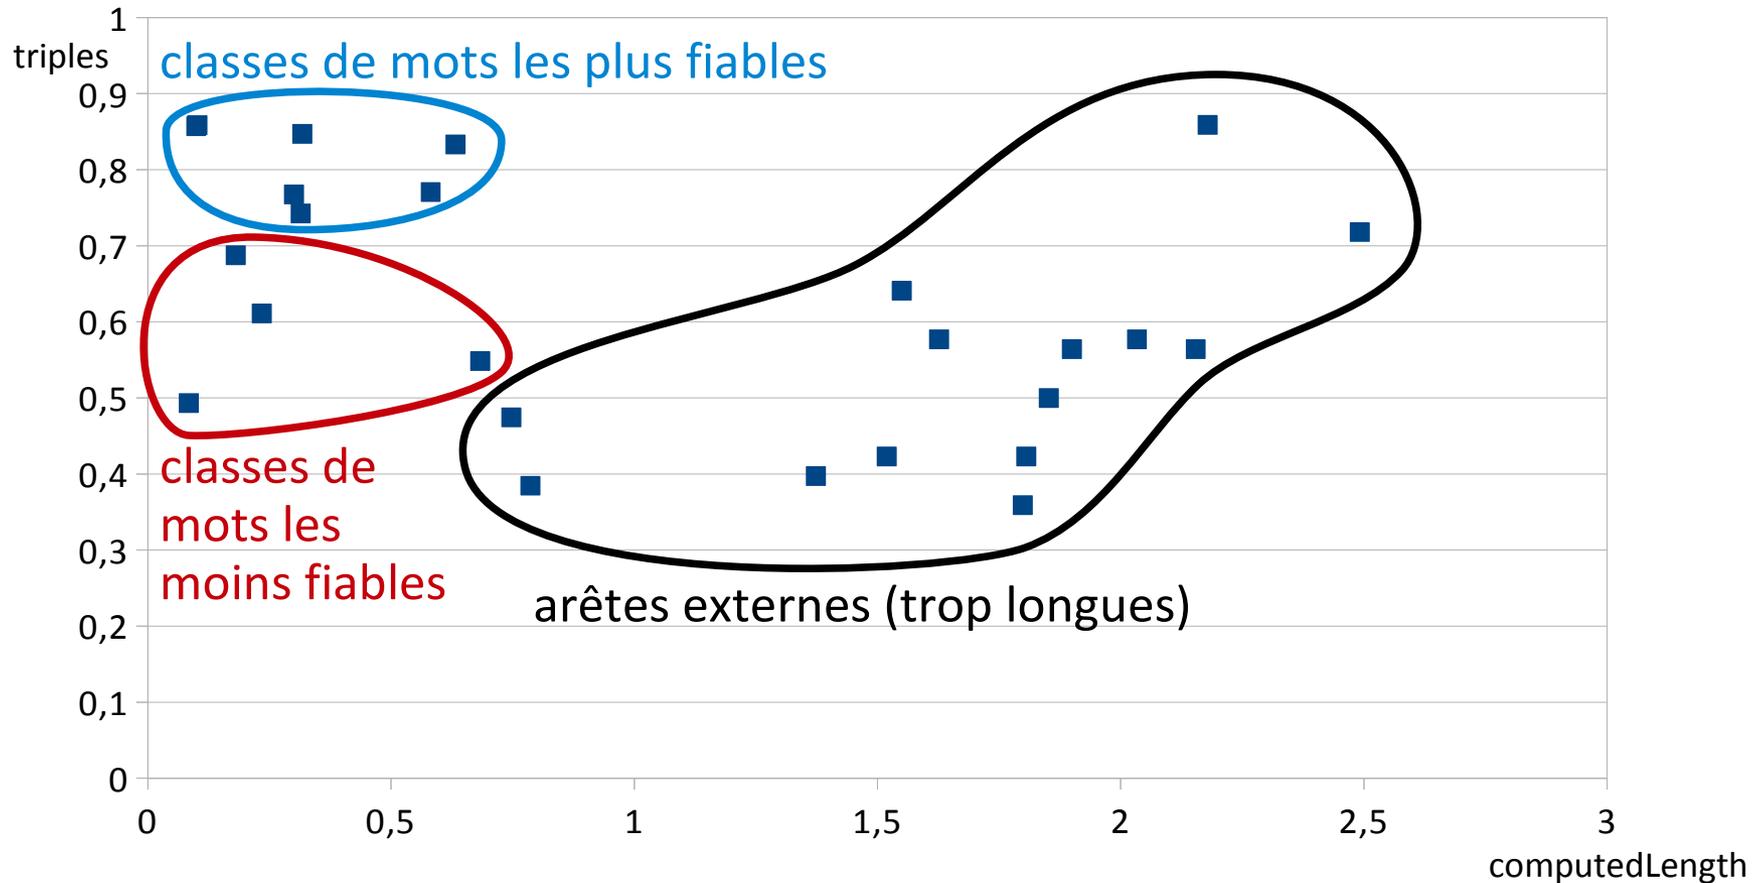
Les formules de longueur d'arête sont-elles **cohérentes** ?



Longueur selon la formule *triples* en fonction de la longueur originale de l'arête pour l'arbre de la famille de *art*

