Textométrie & IRaMuTeQ

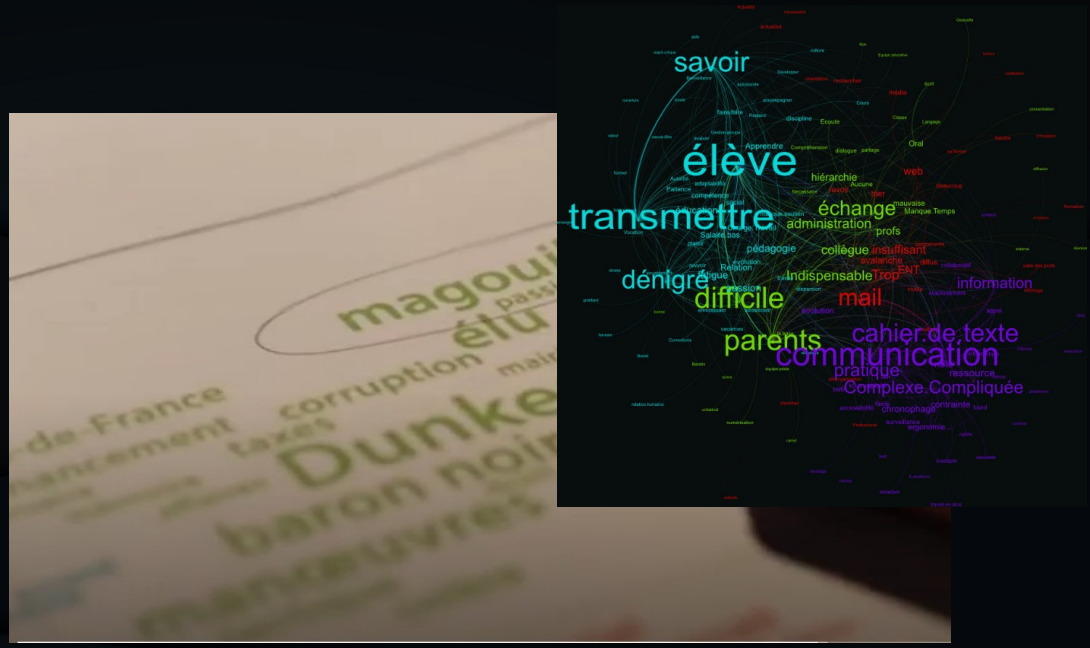

Lucie Loubère

Le 07 octobre 2026 – Urfist Rennes

- 1 – petite intro
- 2 – le corpus
- 3 – entrée en lexico
- 4 – vocabulaire et préparation du corpus
- 5 – analyses

1. Petite introduction

Tour de table : quelle image représente le plus/mieux votre étude ?



Le logiciel Iramuteq

- Interface pour R d'Analyses Multidimensionnelles de Texte et de Questionnaires.
- Développé par P. Ratinaud (Lerass) dans le cadre du LabEx SMS (Toulouse)
- Logiciel libre et gratuit développé sur la base de logiciels libres
  - Python http://www.python.org
  - R (R Development Core Team, 2009): http://r-project.org
  - Lexique 3 (New, Pallier & Ferrand, 2005): http://lexique.org

Quelques autres logiciels texto...

- TXM (Université de Lyo
- Hyperbase (Etienne Brunet, Université de Nic
- Lexico 5 (André Salem, Université de Paris
- DTMVic (Ludov(ic Lebart Télécom Paris-Tech)
- Gargantext (ISCIF, https://gargantext.or
- Alceste® (Max Reinert, société Image) €
- Sphinx® (société le sphynx) €

2. Le corpus

Le corpus… point de vue technique

- Vu comme un ensemble
  - 1 fichier .txt
  - Délimitation de chaque texte par une « ligne étoilée » avec métadonnées

    **** *variable_modalité *genre_F *region_occi
- Pourra être découpé une fois ouvert dans iramuteq par:
  - Modalité d’une variable,
  - Thématique,
  - Concordancier d’un ou plusieurs mots,

Pour quels types de corpus…

- Des discours longs (livre, articles, entretiens...)
- Des discours brefs (tweets, questions ouvertes, focus-groups...)
- Des corpus de toute taille :
  - Quelques entretiens, un discours
  - Grand débat national (167 853 085 occurrences)
    - 111 x *À la recherche du temps perdu*
    - 39 000 x le l'allocution d'E.Macron du 9 novembre 2021

CC BY NC ND

Un format spécifique...

Le corpus

**** *source_la_tribune_france *date_2023-03-31 *am_2023-03 *annee_2023

Contre le « ChatGPT bashing » Gontran Peubez OPINION. En plein polémique sur les craintes du monde de la recherche sur le manque de garde-fous autour de cette nouvelle technologie, pour l'instant maîtrisée uniquement par une poignée de géants de la tech, Gontran Peubez (Partner Data & IA, Onepoint) fait une analyse des Large Language Models (LLM). Gaspard Koenig a écrit que « sur le plan épistémologique ChatGPT constituait une indéniable régression dans la production de la connaissance ». ChatGPT , dont il n'est plus nécessaire de présenter les fonctionnalités synthétise et restitue selon une syntaxe statistique une information issue de millions de pages Internet [illegible] à l'aide de Machine Learning spécifique, appelé Modèle de Langue. Restituer de l'information et non produire de la connaissance. L[illegible]t avancé par d'autres de ses détracteurs : sa propension à reproduire des biais et même à articuler sans sourciller d[illegible]

Lignes étoilées

**** *source_la_tribune_france *date_2023-03-24 *am_2023-03 *annee_2023

Données personnelles : quelles leçons retenir des premiers déboires de ChatGPT ? François Manens Coup sur coup, le chatbot d'OpenAI, ChatGPT , a subi deux incidents relatifs aux données personnelles. Heureusement, les bugs ont rapidement été corrigés et les conséquences semblent limitées. Néanmoins, ces ratés de la startup star de l'intelligence artificielle peuvent servir de piqûre de rappel : il ne faut pas donner d'information sensible à ChatGPT ou à ses concurrents. Comme un avertissement. Lundi, ChatGPT est resté en maintenance pendant plusieurs heures, car l'entreprise réparait en urgence un dysfonctionnement étrange. Lorsque certains utilisateurs se connectaient à leurs comptes, ils voyaient dans leur historique (situé dans une colonne à gauche de l'outil) les titres de conversations qui n'étaient pas les leur, mais celles d'autres utilisateurs. Lire aussiPourquoi vos données devront alimenter demain ChatGPT et autres IA (lien : https://www.latribune.fr/opinions/tribunes/pourquoi-vos-donnees-devront-alimenter-demain- chatgpt -et-autres-ia-955991.html) Heureusement, la fuite se limitait à cette information. Elle ne révélait ni le contenu des conversations avec le bot, ni l'identité de l'utilisateur. L'entreprise s'en sort ainsi à moindre mal. Quant aux utilisateurs, l'incident apparaît comme une piqûre de rappel : toute information intégrée aux discussions peut fuir en cas d'incident. C'est pourquoi OpenAI lui-même (lien : https://help.openai.com/en/articles/6783457- chatgpt -general-faq) conseille aux utilisateurs de ne pas donner d'informations sensibles à ChatGPT .

