

Module de formation doctorale en informatique textuelle  
*Séance 4 - De la lexicométrie au traitement automatique des langues (TAL)*  
06/03/2021 – UPEC, Créteil

# ***TreeCloud pour la visualisation et l'analyse de données textuelles***


Philippe Gambette  
LIGM, Université Gustave Eiffel






# Le « nuage arboré », une information double

nuage de mots




arbre de mots





# Le « nuage arboré », une information double

nuage de mots



arbre de mots



Discours inaugural de Barack Obama

construit avec



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








# Processus de construction

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



# Calcul des proximités entre mots

Déplacement d'une « fenêtre glissante » tout au long du texte pour compter, pour chaque paire de mots  $u$  et  $v$ , leurs cooccurrences :



Nombre de cooccurrences entre  $u$  et  $v$

nombre de fenêtres	mot $u$ dans $S$	mot $u$ pas dans $S$
mot $v$ dans $S$	5	10
mot $v$ pas dans $S$	50	935


Exemple : texte de 991 mots avec 55 occurrences de  $u$  et 15 de  $v$ ,  $w=10$ ,  $s=1$



Score de cooccurrence entre  $u$  et  $v$

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

Evert,  
*Statistics of words cooccurrences*, Thèse, 2005



# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN

Données sur  
les feuilles

## MOTS

Position des mots


# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN

Distances fondées sur la différence entre les deux séquences (mutations, insertions, délétions)

Données sur les feuilles



Distances entre les feuilles

	A	B	C	D
A	0	2	5	6
B	2	0	5	6
C	5	5	0	3
D	6	6	3	0

## MOTS

Position des mots

Distances fondées sur la cooccurrence entre les deux mots


# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN

Distances fondées sur la différence entre les deux séquences (mutations, insertions, délétions)

Données sur les feuilles



Distances entre les feuilles

	A	B	C	D
A	0	2	5	6
B	2	0	5	6
C	5	5	0	3
D	6	6	3	0



*classification hiérarchique ascendante*  
*algorithme UPGMA*

Arbre



## MOTS

Position des mots

Distances fondées sur la cooccurrence entre les deux mots


# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN

Distances fondées sur la différence entre les deux séquences (mutations, insertions, délétions)

Données sur les feuilles



Distances entre les feuilles

	A+B	C	D
A+B	0	5	6
C	5	0	3
D	6	3	0



*classification hiérarchique ascendante*  
*algorithme UPGMA*

Arbre



## MOTS

Position des mots

Distances fondées sur la cooccurrence entre les deux mots

# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN


Distances fondées sur la différence entre les deux séquences (mutations, insertions, délétions)

## MOTS

Position des mots

Distances fondées sur la cooccurrence entre les deux mots

Données sur les feuilles




Distances entre les feuilles

	A+B	C	D
A+B	0	5	6
C	5	0	3
D	6	3	0



*classification hiérarchique ascendante*  
*algorithme UPGMA*

Arbre




# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN

Distances fondées sur la différence entre les deux séquences (mutations, insertions, délétions)

Données sur les feuilles




Distances entre les feuilles

	A+B	C+D
A+B	0	5,5
C+D	5,5	0



*classification hiérarchique ascendante*  
*algorithme UPGMA*

Arbre



## MOTS

Position des mots

Distances fondées sur la cooccurrence entre les deux mots

# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN


Distances fondées sur la différence entre les deux séquences (mutations, insertions, délétions)

## MOTS

Position des mots

Distances fondées sur la cooccurrence entre les deux mots

Données sur les feuilles




Distances entre les feuilles

	A+B	C+D
A+B	0	5,5
C+D	5,5	0



*classification hiérarchique ascendante*  
*algorithme UPGMA*

Arbre



# Arbres phylogénétiques et arbres de mots

## ESPÈCES

Séquences ADN


Distances fondées sur la différence entre les deux séquences (mutations, insertions, délétions)