Scores de chaque formule

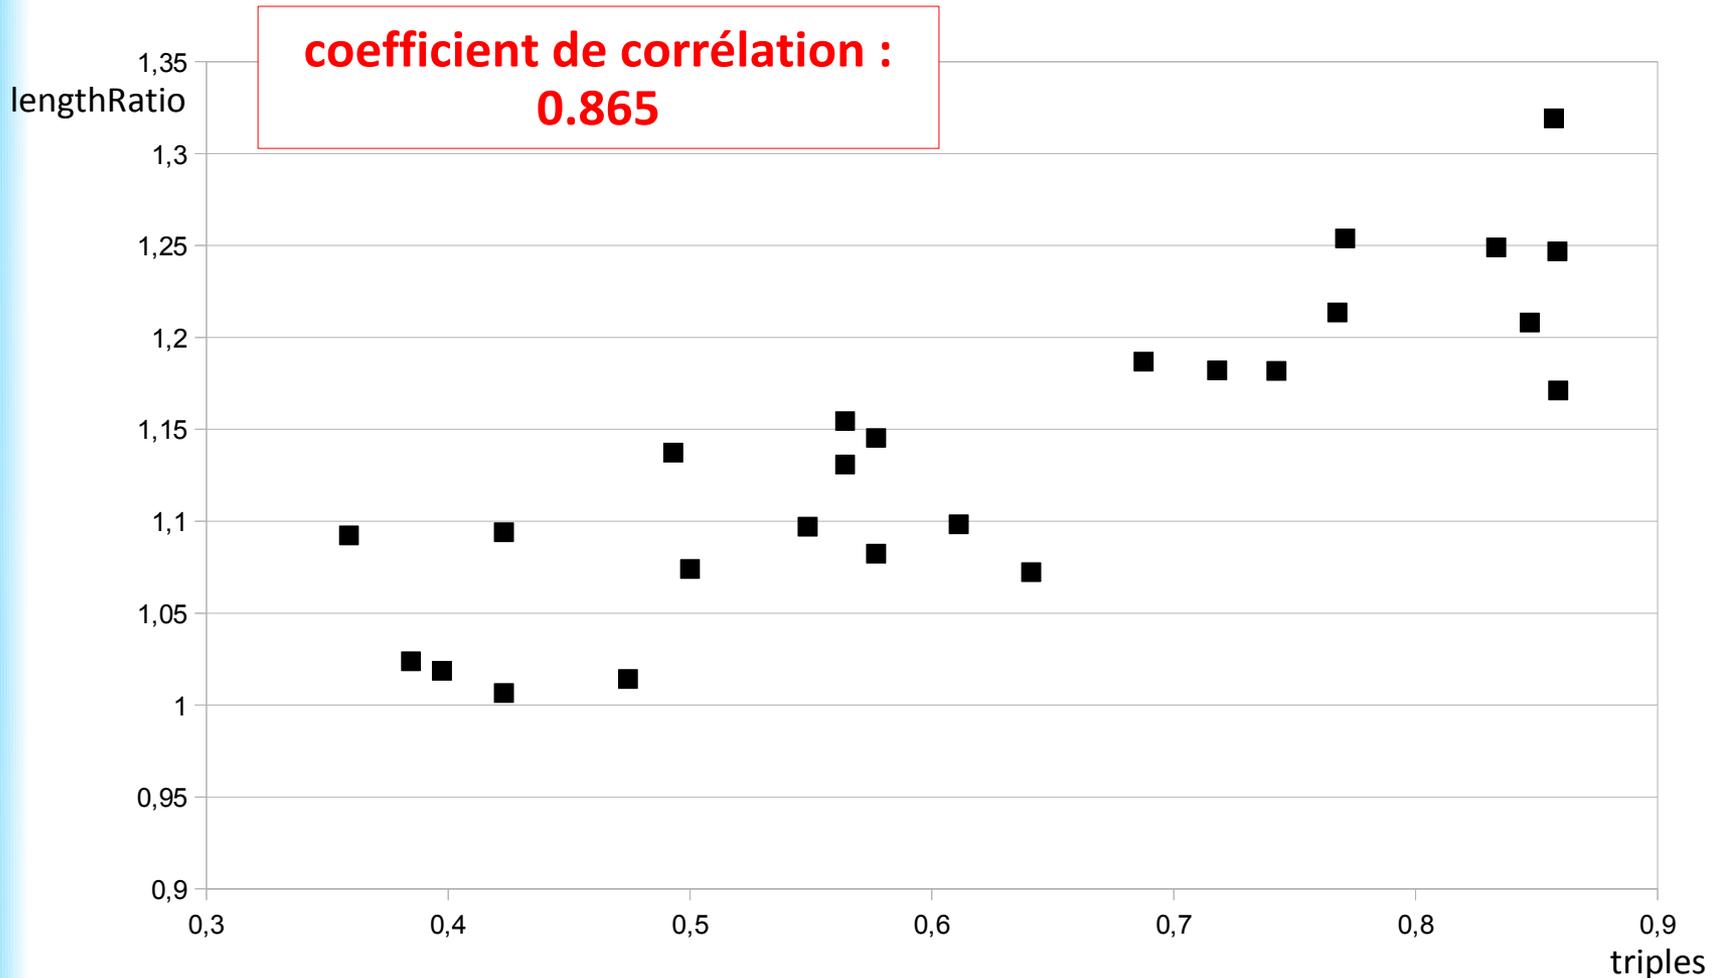
Les formules de longueur d'arête sont-elles **cohérentes** ?



Longueur selon la formule *triples* en fonction de la longueur originale de l'arête pour l'arbre de la famille de *art*

Scores de chaque formule

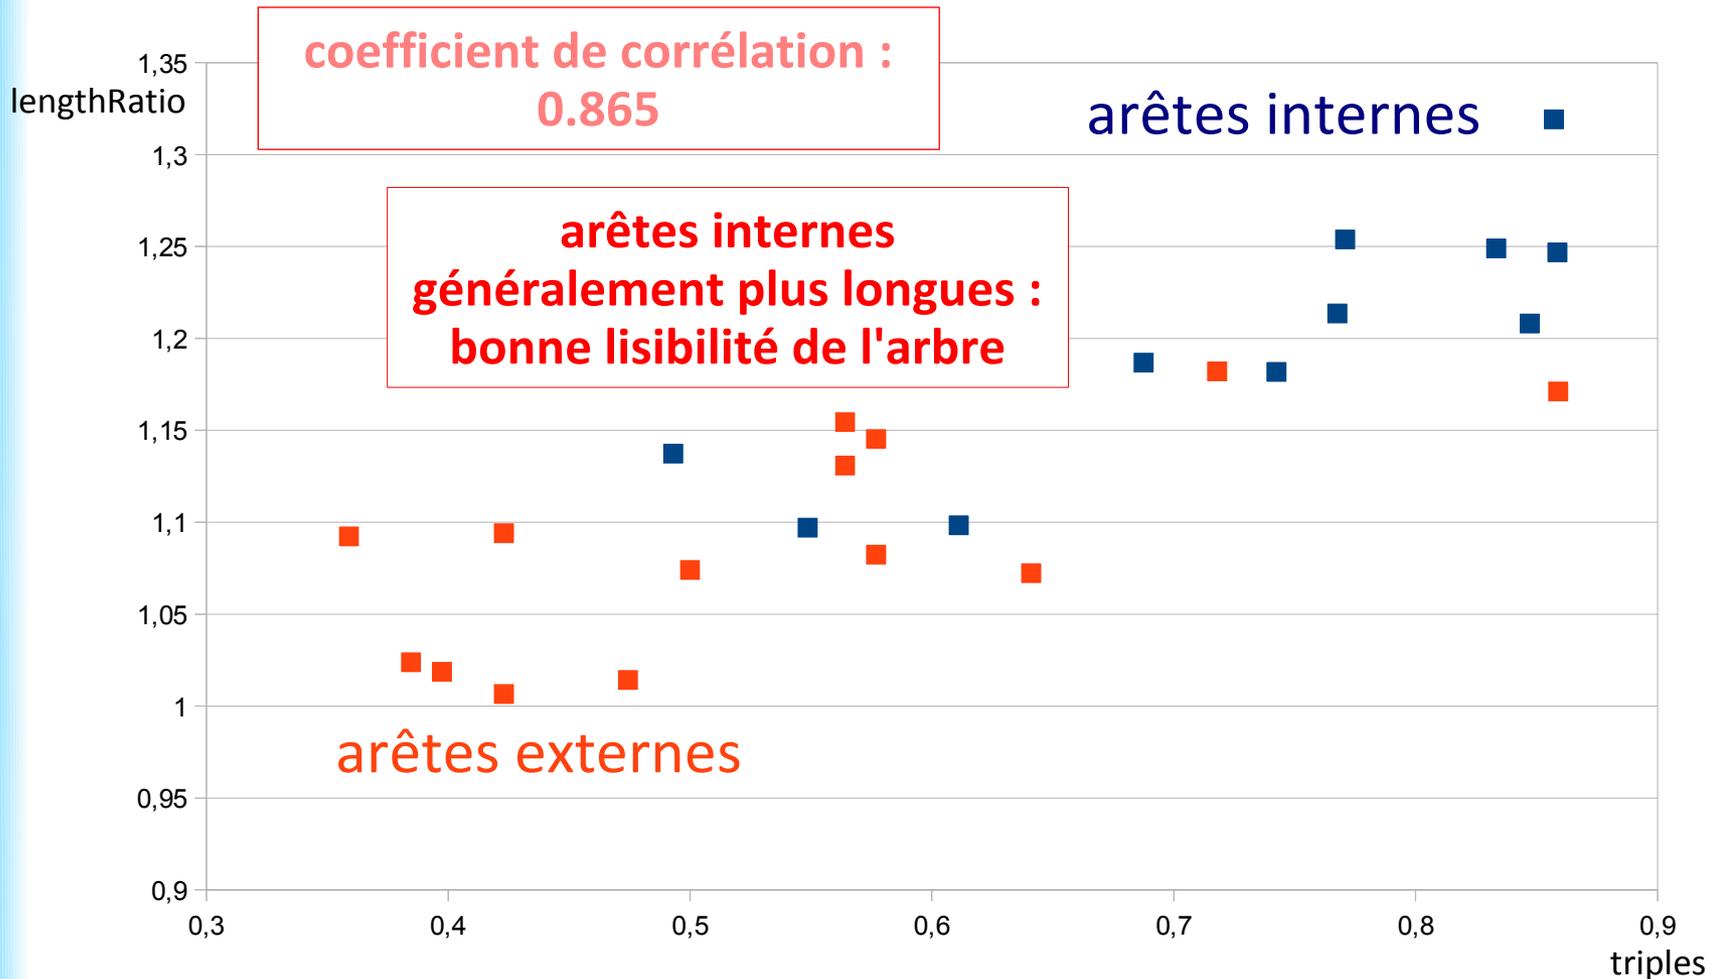
Les formules de longueur d'arête sont-elles **cohérentes** ?