3. Entrée en lexicométrie

Analyses textuelles en lexico

Analyse de discours manuelle

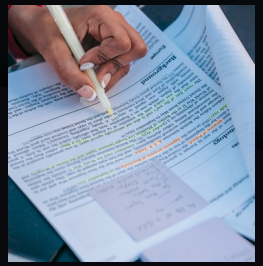

corpus

Interprétation

Commentaires

Interprétation

Extraits
Du corpus

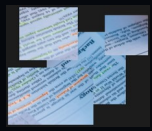

Interprétation

Analyse de discours textométrique

Codage





Réorganisations
Mesures
Statistiques
Autres...



Fouille

résultat
s

CC BY NC ND

Variation d'une Diapo d'André Salem

Une toute première approche le Zipf

La fréquence d'un mot est liée à son rang d'arrivé dans le texte :

- Plus il apparaît tôt dans le texte, plus il aura d'occurrences (le nombre de fois qu'il apparaît).
- Plus il apparaîtra tard dans le texte, moins il aura d'occurrences.

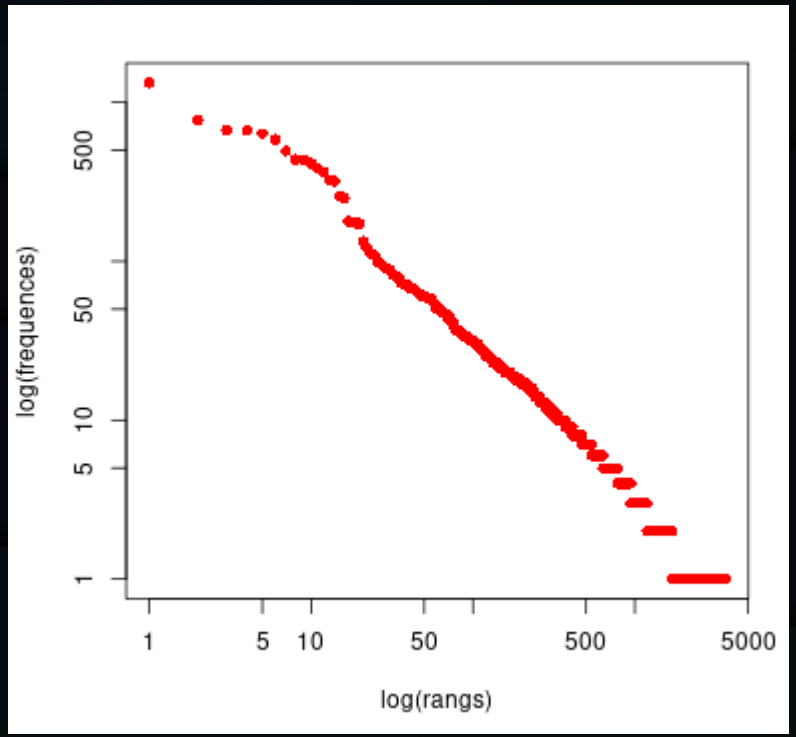

George Kingsley Zipf (1902, 1950)

Un rapport global/macro

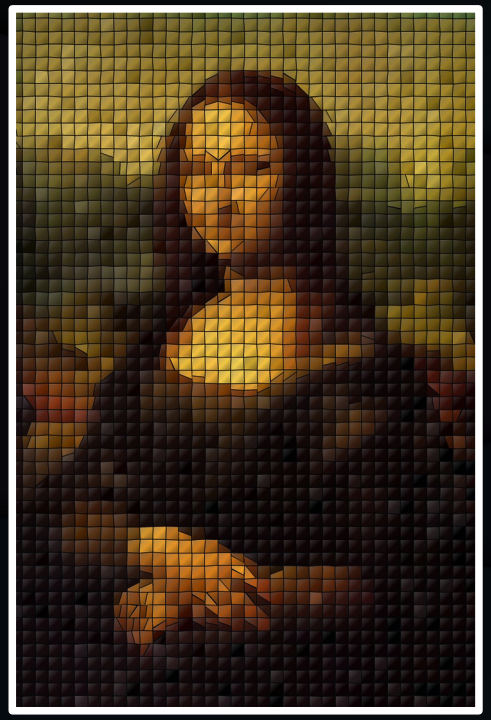

Pixellisation de la Joconde (Léonard de Vinci)

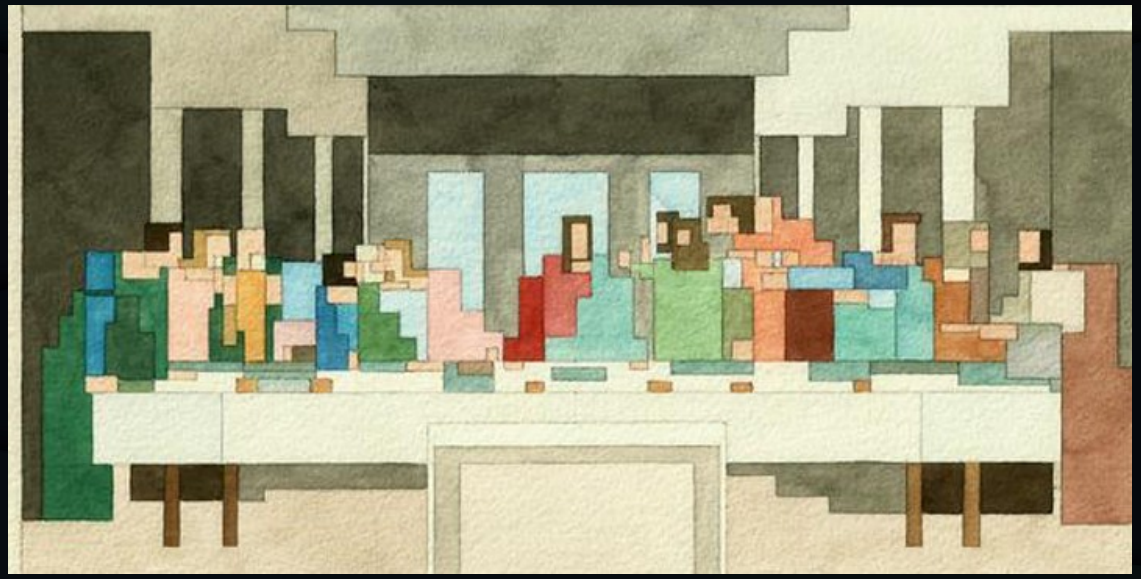

Variation de La cène (Léonard de Vinci) par Adam Lister

Un exemple d’un corpus de 2023...

