

Perte d'information?

Corpus de Gestion Publique
Lemmatisation singulier/pluriel
Laure Payret, Université de
Picardie


Systematique

Outil

-tronque: fréquence minimale, seuil ...

-élague: mots-outils, hapax ...


-regroupe: singulier - pluriel,
féminin –masculin,
type généralisé



**lemmatisation
paramétrage**

Types de corpus

Taille du corpus :

- questionnaires à réponses ouvertes 20, 30 observations 20 à 200 ko par questionnaire, corpus de 400 à 6 mo
 - discours: 1 mo de 41 mo
 - textes formatés: contrats de ville 16 mo, traité européen avec acte final 1,1 mo
-  Elagage: mots-outils, hapax ...

Filtres

Parties:

- chapitre,
- thème,
- unité de temps
- variable signalétique

"l'objectif d'identification du genre serait un préalable à l'application de stratégies différenciées de la recherche d'informations dans le texte." Denise MALRIEU

Spécificité


- Pathologies psychologiques: l'emploi du singulier stigmatise un comportement de retrait face au monde, (S.BRUNER JADT 2004)
- Groupe politique minoritaire au pouvoir: sous-utilisation des verbes et actions à court terme,
- Collectivités Territoriales et Culture: typologie issue de l'organisation, (C.LABBE, D.LABBE, D.MONIERE)
- Une typologie s'avère fondée, dans les différents genre du discours en Sciences de la Société,
- La spécificité du corpus est liée à la fonction de l'acteur.

Ambiguïté

Genre du corpus



Arborescence textuelle



Type de variables retenues



Lemmatisation

Libre liberté libertés libéral libéralisme



Plan

- *Méthodologie*
- *Discours*
 - *Discours pluriel au singulier*
 - *Concordances*
 - *Visualisation*
- *Réponses ouvertes:*
 - *Spécificités*
 - *Visualisation*

Méthodologie

- 1 Corpus primaire, dictionnaire
- 2 Mise en évidence formes signifiantes
- 3 La concordance de ces formes signifiantes
- 4 Calcul du coefficient d'implication réciproque (RD),
- 5 Pourcentage de ces formes signifiantes dans le corpus,
- 6 Spécificité
- 7 AFC
- 8 Reprise du processus avec le corpus réduit et lemmatisé.

corpus réduit,

fonction de la taille initiale

formes présentant un seuil de fréquence fixé,

une fois lemmatisé offre à certaines formes la fréquence nécessaire pour être retenue.

Pour que cela ait un sens "mesurable", il faudrait que la lemmatisation soit effectuée sur tous les substantifs

Discours présidentiels[°]

plus de 85% des signifiants sont des noms.

- Taille 63071
- Vocabulaire 7101
- maxfréq Signifiant /T 0,2822%
- maxfréq Signi/V 3,0418%
- fréqConservée/T 0,0342%
- fréqConservée/V 0,3042%

[°] Discours F.MITTERAND , 1981-1995, cd Fondation J.JAURES, filtre: laïcité

Discours

- 992 formes de fréquence supérieure ou égale à 5, signifiants sans mots-outils.
- 693 formes de fréquence supérieure ou égale à 5, sans les mots-outils avec les formes regroupées
 - *Concordances:*
- 215 formes signifiantes de fréquence supérieure ou égale à 14, dans le corpus sans les mots-outils.
- 225 formes signifiantes ayant une fréquence supérieure ou égale à 14, sans les mots-outils avec les formes regroupées (pluriel, singulier).
- Les concordances signifiantes sont extraites des 7 formes à gauche et à droite de la forme pôle.

Corpus signifiant non lemmatisé, concordance LIBERTE(S)

	CIR%	LS%	LS et L	L%	LIBERTE	CIR%
LIBERTES						
<i>USAGE</i>	4 2,8571	4,7619	<i>PRIVILEGES</i>	3 2,3810	ENSEIGNEMENT	5 0,1353
SOLIDARITE	1 0,5102	0,8547	DROITS	2 0,5556	LOIS	3 0,0999
ORDRE	1 0,2976	3,0303	HOMME	4 1,5504	ETAT	3 0,0293
NATIONALE	1 0,1832	6,0606	PENSE	4 2,0833	CONQUETES	3 0,6494
SAUVEGARDE	1 1,7857	2,0833	POUVOIR	2 0,9009	BESOIN	3 0,0248
EPANOUISSEMENT	1 1,4286	6,6667	ENSEIGNER	2 1,2821	<u>LIBERTES</u>	2 0,1855
BAFOUES	1 3,5714	3,2258	OBJECTIF	2 1,0638	<i>CREATRICES</i>	2 1,2987
DRAPEAU	1				VIE	2
MENACEES	1				RESPONSABILITE	2
BATAILLE	1				PUBLIC	2
FRANCE	1				ORGANISATION	2
TIERS MONDE	1				EGALITE	2
ECONOMIQUE	1				EXAMEN	2
CONSTRUCTION	1				SAVOIR	2
					PENSE	2