Longueur selon la formule *lengthRatio* en fonction de celle selon la formule *triples* pour l'arbre de la famille de *art*

Scores de chaque formule

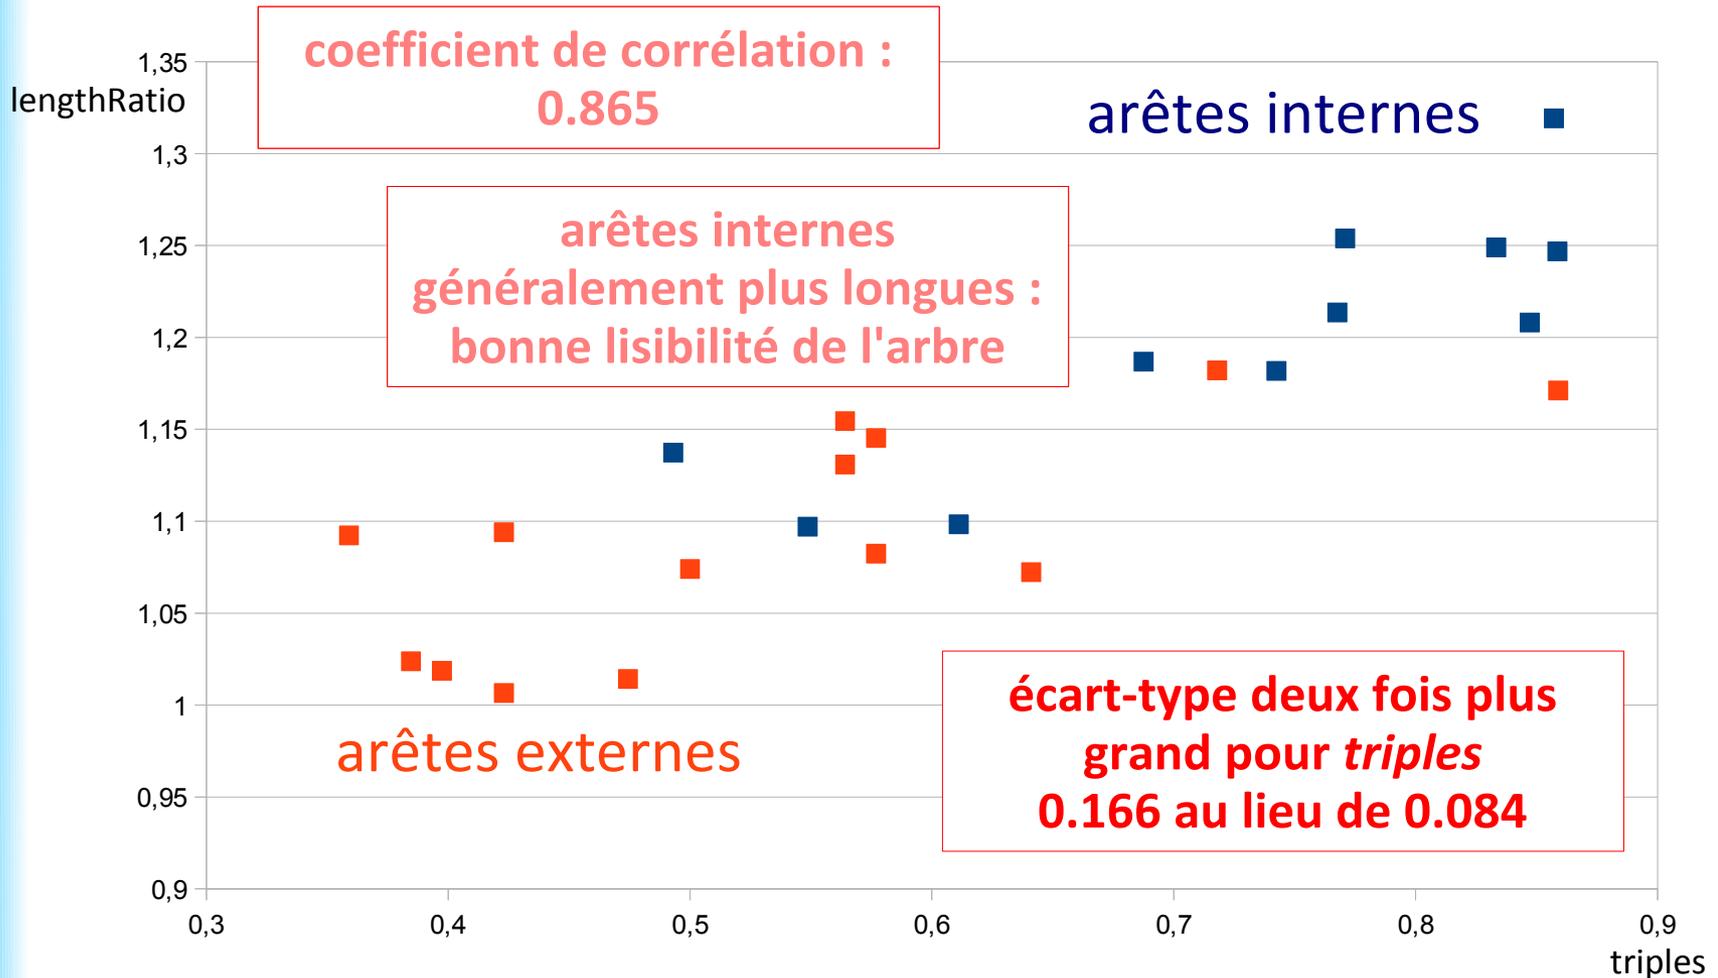
Les formules de longueur d'arête sont-elles **cohérentes** ?