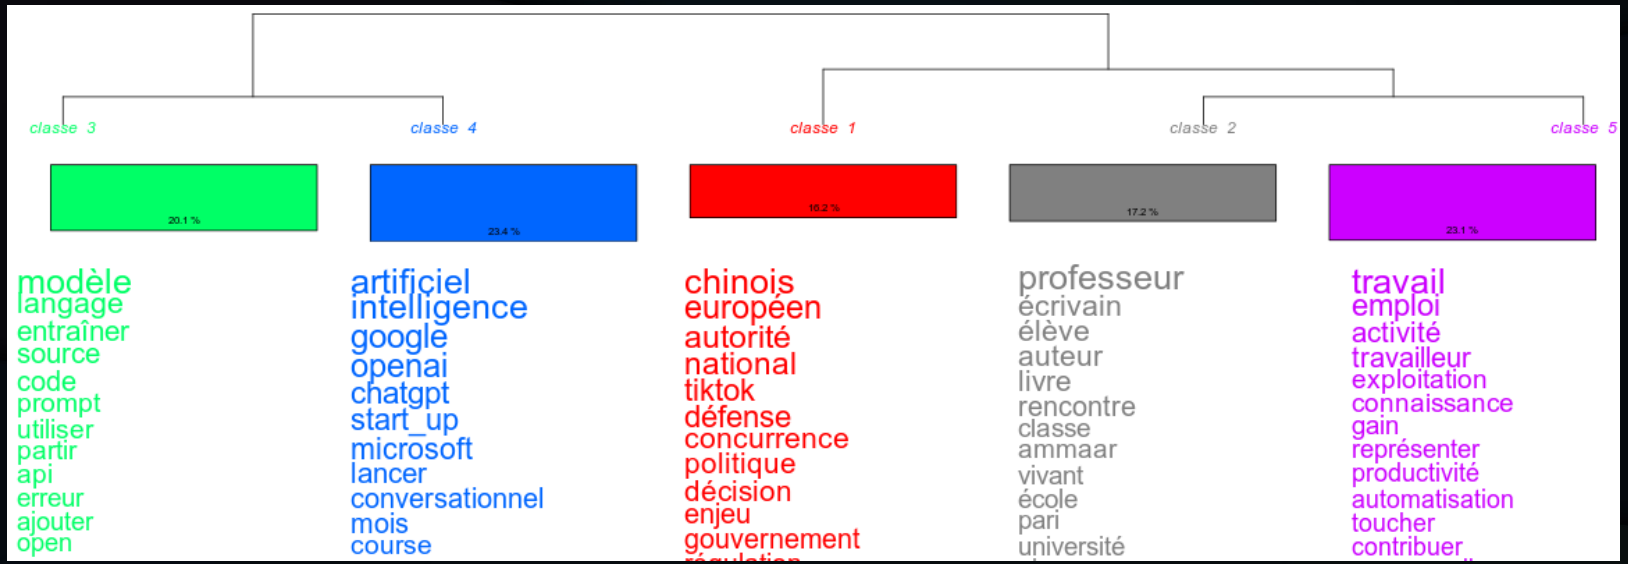

Les stats textuelles une fraction de l'information...

Supposons (...) que
l'on étudie les histogrammes des **longueurs d'ondes** correspondant aux couleurs d'un tableau de Rembrandt (pour chacun des pixels d'une reproduction).

Il va de soi que l'on utilise une **fraction dérisoire** de l'information contenue dans l'image d'origine.

Il est cependant possible que la forme de l'histogramme (ou d'une fonction plus élaborée des mêmes mesures et données de base) **permette de distinguer** un Rembrandt d'un Rubens ou d'un Van Dyck » (p.21).



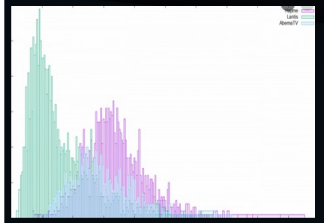

≠

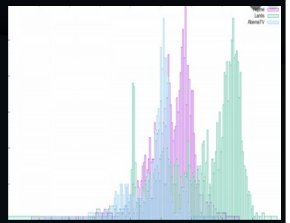



Le Syndic de la guilde des drapiers (Rembrandt)

Triple portrait de Charles 1er (Van Dyck)

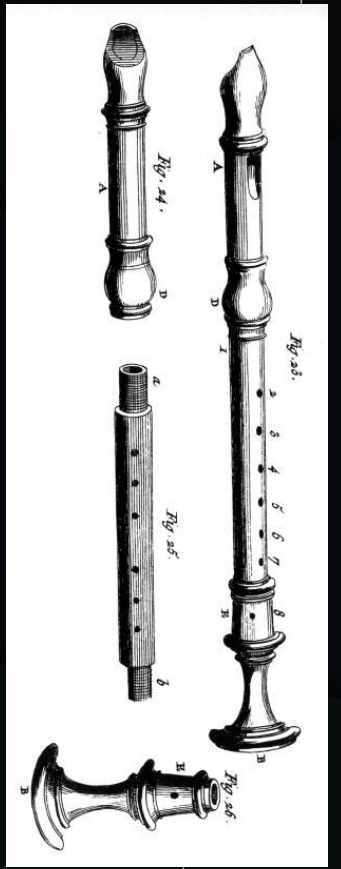

Lebart & Salem (1994)

Pour synthétiser… lexico = statistiques

Les questions que se donne la statistique lexicale sont les suivantes :

« quels sont les textes les plus **semblables** en ce qui concerne le **vocabulaire** et la **fréquence** des formes utilisées ?

Quelles sont les formes qui **caractérisent** chaque texte, par leur présence ou leur absence ? » (Lebart & Salem, 1994, p.135).

Retour sur le corpus

- Statistiques = qu’est-ce qui se différencie d’un ensemble
  - c’est quoi l’ensemble ?
  - questions sur l’homogénéité du corpus (même logique qu’une population)
  - Questions sur métadonnées (ligne étoilée), risque de biais :
    - paradoxe simpson
    - Périmètre des données
    - ...

4. Vocabulaire et préparation du corpus

Un peu de vocabulaire...

- **Forme** : une suite de caractères délimités par des séparateurs (espace, retour à la ligne…)
- **Formes actives** : les noms, les adjectifs, les adverbes, les verbes
- **Occurrence** : apparition d'une forme
- **Lemme** : racine grammaticale d'une forme (manger est le lemme de mangeons)
- **Hapax** : forme qui n'apparaît qu'une fois

Préparation automatique du corpus 1/3

1 – Segmentation du corpus

2 textes

**** *source_la_tribune_france *date_2023-03-31 *am_2023-03 *annee_2023

Contre le « ChatGPT bashing » Gontran Peubez OPINION. En plein polémique sur les craintes du monde de la recherche sur le manque de garde-fous autour de cette nouvelle technologie, pour l'instant maîtrisée uniquement par une poignée de géants de la tech, Gontran Peubez (Partner Data & IA, Onepoint) fait une analyse des Large Language Models (LLM). Gaspard Koenig a écrit que « sur le plan épistémologique ChatGPT constituait une indéniable régression dans la production de la connaissance ». ChatGPT , dont il n'est plus nécessaire de présenter les fonctionnalités synthétise et restitue selon une syntaxe statistique une information issue de millions de pages Internet « apprises » à l'aide de Machine Learning spécifique, appelé Modèle de Langue. Restituer de l'information et non produire de la connaissance. La meilleure preuve en est l'argument avancé par d'autres de ses détracteurs : sa propension à reproduire des biais et même à articuler sans sourciller de sérieuses inepties.

**** *source_la_tribune_france *date_2023-03-24 *am_2023-03 *annee_2023

Données personnelles : quelles leçons retenir des premiers déboires de ChatGPT ? François Manens Coup sur coup, le chatbot d'OpenAI, ChatGPT , a subi deux incidents relatifs aux données personnelles. Heureusement, les bugs ont rapidement été corrigés et les conséquences semblent limitées. Néanmoins, ces ratés de la startup star de l'intelligence artificielle peuvent servir de piqûre de rappel : il ne faut pas donner d'information sensible à ChatGPT ou à ses concurrents. Comme un avertissement. Lundi, ChatGPT est resté en maintenance pendant plusieurs heures, car l'entreprise réparait en urgence un dysfonctionnement étrange. Lorsque certains utilisateurs se connectaient à leurs comptes, ils voyaient dans leur historique (situé dans une colonne à gauche de l'outil) les titres de conversations qui n'étaient pas les leur, mais celles d'autres utilisateurs. Lire aussiPourquoi vos données devront alimenter demain ChatGPT et autres IA (lien : https://www.latribune.fr/opinions/tribunes/pourquoi-vos-donnees-devront-alimenter-demain- chatgpt -et-autres-ia-955991.html) Heureusement, la fuite se limitait à cette information. Elle ne révélait ni le contenu des conversations avec le bot, ni l'identité de l'utilisateur. L'entreprise s'en sort ainsi à moindre mal. Quant aux utilisateurs, l'incident apparaît comme une piqûre de rappel : toute information intégrée aux discussions peut fuir en cas d'incident. C'est pourquoi OpenAI lui-même (lien : https://help.openai.com/en/articles/6783457- chatgpt -general-faq) conseille aux utilisateurs de ne pas donner d'informations sensibles à ChatGPT .