## MOTS

Position des mots

Distances fondées sur la cooccurrence entre les deux mots

Données sur les feuilles




Distances entre les feuilles

	A	B	C	D
A	0	2	5	6
B	2	0	5	6
C	5	5	0	3
D	6	6	3	0




*classification hiérarchique ascendante  
algorithme UPGMA*

Arbre






# Le « nuage arboré », pour quoi faire ?




*Analyse textuelle*

# Le « nuage arboré », pour quoi faire ?




*Analyse textuelle*

# Le « nuage arboré », pour quoi faire ?




*Analyse textuelle*

# Exploration de corpus avec TreeCloud



# Exploration de corpus avec TreeCloud






# Méthode : interpréter les regroupements

## Dessiner des « patates »


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



Rencontre  
Docteurs &  
Entreprises




# Exploration de corpus avec TreeCloud



# Méthode : voisinage des mots fréquents


Amstutz & Gambette, JADT 2010



Nuage arboré globaux des 60 mots les plus fréquents dans *Cinna* de Corneille (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)

# Méthode : voisinage des mots fréquents

Amstutz & Gambette, JADT 2010




Nuage arboré globaux des 60 mots les plus fréquents dans *Cinna* de Corneille (distance Liddell, fenêtre de largeur 20), colorés chronologiquement (rouge au début, bleu à la fin)




# Méthode : voisinage des mots fréquents

Amstutz & Gambette, JADT 2010




Spécificités d'emploi de « Rome », « liberté » et « empire », chez les différents personnages de Cinna, selon Lexico3





# Méthode : voisinage des mots fréquents

Amstutz & Gambette, JADT 2010



# Méthode : voisinage des mots fréquents


Amstutz & Gambette, JADT 2010



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.


# Exploration de corpus avec TreeCloud



# 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 :






# Exploration de corpus avec TreeCloud






# Exploration de corpus avec TreeCloud








# Méthode : mots au début de chaque phrase



50 mots les plus fréquents parmi les débuts (10 premiers mots) des textes de pétitions de la catégorie « politique » du site lapetition.be.

Travaux menés avec Christine Barats, Anne Dister, Jean-Marc Leblanc et Marie Peres-Leblanc dans le cadre de l'ANR APPEL


# Méthode : mots au début de chaque phrase



50 mots les plus fréquents parmi les débuts (10 premiers mots) des textes de pétitions de la catégorie « politique » du site lapetition.be.

Travaux menés avec Christine Barats, Anne Dister, Jean-Marc Leblanc et Marie Peres-Leblanc dans le cadre de l'ANR APPEL

# Méthode : mots au début de chaque phrase




Relevé manuel :  
6,5% d'adresse aux décideurs des pétitions  
3,8% d'adresse aux signataires des pétitions


50 mots les plus fréquents parmi les débuts (10 premiers mots) des textes de pétitions de la catégorie « politique » du site lapetition.be.

Travaux menés avec Christine Barats, Anne Dister, Jean-Marc Leblanc et Marie Peres-Leblanc dans le cadre de l'ANR APPEL

# Exploration de corpus avec TreeCloud




# Nuages arborés des contextes de « étude »




Nuage arboré des 100 mots les plus fréquents dans les contextes (10 mots avant, 10 mots après) des mots de la catégorie "étude" dans un corpus de textes scientifiques et littéraires sur la science (projet AnimalHumanité)

# Nuages arborés des contextes de « étude »



Nuage arboré des 100 mots les plus fréquents dans les contextes (10 mots avant, 10 mots après) des mots de la catégorie "étude" dans un corpus de textes scientifiques et littéraires sur la science (projet AnimalHumanité)

# Exploration de corpus avec TreeCloud




# 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

Gambette & Martinez,  
*Texto!*, 2013




# 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




Gambette & Martinez,  
*Texto!*, 2013



# Exploration de corpus avec TreeCloud




# 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 cooccurents), construit par TreeCloud avec la formule Liddell, et des fenêtres glissantes de 20 mots

# Nuages arborés des contextes de « médecins »

Articles  
avec agence




Articles  
de journalistes




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 cooccurents), construit par TreeCloud avec la formule Liddell, et des fenêtres glissantes de 20 mots

# Exploration de corpus avec TreeCloud




# 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




*Nuage arboré des 100 mots les plus fréquents dans le « corpus Biodiversa » (projets de recherche avec financement européen sur la biodiversité), période 2008-2011, distance Liddel, fenêtre de 10 mots*