Longueur selon la formule *lengthRatio* en fonction de celle selon la formule *triples* pour l'arbre de la famille de *art*

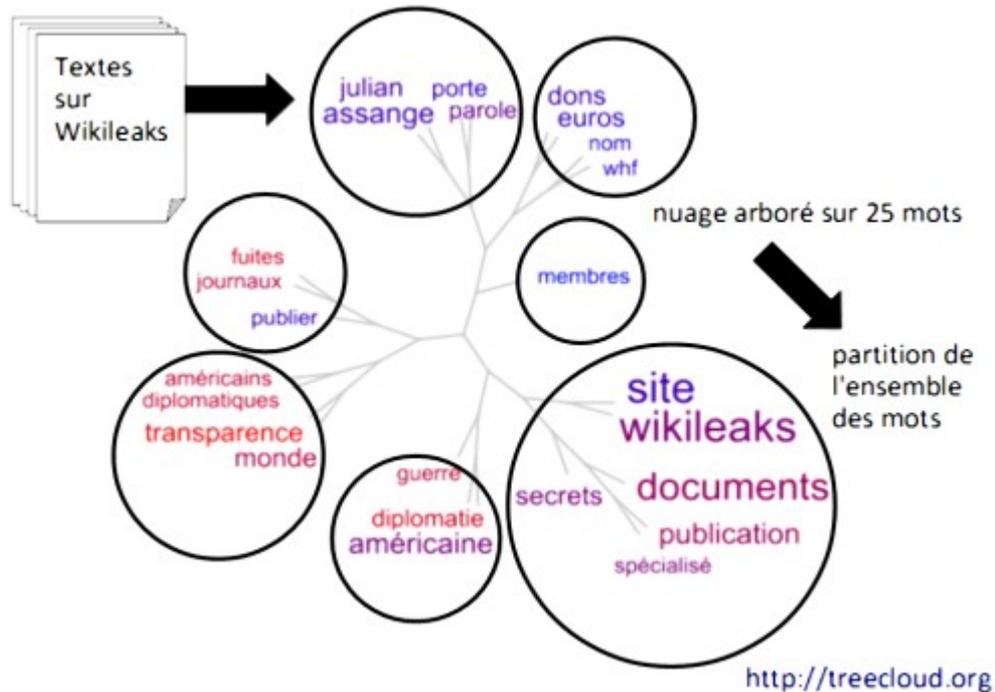
Scores de chaque formule

Les formules de longueur d'arête sont-elles **cohérentes** ?



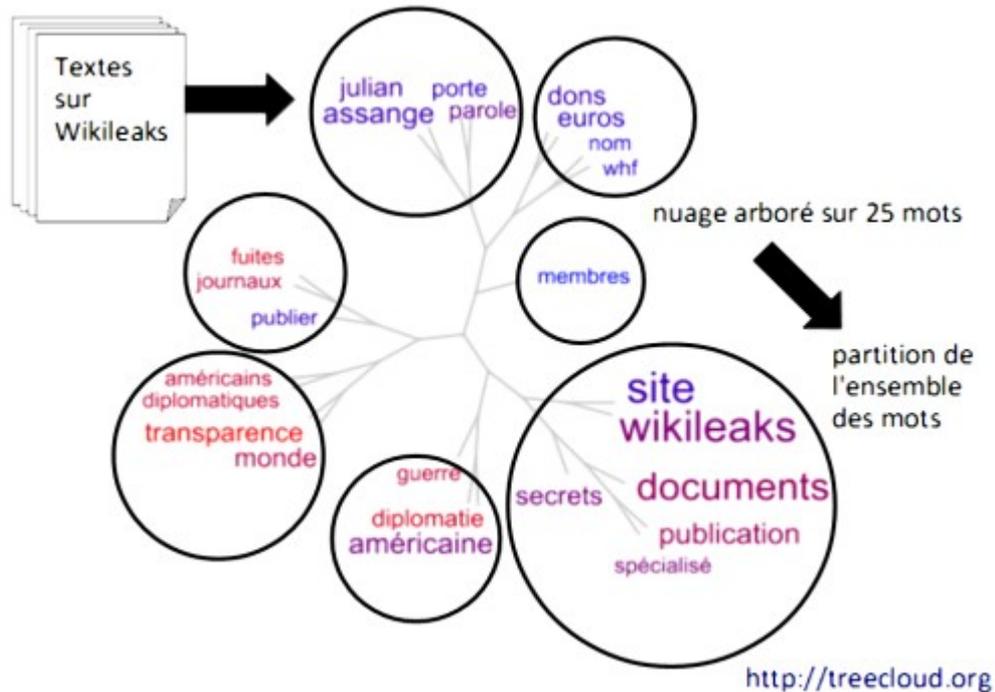
Longueur selon la formule *lengthRatio* en fonction de celle selon la formule *triples* pour l'arbre de la famille de *art*

Second protocole d'évaluation



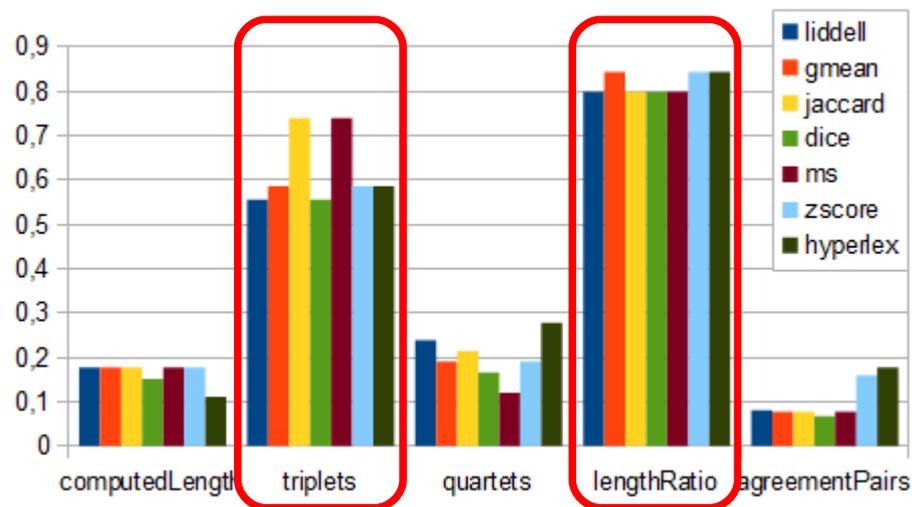
- Rédaction, par les étudiants de M1 de l'UPEMLV, de 10 textes respectant cette partition des mots en 7 classes
- Calcul des classes selon les différentes formules de longueurs d'arêtes, après découpage des 6 arêtes les plus longues