5 Segments De textes

Paramétrable à l'ouverture d'un corpus

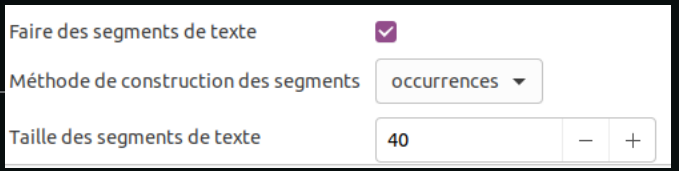

Lucie Loubère - 13/04/2026

Préparation automatique du corpus 2/3

2 - Nettoyage

- Iramuteq va effectuer des modifications sur le texte :
  - Il met tout le texte en minuscule (perte des majuscules)
  - il ne garde que les lettres, nombres et _ il remplace tout le reste par un espace

Paramétrable à l'ouverture du corpus (onglet nettoyage)

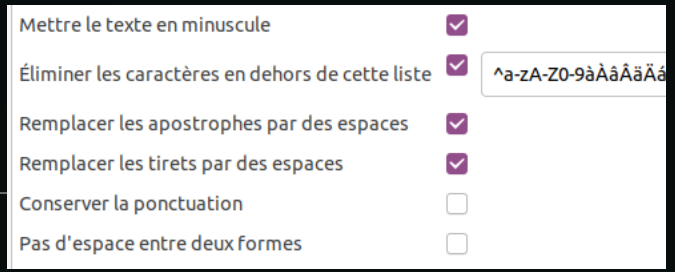

Préparation automatique du corpus 3/3

3 - Lemmatisation

Réduction de tous les mots reconnus par leur lemme

- Adjectif et nom = masculin singulier
- Verbes = infinitif

---

22 occurrences
19 formes

tu vois le monde se divise en deux catégories ceux qui ont un pistolet chargé et ceux qui creusent toi tu creuses

---

22 occurrences
18 formes

tu voir le monde se diviser en deux catégorie ceux qui avoir un pistolet chargé et ceux qui creuser toi tu creuser

Paramétrable avant chaque analyse

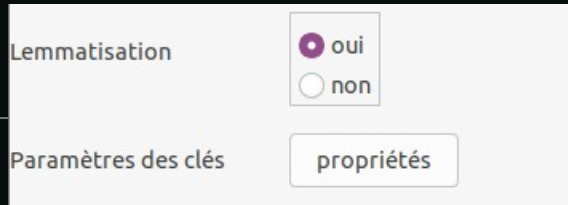

5. Les analyses

3 types d’analyses

- Comparaisons lexicales de sous ensembles de textes :
  - Analyses de spécificités
  - AFC
  - Distances de Labbé
- Exploration des mondes lexicaux (Reinert, 1983)
- Exploration de la structure du texte (Analyses de similitudes)

Les analyses de spécificités 1/4

3 types d’approches :

- Quel est le lexique spécifique à un groupe ?
- Comment se répartit un mot dans les groupes ?
- Quels sont les mots universels aux groupes.

Les analyses de spécificités 2/4

- Tableau lexical croisant lemmes (racines grammaticales des mots) et modalités de variables.

	*source_la_croix	*source_le_figaro	*source_le_monde	*source_lhumanité	*source_libération
sécurité	15	46	28	43	15
devenir	33	27	35	17	40
établissement	1	7	12	4	3
tirer	13	4	14	6	12
pencher	0	4	3	5	2
brexit	5	7	4	0	3
reporter	3	5	4	0	0
évolution	4	13	7	3	4
chine	1	5	2	0	2
connaissance	1	2	7	5	1
naturel	0	2	3	1	4
attente	4	5	8	3	3
unir	11	9	15	5	11

Combien d'occurences du mot sécurité en tout ?

Combien de mots contenus dans le monde ?

Les analyses de spécificités 3/4

- Calcul de la spécificité d’un mot vs un groupe,
  - Prend en compte le nombre d’occurrences du mot
  - Prend en compte la taille du groupe
  - Compare à ce que serait le hasard
- Résultat de l’analyse de spécificités
  - Un signe + si sur-représenté, - si sous représenté
  - Si le score est supérieur à 2 (ou inférieur à -2) alors il y a corrélation.

Les analyses de spécificités 4/4

Calculs de spécificités :
quel est le vocabulaire spécifique d'une catégorie de textes et/ou répondants ?

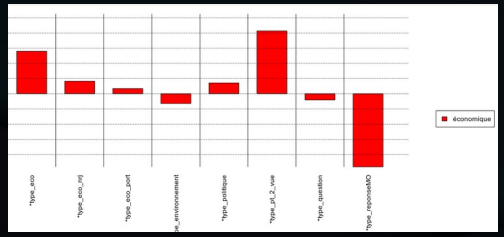

Forms	Banal forms	POS	Forms frequencies	POS frequencies	Forms relative frequencies
formes	*profil_débutant	*profil_débutant	*profil_en_deprise	*profil_engagé	
cancer	12.0343	-0.2663	-5.4833	-1.5261	
sein	11.5894	-0.5908	-3.558	-2.0522	
finalement	9.1673	0.3143	-5.741	-0.8231	
jambe	6.5059	-0.5078	-1.656	-1.2378	
essai	6.4357	-0.7272	-1.6917	-1.0333	
examen	6.1439	-0.4557	-2.6564	-0.5465	
médecin	6.1332	-1.0216	-2.9837	0.3451	
solution	5.7128	-0.5078	-1.656	-0.9198	
traiter	5.3219	-0.3082	-4.6941	0.4895	
attente	4.7981	-0.4336	-1.1439	-1.1039	
irm	4.3342	-0.7272	-1.6917	-0.3629	
au_delà	3.9662	-0.6362	-0.5371	-1.3564	
parkinson	3.7928	1.0671	-5.5307	0.8257	

Analyses Factorielles de Correspondances :
Représentation graphique de la dispersion du vocabulaire des différentes catégories de textes et/ou répondants



Exploration des mondes lexicaux 1/

- Permet (liste non exhaustive)
  - Connaître les thématiques structurantes d’un corpus
  - Connaître la répartition d’une de ces thématiques dans les groupes
  - Explorer le corpus par thématique

Exploration des mondes lexicaux 2/

- Classification Reinert
  - Classification hiérarchique descendante
  - Permet à partir d'un ensemble de texte
    - de les scinder
    - regrouper les passages qui se ressemblent sur la présence ET l'absence de mots (forment une classe de discours)
    - Afficher le lexique sur-représenté dans chaque classe de discours
    - Afficher la répartition de chaque modalité (variable étoilée) dans chaque classe
    - Permet d'explorer le texte par ces/ses thématiques

Exploration des mondes lexicaux 2/3

Segments de textes

Formes actives

	éolien	parc	mer	projet	énergie	impact	public	zone
Classe 1								
Segment Texte 1	0	0	1	1	0	0	1	1
Segment Texte 7	0	0	1	1	0	0	1	0
Classe 2								
Segment Texte 30	1	1	1	0	0	1	0	0
Segment Texte 4	1	0	0	1	1	1	0	0
Segment Texte 12	1	1	0	0	1	1	0	0
Segment Texte 6	1	1	1	0	0	1	0	0
Segment Texte 65	1	0	0	1	0	1	0	0
Segment Texte 22	1	1	1	1	0	0	1	1

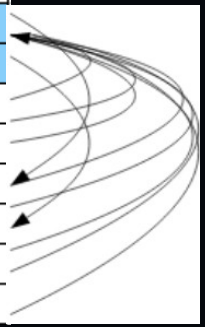

1 – Recherche dans le tableau les lignes qui se ressemblent le plus par rapport au reste.