# Exploration de corpus avec TreeCloud



# 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

structure simple

facile à visualiser

moyennement robuste

faible densité d'information

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



information locale

structure complexe

difficile à visualiser

robuste

forte densité d'information

## projection des mots (Astartex, AFC sur Lexico, TextObserver, etc.)



information globale

structure complexe


facile à visualiser mais chevauchements

robuste

forte densité d'information

# Implémentations

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





# Interface web



Create! Downloads Gallery Credits FAQ  
Créer! Téléchargements Galerie 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 IFC'S'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](#)



[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



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

www.treecloud.org


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 tree cloud online

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

## Créez vos propres nuages arborés

### Documents :



If you use TreeCloud or this website, please mention Philippe Gambette et Jean Véronis: *Visualizing Text Classification as a Tool of Research, Proc. of the 10th International Conference on Intelligent Text Analysis (ICITA 2010)*, to appear, 2010 (supplementary material)

Pour des exemples d'utilisation de la visualisation de nuages de mots, voir Delphine Amstutz et Philippe Gambette: *Using Tree Cloud for Text Mining*, *Proc. of the 10th International Conference on Intelligent Text Analysis (ICITA 2010)*



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 :

[Texte extrait de <http://www.adoc-tm.com/2013rapport.pdf>]

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.



# Interface web



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

www.treecloud.org


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 r des nuages de mots disposés autour d'un ar Le premier nuage arboré est apparu sur le pouvez maintenant [créer les vôtres avec ce](#)

## Créez vos propres nuages arborés

### Documents :



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

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



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 :

[Texte extrait de <http://www.adoc-tm.com/2013rapport.pdf>]

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.



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





# 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://igm.univ-mlv.fr/~gambette/Re20090317.pdf>

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://igm.univ-mlv.fr/~gambette/Re20100611.pdf>

Philippe Gambette, Nuria Gala & Alexis Nasr (2012)

**Longueur de branches et arbres de mots**, *Corpus* 11:129-146  
<http://igm.univ-mlv.fr/~gambette/Re20120209.pdf>

William Martinez & Philippe Gambette (2013)

**L'affaire du Médiateur au prisme de la textométrie**, *Texto!* XVIII(4)  
<http://www.revue-texto.net/index.php?id=3318>

Philippe Gambette, Hilde Eggermont & 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>

Nadège Lechevrel & Philippe Gambette (2016)

**Une approche textométrique pour étudier la transmission des savoirs biologiques au XIXe siècle**, *Nouvelles perspectives en sciences sociales* 12(1):221-253  
<https://hal-upec-upem.archives-ouvertes.fr/hal-01408455>

Philippe Gambette, Tita Kyriacopoulou, Nadège Lechevrel & Claude Martineau (2017)

**Anatomie, animaux, vocabulaire de la vivisection : construire des ressources lexicales pour visualiser une thématique dans un corpus littéraire**, *Colloque AnimalHumanité, Expérimentation et fiction : l'animalité au cœur du vivant*, décembre 2016  
<https://hal-upec-upem.archives-ouvertes.fr/hal-01609198>

Claude Martineau (2017)

**TreeCloud, Unitex: increased synergy**, *ECLAVIT Workshop*, 24 novembre 2017  
<https://hal-upec-upem.archives-ouvertes.fr/hal-01702091>

## Tutoriel :

[https://docs.google.com/document/d/1OauE9EflJTtyVR3gM7ZPc3cGJ3-N0lq2ghPD5RNrb\\_YY/edit?usp=sharing](https://docs.google.com/document/d/1OauE9EflJTtyVR3gM7ZPc3cGJ3-N0lq2ghPD5RNrb_YY/edit?usp=sharing)