Second protocole d'évaluation



- Rédaction, par les étudiants de M1 de l'UPEMLV, de 10 textes respectant cette partition des mots en 7 classes
- Calcul des classes selon les différentes formules de longueurs d'arêtes, après découpage des 6 arêtes les plus longues

score Rand corrigé

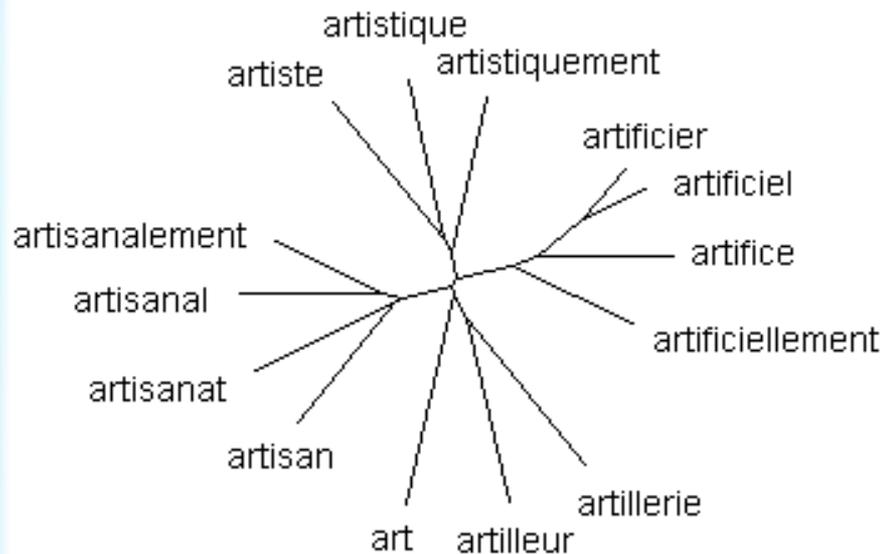


Calcul des longueurs d'arêtes

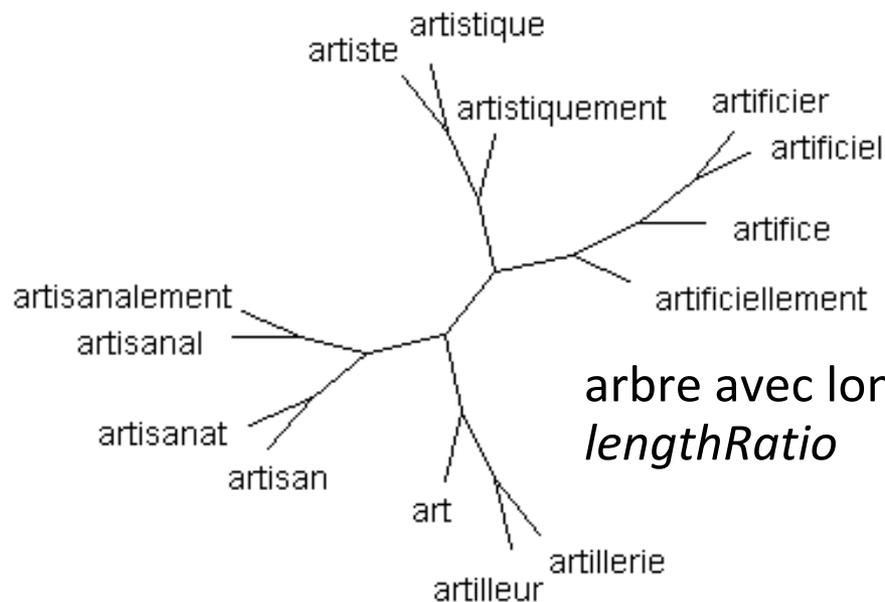
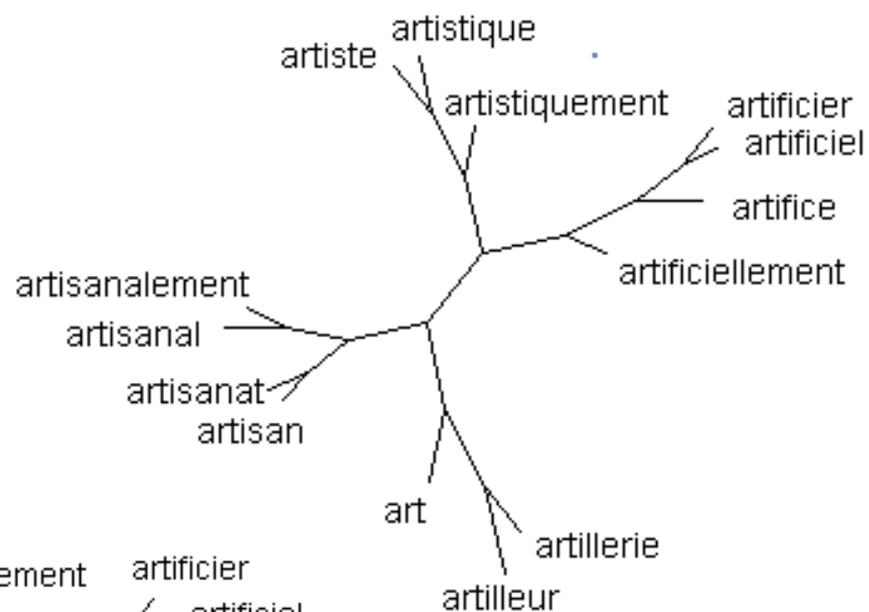
- Interprétation visuelle
- Formules de longueurs d'arêtes
- Protocole d'évaluation
- Résultats
- **Visualisations**