2 – Prend la classe la plus grande et recommence le processus.

3 – Répète l'étape 2 jusqu'à atteindre le nombre de classes requis à la phase 1.

4 – Supprime les classes qui sont plus petites que le nombre minimal de segments de texte défini.

Exploration des mondes lexicaux 4/

Calcul des profils

- Calcule la corrélation entre classe et mot pour : chaque forme active, puis chaque forme supplémentaire, puis chaque modalité de chaque variable étoilée
- Édite la liste des formes et métadonnées sur-représentées pour chaque classe

Valeurs Observées

	Nb de ST avec la forme	Nb de ST sans la forme	Total
Nb de ST dans la classe	200	600	800
NB de ST dans les autres classes	218	330	548
Total	418	930	1048

Valeurs Théoriques

	Nb de ST avec la forme	Nb de ST sans la forme	Total
Nb de ST dans la classe	285,87 (700x428/1048)	621,18	700
NB de ST dans les autres classes	218,57	486,29	548
Total	418	930	1048

Calcul du Chi2 : $\frac{(200-285,5)^2}{285,5} + \frac{(600-621,18)^2}{621,18} + \frac{(218-218,57)^2}{218,57} + \frac{(330-486,29)^2}{486,29} = 76,56$

Exploration des mondes lexicaux 4/

Calcul des profils

- Calcule la corrélation entre classe et mot pour : chaque forme active, puis chaque forme supplémentaire, puis chaque modalité de chaque variable étoilée
- Édite la liste des formes et métadonnées sur-représentées pour chaque classe

Valeurs Observées

	Nb de ST avec la forme	Nb de ST sans la forme	Total
Nb de ST dans la classe	200	600	800
NB de ST dans les autres classes	218	330	548
Total	418	930	1348

Valeurs Théoriques

	Nb de ST avec la forme	Nb de ST sans la forme	Total
Nb de ST dans la classe	254,00 (800x428/1348)	551,93	800
NB de ST dans les autres classes	169,92	370,07	548
Total	418	930	1348

Calcul du Chi2 : $\frac{(200-254)^2}{254} + \frac{(600-551,93)^2}{551,93} + \frac{(218-169,92)^2}{169,92} + \frac{(330-370,07)^2}{370,07}$

Exploration des mondes lexicaux 3/3

1 Classe 1 8045/94858 8.48%	2 Classe 2 699/94858 0.74%	3 Classe 3 3063/94858 3.23%	4 Classe 4 6479/94858 6.83%	5 Classe 5 6677/94858 7.04%	6 Classe 6 4408/94858 4.65%	7 Classe 7 1648/94858 1.74%

num	eff. s.t.	eff. total	pourcentage	chi2	Type	forme	p
0	834	2344	35.58	2273.9	nom	chose	< 0,0001
1	387	773	50.06	1736.26	nom	gens	< 0,0001
2	724	2219	32.63	1706.76	ver	penser	< 0,0001
3	530	1631	32.5	1233.0	ver	entendre	< 0,0001
4	1196	6640	18.01	835.59	ver	voir	< 0,0001
5	393	1298	30.28	805.49	adv	vraiment	< 0,0001
6	469	1969	23.82	609.45	ver	travailler	< 0,0001
7	256	787	32.53	591.25	adj	intéressant	< 0,0001
8	340	1292	26.32	536.77	nom	monde	< 0,0001
9	532	2540	20.94	522.35	ver	venir	< 0,0001
10	237	785	30.19	480.66	adv	simplement	< 0,0001
11	226	737	30.66	470.94	nom	idée	< 0,0001
488	2710	15836	17.11	1824.79	pro_p...	je	< 0,0001
489	3599	26591	13.53	1215.71	pro_rel	que	< 0,0001
490	2764	19043	14.51	1117.43	adv_s...	pas	< 0,0001
491	2988	21193	14.1	1109.66	adv_s...	ne	< 0,0001
492	2999	22708	13.21	858.99	pro_p...	on	< 0,0001
493	942	4702	20.03	850.71	pro_p...	j	< 0,0001
494	312	938	33.26	749.55	adj_ind	quelque	< 0,0001
495	2317	16781	13.81	745.14	pro_d...	c	< 0,0001
496	4715	42624	11.06	664.21	aux	avoir	< 0,0001
663	7040	59904	11.75	2241.0		*source_reu	< 0,0001
664	919	6055	15.18	373.67		*db_DieppeTreport	< 0,0001
665	1241	9742	12.74	253.55		*db_SaintNazaire	< 0,0001
666	182	808	22.52	207.07		*3_Président_de_...	< 0,0001
667	319	1871	17.05	180.54		*3_Présidente_de...	< 0,0001
668	293	1709	17.14	168.29		*2_Claude_BRÉVAN	< 0,0001

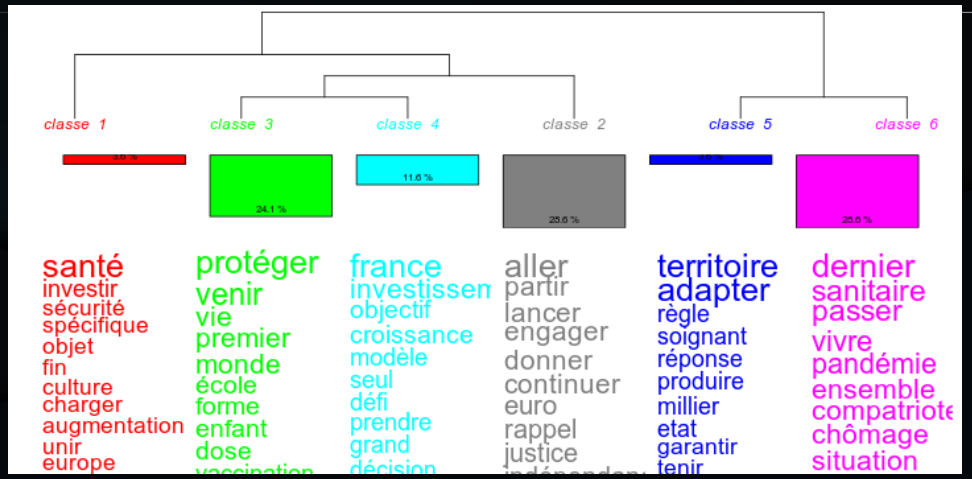

Segments de texte caractéristiques - Classe 1

****** *db_SaintNazaire *source_reu *2_Béatrice_BUFFON**
***3_directrice_adjointe_EDF_Énergies_Nouvelles_**

score : 6279.29

en revanche j **entends** bien votre **proposition** et je **pense** qu on l a tous **entendue** et c est quelque **chose** à laquelle on pourrait **réfléchir** à la suite et ça pourrait faire partie **effectivement** de **propositions** pour la suite du **débat** concernant le croisic spécifiquement monsieur gaëtan duchene