LIBERTES	CIR%	LS%	L%	CIR%
<i>CIR Coefficient d'Implication Réciproque : rapport nombre de cooccurrences de 2 ou plusieurs formes au produit de leur fréquence</i>				
		LS et L		LIBERTE
USAGE	4 2,8571	4,7619	3 2,3810	
		PRIVILEGES		ENSEIGNEMENT 5 0,1353
SOLIDARITE	1 0,5102	0,8547	2 0,5556	
		DROITS		LOIS 3 0,0999
ORDRE	1 0,2976	3,0303	4 1,5504	
		HOMME		ETAT 3 0,0293
NATIONALE	1 0,1832	6,0606	4 2,0833	
		PENSE		CONQUETES 3 0,6494
SAUVEGARDE	1 1,7857	2,0833	2 0,9009	
		POUVOIR		BESOIN 3 0,0248
EPANOUISSEMENT	1 1,4286	6,6667	2 1,2821	
		ENSEIGNER		LIBERTES 2 0,1855
BAFOUES	1 3,5714	3,2258	2 1,0638	
		OBJECTIF		CREATRICES 2 1,2987

ne classe pas selon le même ordre les cooccurrences communes à liberté et libertés.
 Enseigner, privilèges, objectif pour libertés; Privilèges, pense, homme pour liberté


Implication réciproque

- Les termes en italiques n'appartiennent pas aux signifiants (fréquence trop faible).
- Les "libertés" sont liées fortement à l'"usage" alors que la "liberté" l'est avec "enseignement" puis "lois", "Etat", "conquêtes", "besoin".
- Cette différence pointe la séparation entre le pouvoir national, décisionnel, et le pouvoir local, opérationnel.
- Les formes communes relèvent du domaine conceptuel, du projet.


Spécificité avec formes singulier et pluriel




Formes ramenées au singulier



Spécificités



originales



lemmatisées


La forme liberté devient banale

Discours les pluriels au singulier


- Perte d'information avec la forme "liberté " qui devient banale, alors que au pluriel sens diffère en particulier dans cette thématique porteuse des libertés individuelles, "liberté de conscience« , au singulier la personnification de la liberté,
- Ecole, forme très spécifique des types de discours, avec opposition entre les allocutions et les rencontres perd son sens "local" pour mettre en évidence uniquement le sens national, En fonction du pourcentage de la forme au singulier, les spécificités de celui-ci l'emportent
- Tous les termes retenus, ici, sauf "enfant" avaient un poids plus important au singulier qu'au pluriel,
- En revanche, dans le corpus lemmatisé, des termes INITIATIVE, ORGANISATION, CLANDESTIN, CITOYEN, DECISION, COMMUNISTE sont retenus.

Pour limiter les pertes de sens, il semble intéressant de regarder les contextes de ces formes avant de ramener au singulier.

Analyse Factorielle originale



Après lemmatisation partielle



Réponses ouvertes

- 16 acteurs de 3 CSP différentes, taille $T=17822$ formes, vocabulaire $V=2989$
- Sur les questionnaires à réponses ouvertes du CHU
- Taille 17822
- Vocabulaire 2989
- maxfréq signifiant / T 1,8180%
- maxfréq signifiant/ V 10,8397%
- seuil 10%