Visualisations

arbre original *computedLength*



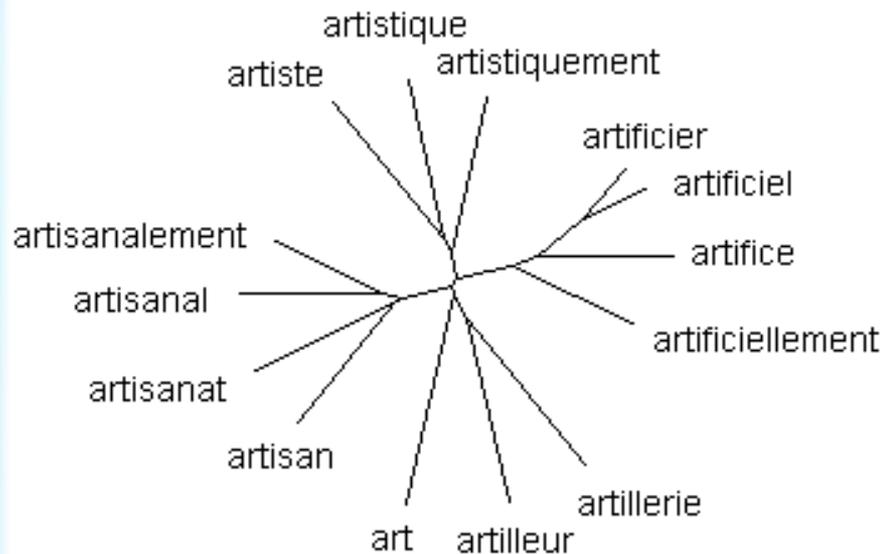
arbre avec longueurs d'arêtes *triples*



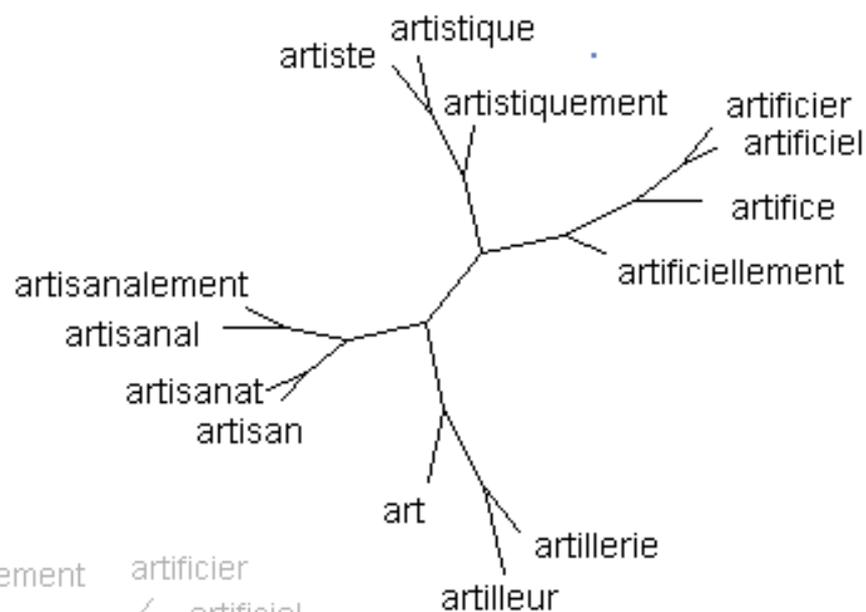
arbre avec longueurs d'arêtes *lengthRatio*

Visualisations

arbre original *computedLength*



arbre avec longueurs d'arêtes *triples*



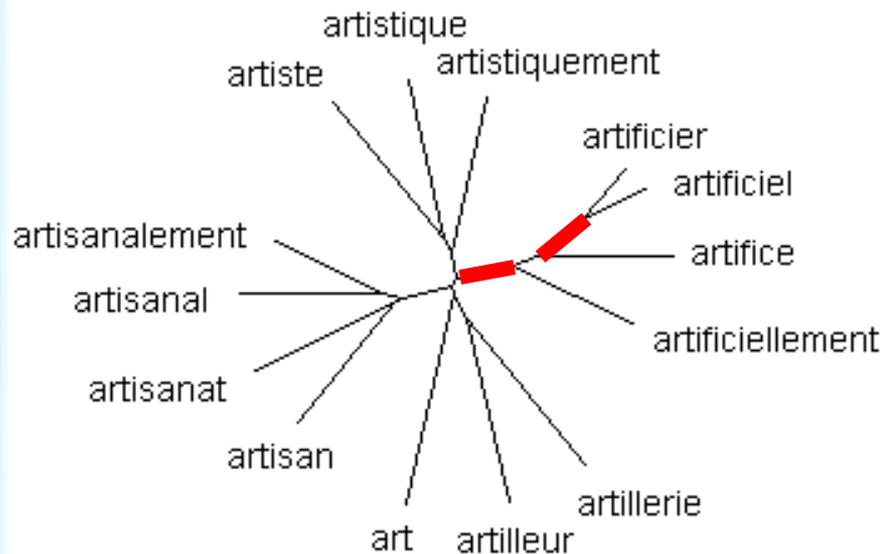
**variance trop faible des
longueurs d'arêtes !**

arbre avec longueurs d'arêtes
lengthRatio

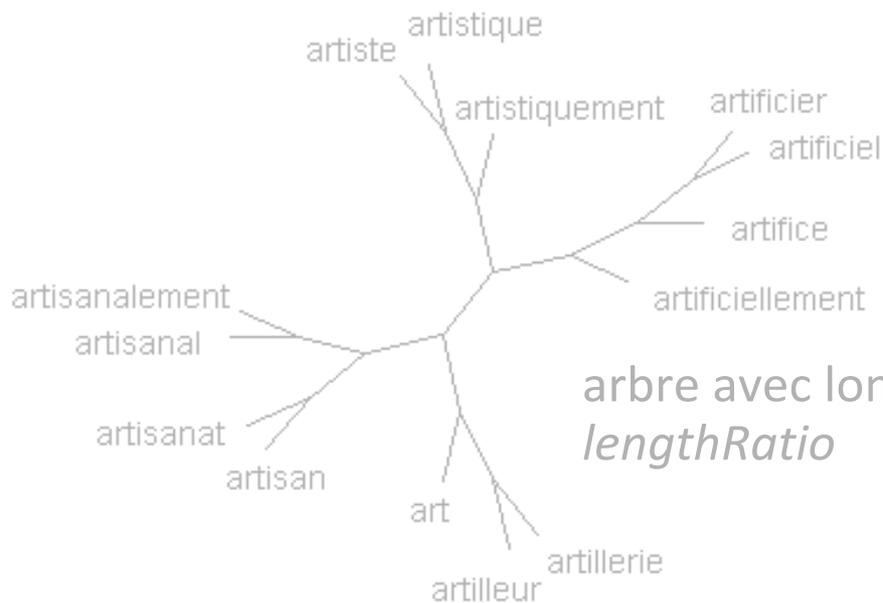
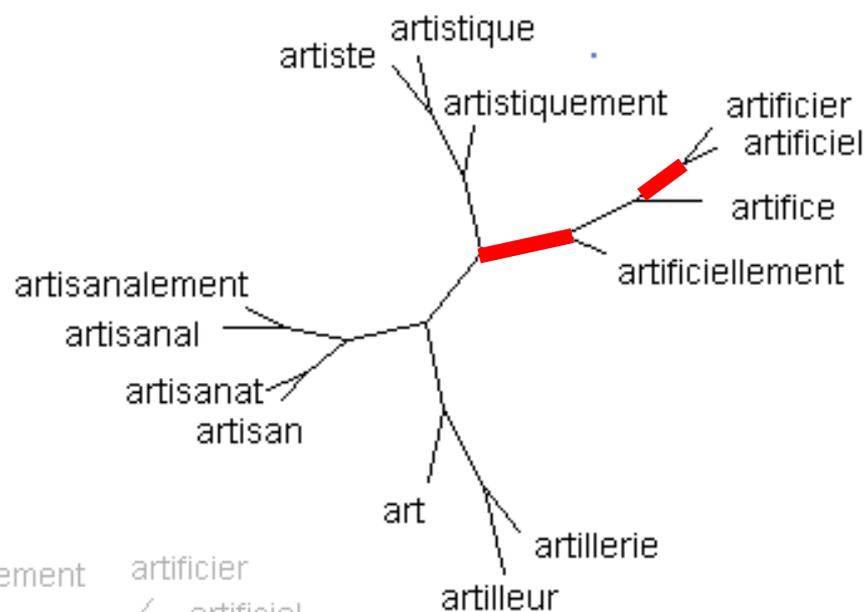