****** *db_DieppeTreport *source_reu *2_Marie-Thérèse_CASTAY_**

score : 6178.83

pour moi cela a été quelque **chose** de très **important** cette possibilité de **rencontrer** des **gens** qui permettait de **réfléchir** de **façon** un peu plus vaste que ce que j en **pensais** sur l éolien en mer et ses conséquences merci

****** *db_DieppeTreport *source_reu *2_Yannick_POURCHAUX**
***3_Président_du_Comité_régional_des_Pêches_de_Haute-Normandie**

score : 6144.27

marchons nous sur la tête a un **moment donné** il faudra peut_être mettre tout cela en pratique je suis un **spécialiste** de mon secteur mais pas de ce que j ai **entendu** jusque là et des **gens** ont des **choses** très **intéressantes** à dire

Structure du discours

- Analyse de similitude :
  - Issue de la théorie des graphes (Flament, 1962 ; Flament, 1981 ; Vergès & Bouriche, 2001)
  - Permet de visualiser les relations entre les éléments
  - Exemple avec l'indice « nombre d'occurrences »

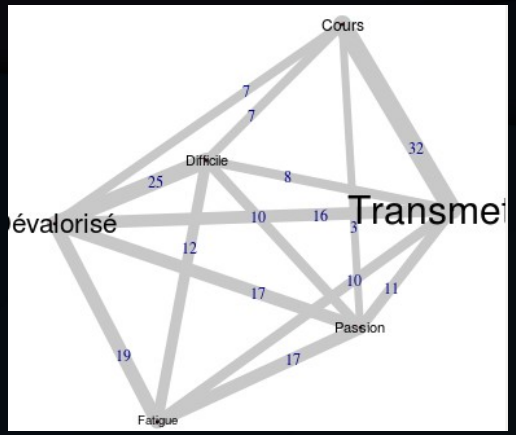

Transmettre et *cours* se retrouvent ensemble dans 32 segments de textes

Fatigue et *difficile* dans 12 questionnaires

Transmettre et *passion* 11 fois...

Iramuteq : l'interface du logiciel

Menu

Historique
des corpus et analyses

Résultats

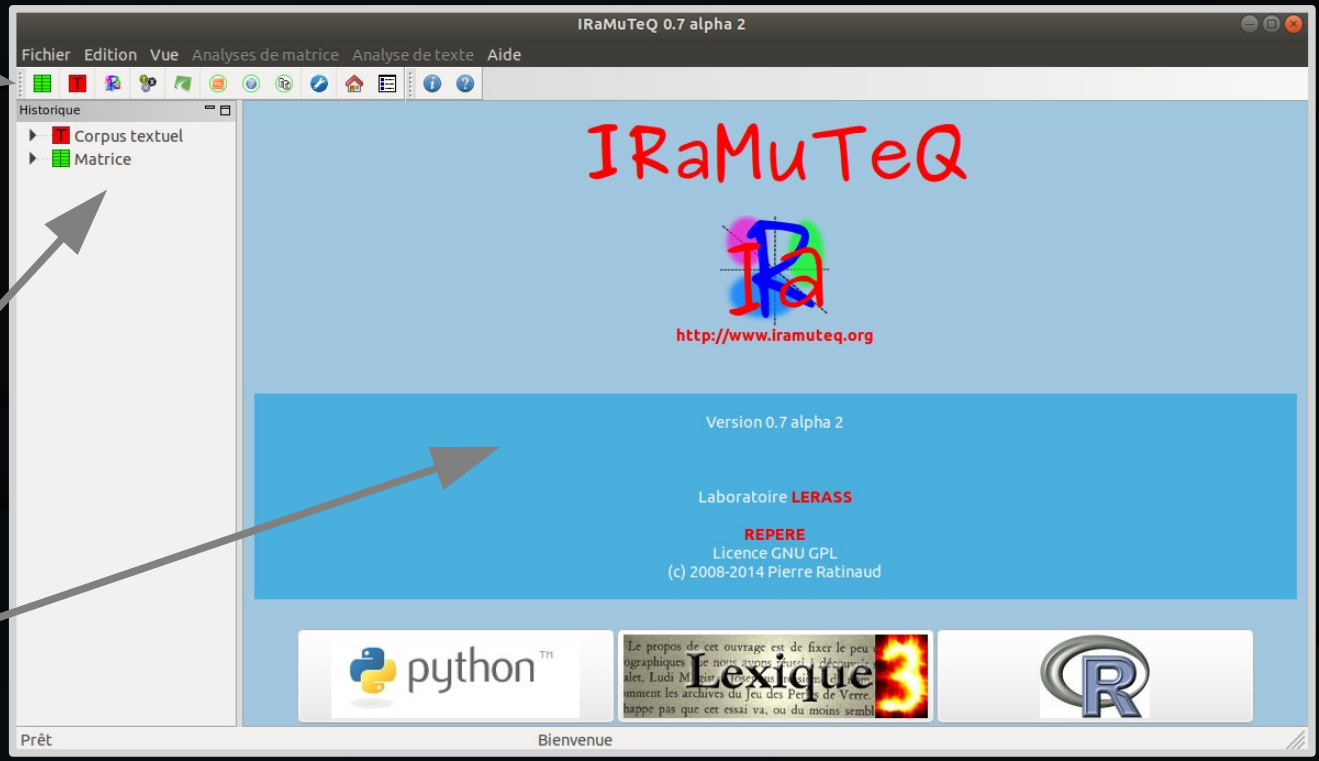

Iramuteq : l'interface (suite)