## Possibilités de réalisations numériques sur vos corpus :

- en ajoutant des liens sur les mots du nuage arboré, avec *TreeCloud Linker* :
  - Mots-clés des publications de l'UPEM :  
<http://treecloud.univ-mlv.fr/treecloud-linker/>
  - Collections du musée Fragonard de l'école vétérinaire d'Alfort :  
<http://treecloud.univ-mlv.fr/treecloud-linker/fragonard.html>
- en les chargeant dans *TreeCloud Corpus* :
  - *Vœux présidentiels* rassemblés par Jean-Marc Leblanc, 1960-2018  
<http://treecloud.univ-mlv.fr/treecloud-voeux/>
  - *Lettres républicaines* de Daniel Stern (pseudonyme de Marie d'Agoult), 1848  
<http://treecloud.univ-mlv.fr/treecloud-corpus/lettres-republicaines/>

# Prétraitements divers

Utilisation de formules de tableur pour pré-traiter des corpus :

- **Données d'enquête :**

- ajouter “ a a a a a a a a ” à la fin de chaque réponse à une question ouverte, pour éviter que les mots d'une réponse soient considérés proches des mots de la réponse suivante (si *fenêtre glissante* paramétrée à 10 mots).
- possibilité de filtrer les lignes pour sélectionner uniquement les réponses d'un échantillon donné.

- **Données d'entretien :**


- mettre le nom du locuteur sur la ligne précédant ses paroles
- possibilité d'utiliser une formule pour créer une colonne avec le nom du locuteur sur chaque ligne
- Filtre pour sélectionner seulement les paroles d'un locuteur

→ consulter et copier ou télécharger [ce document tableur partagé](#)

# Prétraitements de textes obtenus par OCR

Rechercher/remplacer (par exemple avec [Notepad2](#)) :

- remplacer les apostrophes courbes : remplacer "''" par ""
- supprimer les références aux notes de fin de texte, en utilisant les “expressions régulières”, remplacer "[0-9]+[" par "" : un caractère "[" suivi d'un chiffre, éventuellement répété, suivi d'un caractère "]" .



# Prétraitements de textes obtenus par OCR

Aide automatique à la détection des césures de fin de ligne :

**coupeCésure**

<http://igm.univ-mlv.fr/~gambette/text-processing/coupeCesure/>

Code couleur :


- mot dont la césure a été supprimée car trouvé en entier dans le dictionnaire
- mot pour lequel le trait d'union a été gardé

## Texte obtenu après remplacements...

Quand vous y ferez quelque réflexion, je crois  
que vous trouverez que j'ai raison, et que si je fusse retournée , je rendois mon voyage inutile par être trop  
court. Pour mon fils et sa femme, ils sont ravis de passer ici jusqu'au carême avec moi : en ce temps-là j'irai  
à Rennes par complaisance pour eux, parce que ce  
temps est plus triste que l'hiver à la campagne : peut-être que ce projet changera, il ne faut point voir de si  
loin. Ge qui est sûr, ma fille, c'est que l'air d'ici est fort  
bon; vous lui faites tort de le croire mauvais. Il fait  
depuis plus de deux mois le plus beau temps du monde,  
des chaleurs dans la canicule, un mois de septembre


# Extraction de contextes avec VoyantTools

- Charger le corpus dans <http://voyant-tools.org> (ex. : [corpus des voeux présidentiels](#), de Jean-Marc Leblanc ; sélection de plusieurs fichiers txt sur le disque dur avec le bouton « Charger »)
- Charger les **contextes** de “religion”, par exemple, dans le cadre en bas à droite, puis exporter avec le bouton entouré en rouge :



Document	Gauche	Terme	Droite
2) voeux1961D...	ait jamais existé. Aider cette	europe	rassemblée, et l'Amérique sa fille
3) voeux1962D...	Moscou sur notre continent. En	europe	, l'union qui se dessine entre
3) voeux1962D...	sera celle du regroupement en	europe	et de la modernisation de

- Dans la **fenêtre d'export**, choisir “Export Current Data”, “export current data as tab separated values (text)”
- Coller dans un **document tableur**
- Sélectionner uniquement les contextes gauches, droits, ou les deux, pour les charger dans TreeCloud.  
→ Visualiser les fréquences d'une liste de mots  
**VisuLexique**



**Export**

a URL for this view (tools and data)

Export View (Tools and Data)

Export Current Data

export current data as HTML

export current data as tab separated values (text)

export all available data in JSON

export all available data as tab separated values (text)