Visualisations

arbre original *computedLength*



arbre avec longueurs d'arêtes *triples*



arbre avec longueurs d'arêtes *lengthRatio*

Plan

- Nuages de mots et nuages arborés
- Caractéristiques du nuage arboré
- Utilisations du nuage arboré
- Construction d'un nuage arboré
- Évaluation de la robustesse de l'arbre
- Calcul des longueurs d'arêtes de l'arbre
- **Perspectives**

Perspectives

- intégration de la **visualisation en nuages arborés** avec longueurs de branches post-calculées :
 - dans les outils de textométrie existants
 - par des interfaces d'import/export adaptées
 - pour faciliter le retour au texte
- amélioration des méthodes de **construction de l'arbre**
 - transformée de Farris pour le calcul des distances
 - algorithme de Luong pour le calcul de l'arbre
- étude du lien entre les distances de cooccurrences extraits d'un corpus et les données de **Jeux de mots**
 - réseau de plus de 200 000 mots et 1 200 000 liens pondérés
 - cooccurrences dans la production spontanée de mots par rapport à un mot cible
 - cohérence avec les distances de cooccurrence calculées à partir d'un texte ?

Questions ?

Merci pour votre attention !

Coauteurs de ces travaux :



Nuria
Gala

Alexis
Nasr

Jean
Véronis

Jean-Charles
Bontemps



Alain
Guénoche



Delphine
Amstutz

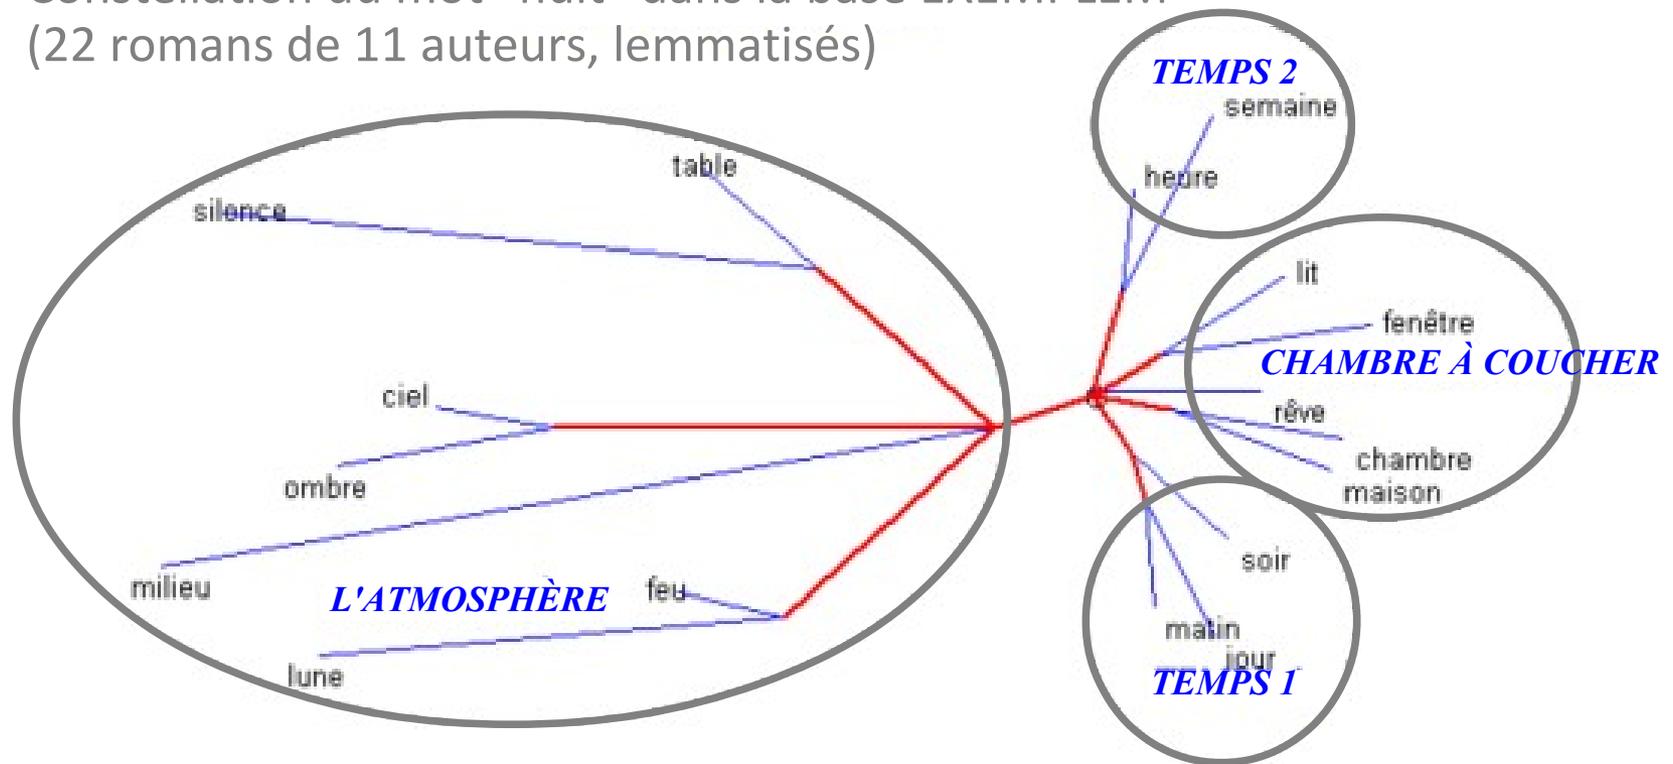


CELLF 17°-18°

Analyses arborées

Rapprochement des mots d'un texte selon leur degré de cooccurrence dans le texte

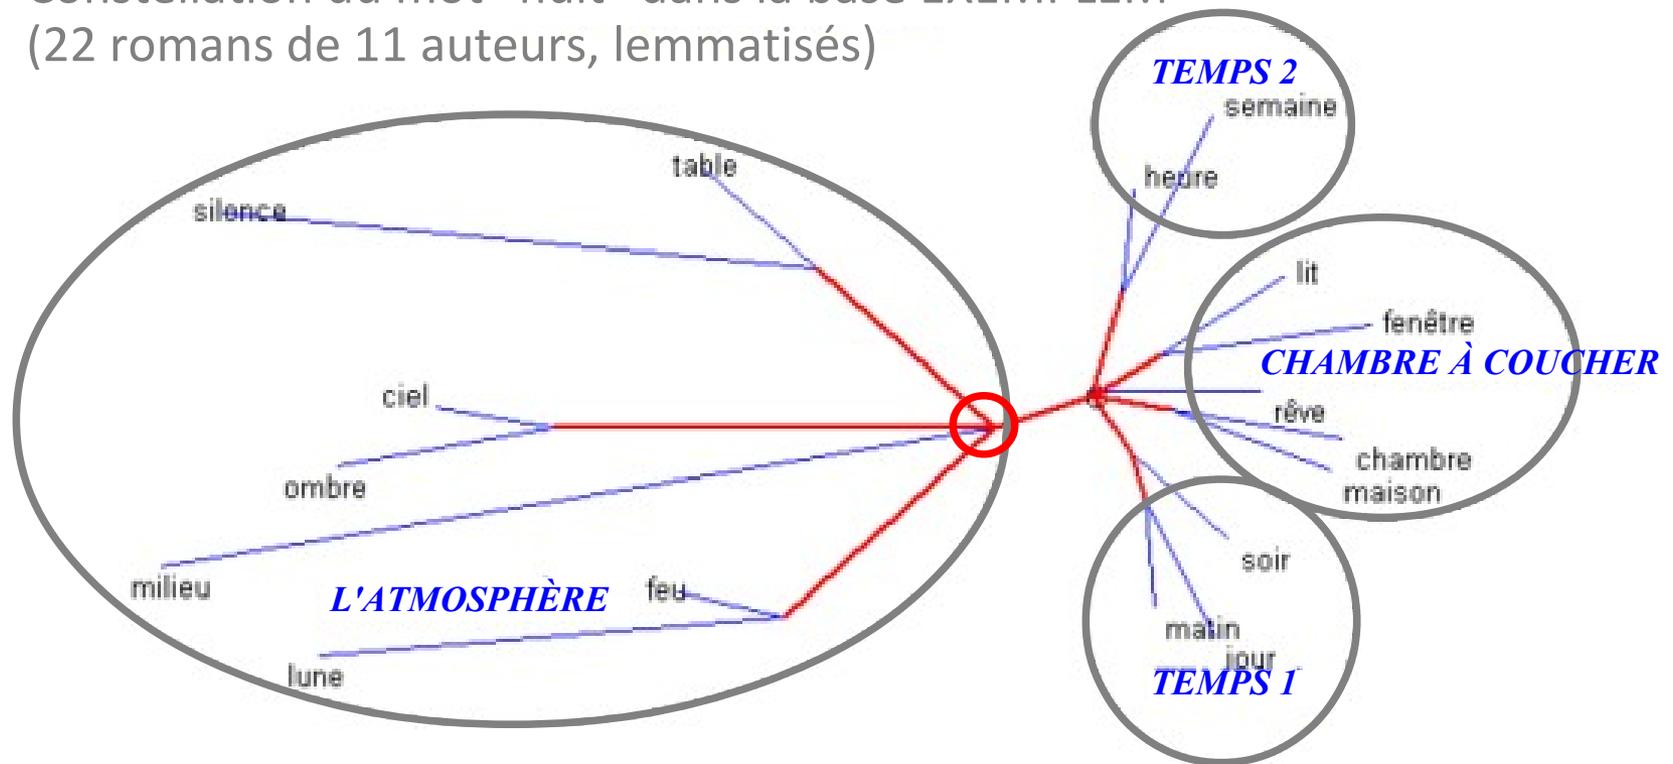
Constellation du mot "nuit" dans la base EXEMPLEM
(22 romans de 11 auteurs, lemmatisés)



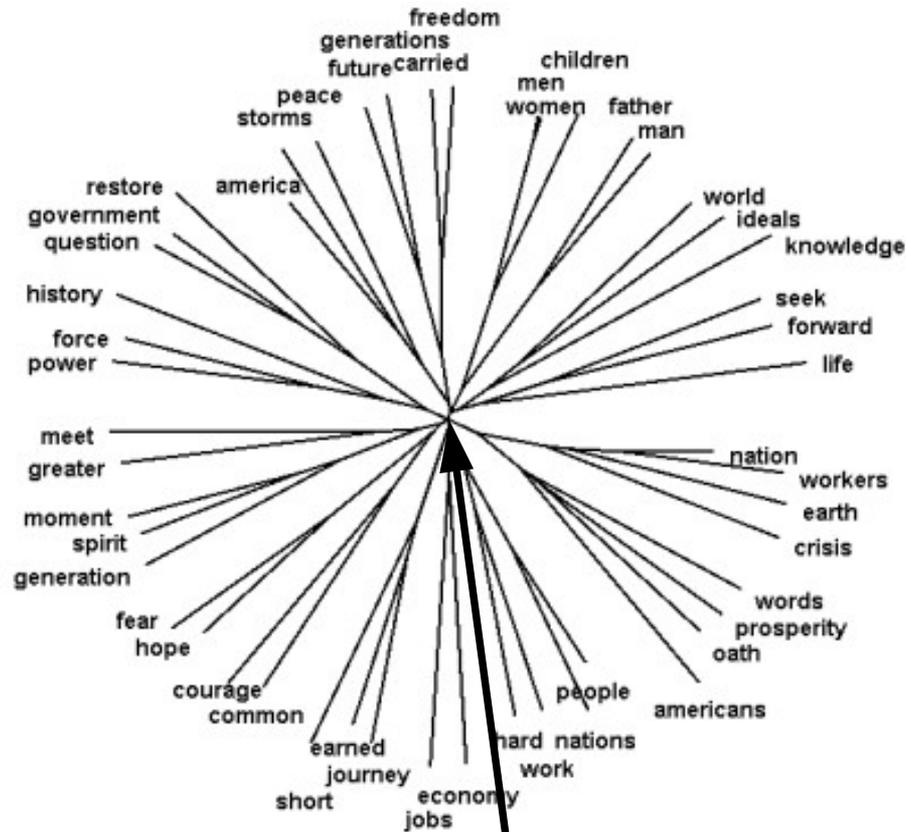
Analyses arborées

Rapprochement des mots d'un texte selon leur degré de cooccurrence dans le texte

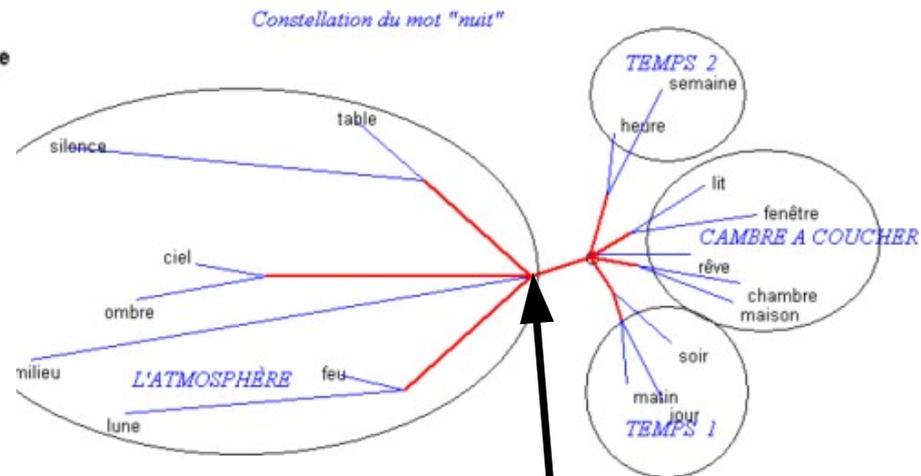
Constellation du mot "nuit" dans la base EXEMPLEM
(22 romans de 11 auteurs, lemmatisés)



Ultramétries, centre d'un arbre



“centre” de l'arbre



arbre “sans centre” (feuilles à gauche plus éloignées de ce point que celles à droite)