Options accessibles par clic droit

Sur l'analyse

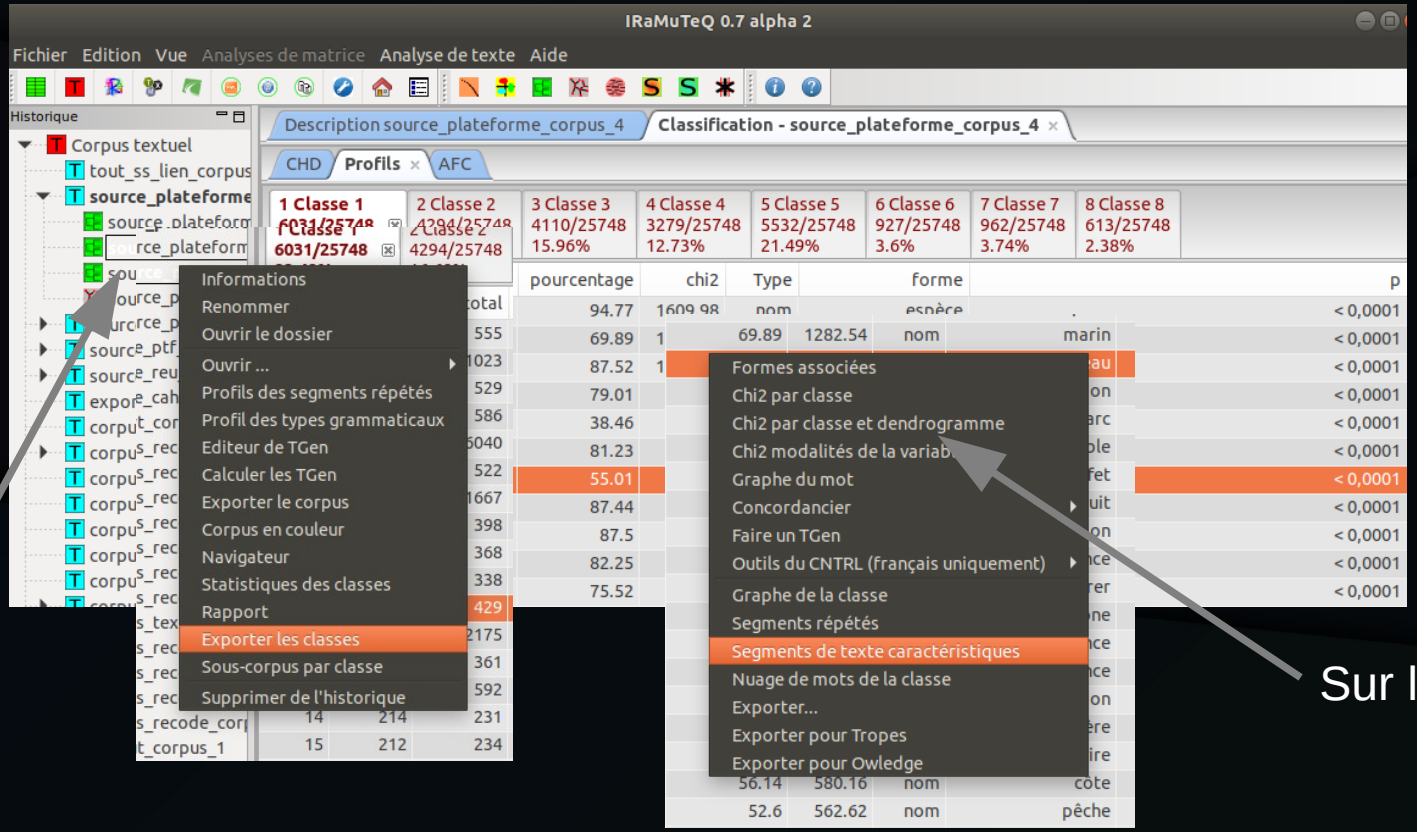

Sur la forme

L’ouverture du corpus

- Corpus .txt formaté (ligne étoilée)
- À l’ouverture :
  - Segmentation (par défaut)
  - Nettoyage (par défaut)
  - Indexation avec un dictionnaire (français par défaut)

La classification Reinert : paramètres

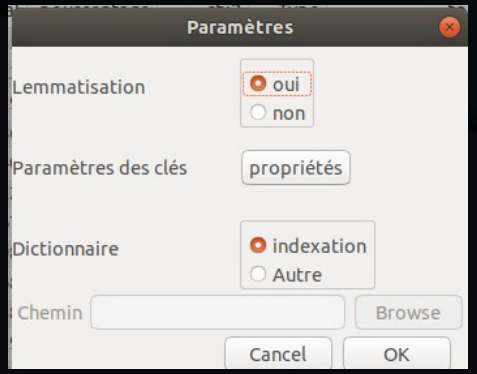

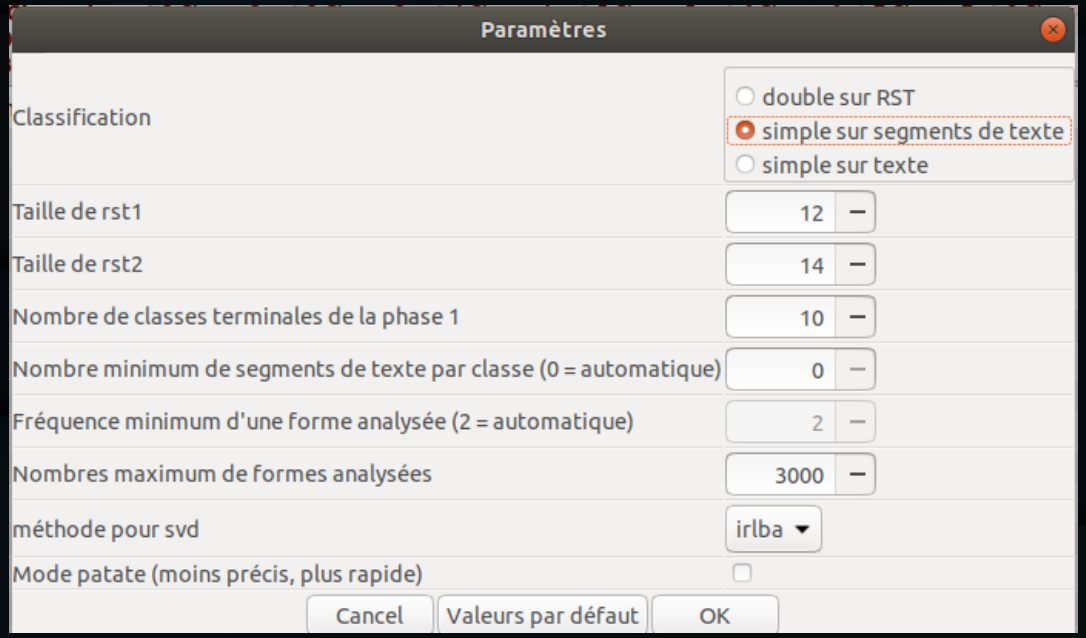

La classification Reinert : résultats

Nombre de ST contenant cette forme dans cette classe

Nombre de ST contenant cette forme dans la classification

Pourcentage de ST contenant cette forme dans cette classe

Chi2 de corrélation entre la forme et la classe

CHD | Profils | AFC

1 Classe 1 6031/25748 23.42%	2 Classe 2 4294/25748 16.68%	3 Classe 3 4110/25748 15.96%	4 Classe 4 3279/25748 12.73%	5 Classe 5 5532/25748 21.49%	6 Classe 6 927/25748 3.6%	7 Classe 7 962/25748 3.74%	8 Classe 8 613/25748 2.38%

num	eff. s.t.	eff. total	pourcentage	chi2	Type	forme	p
0	526	555	94.77	1609.98	nom	espèce	< 0,0001
1	715	1023	69.89	1282.54	nom	marin	< 0,0001
2	463	529	87.52	1237.23	nom	oiseau	< 0,0001
3	463	586	79.01	1033.0	nom	fondation	< 0,0001
4	2323	6040	38.46	994.77	nom	parc	< 0,0001
5	424	522	81.23	992.48	nom	câble	< 0,0001
6	917	1667	55.01	991.39	nom	effet	< 0,0001
7	348	398	87.44	923.54	nom	bruit	< 0,0001
8	322	368	87.5	854.59	nom	poisson	< 0,0001
9	278	338	82.25	660.76	nom	présence	< 0,0001
10	324	429	75.52	660.25	ver	montrer	< 0,0001
11	994	2175	45.7	657.35	nom	zone	< 0,0001
12	287	361	79.5	641.93	nom	distance	< 0,0001

La classification Reinert : options

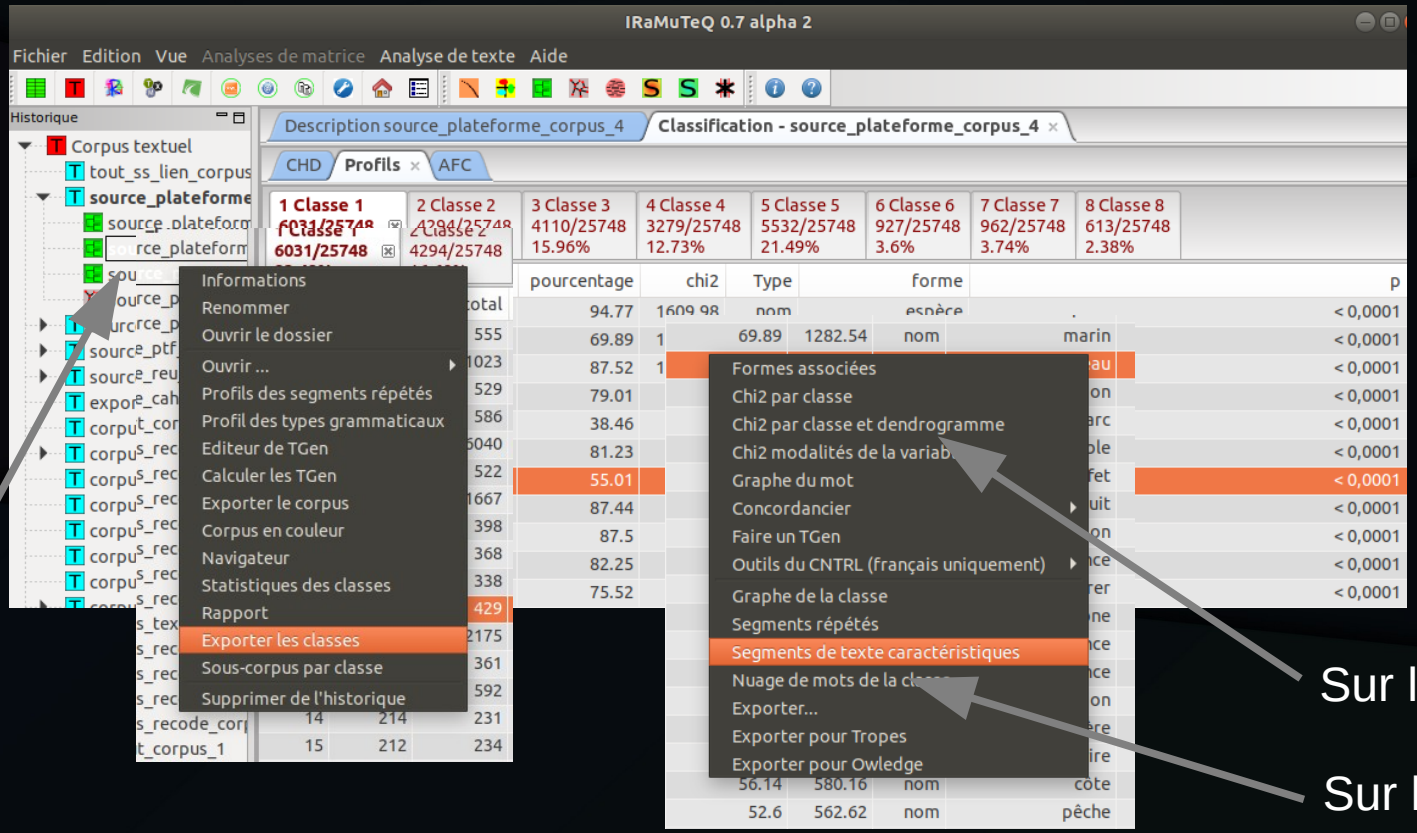

Analyses de similitudes

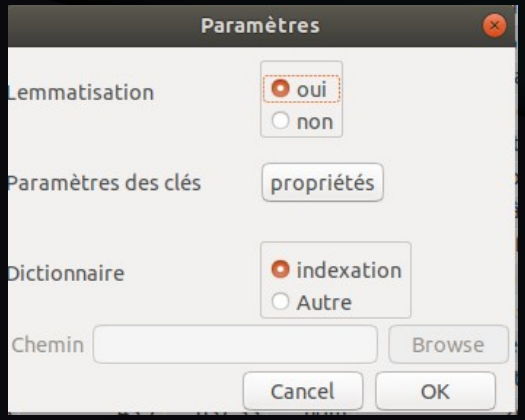

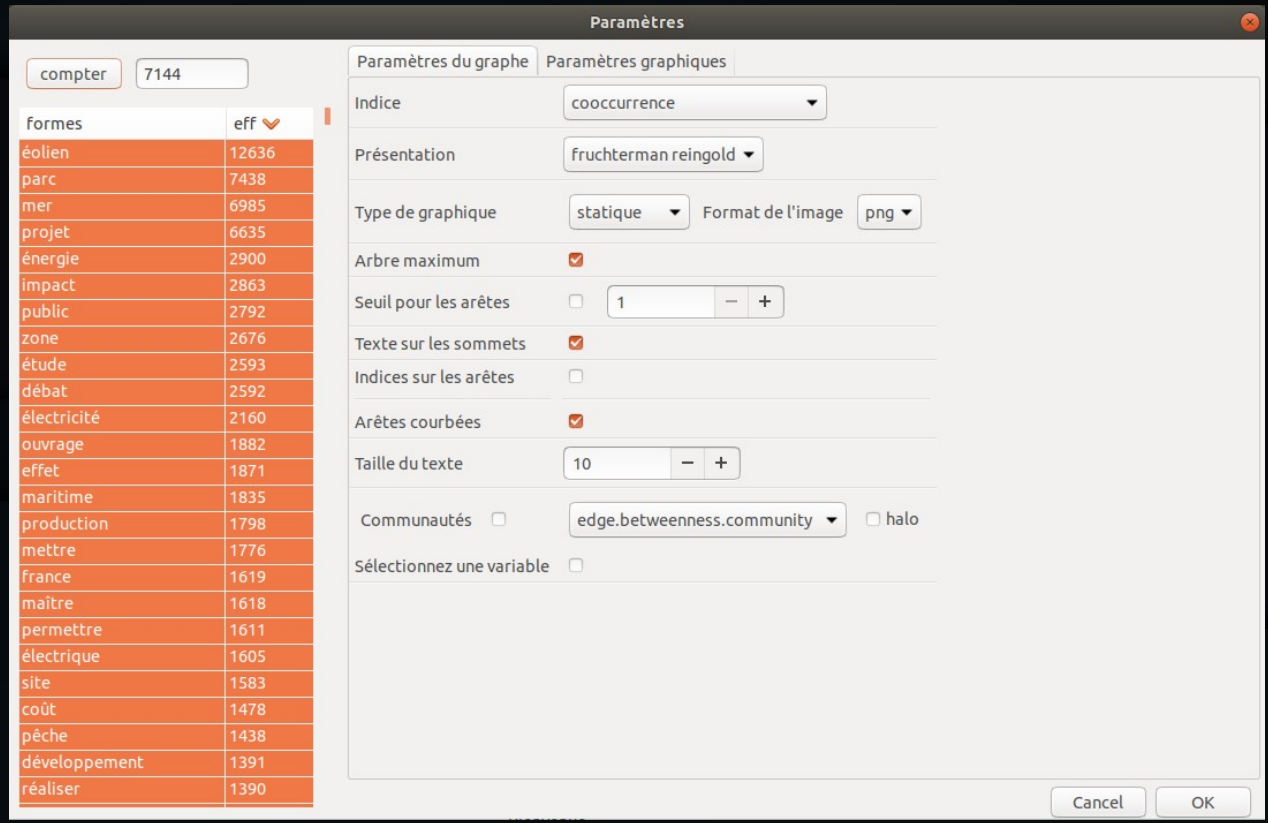

Analyses de spécificités