Spécificités

Administratif

base	0,82	0,40	45	72	5,421	0,000
donnée	0,18	0,06	10	10	4,320	0,000
<i>documents</i>	<i>0,44</i>	<i>0,20</i>	<i>24</i>	<i>36</i>	<i>4,258</i>	<i>0,000</i>
l hôpital	0,35	0,15	19	27	4,026	0,000
pédiatrie	0,31	0,13	17	24	3,826	0,000
base données	0,15	0,04	8	8	3,767	0,000
projet	0,38	0,19	21	34	3,550	0,000
hôpital	0,35	0,17	19	30	3,488	0,000
service	0,93	0,62	51	110	3,322	0,000
service pédiatrie	0,20	0,08	11	15	3,126	0,001
services	0,31	0,16	17	28	3,078	0,001
préparation	0,13	0,04	7	8	2,957	0,002
hospitalisation	0,15	0,06	8	10	2,884	0,002
<i>information</i>	<i>0,15</i>	<i>0,06</i>	<i>8</i>	<i>10</i>	<i>2,884</i>	<i>0,002</i>
<i>papier</i>	<i>0,60</i>	<i>0,40</i>	<i>33</i>	<i>72</i>	<i>2,555</i>	<i>0,005</i>
temps	0,29	0,49	16	88	-2,565	0,005
infirmière	0,02	0,13	1	23	-2,833	0,002
<i>cahier</i>	<i>0,05</i>	<i>0,35</i>	<i>3</i>	<i>62</i>	<i>-4,928</i>	<i>0,000</i>

Spécificités

Infirmier

<i>cahier</i>	<i>0,92</i>	<i>0,35</i>	<i>49</i>	<i>62</i>	<i>7,881</i>	<i>0,000</i>
vert	0,34	0,10	18	18	6,164	0,000
<i>cahiers</i>	<i>0,26</i>	<i>0,09</i>	<i>14</i>	<i>16</i>	<i>4,541</i>	<i>0,000</i>
cahier vert	0,19	0,06	10	10	4,388	0,000
dossier médical	0,39	0,17	21	31	4,167	0,000
box	0,28	0,11	15	20	3,942	0,000
chambre	0,19	0,06	10	11	3,915	0,000
mauve	0,15	0,04	8	8	3,833	0,000
<i>soin</i>	<i>0,21</i>	<i>0,07</i>	<i>11</i>	<i>13</i>	<i>3,810</i>	<i>0,000</i>
<i>note</i>	<i>0,17</i>	<i>0,06</i>	<i>9</i>	<i>10</i>	<i>3,636</i>	<i>0,000</i>
dossier patient informatisé	0,19	0,07	10	12	3,540	0,000
alarme	0,13	0,04	7	7	3,524	0,000
violet	0,13	0,04	7	7	3,524	0,000
scope	0,13	0,04	7	7	3,524	0,000
<i>feuilles</i>	<i>0,30</i>	<i>0,13</i>	<i>16</i>	<i>24</i>	<i>3,523</i>	<i>0,000</i>
<i>notes</i>	<i>0,00</i>	<i>0,08</i>	<i>0</i>	<i>14</i>	<i>-2,461</i>	<i>0,007</i>
pédiatrie	0,02	0,13	1	24	-2,844	0,002
<i>documents</i>	<i>0,06</i>	<i>0,20</i>	<i>3</i>	<i>36</i>	<i>-2,893</i>	<i>0,002</i>

LP CRIISEA

Spécificités

Médecin


<i>notes</i>	0,19	0,08	13	14	3,909	0,000
rempli	0,14	0,06	10	10	3,756	0,000
activité	0,14	0,06	10	10	3,756	0,000
personnelles	0,13	0,05	9	9	3,514	0,000
<i>notes personnelles</i>	0,13	0,05	9	9	3,513	0,000
senior	0,11	0,04	8	8	3,258	0,001
terme	0,14	0,06	10	11	3,233	0,001
<i>diagnostic</i>	0,10	0,04	7	7	2,982	0,001
recherche	0,31	0,19	22	34	2,828	0,002
médecin	0,50	0,34	35	61	2,737	0,003
traitements	0,11	0,05	8	9	2,717	0,003
thérapeutiques	0,09	0,03	6	6	2,683	0,004
transmettre	0,09	0,03	6	6	2,683	0,004
exploration	0,09	0,03	6	6	2,683	0,004
<i>soin</i>	0,01	0,07	1	13	-2,186	0,014
hospitalisation	0,03	0,10	2	17	-2,188	0,014
<i>feuille</i>	0,03	0,10	2	17	-2,188	0,014
cahier vert	0,00	0,06	0	10	-2,464	0,007
donnée	0,00	0,06	0	10	-2,466	0,007
<i>cahier</i>	0,14	0,35	10	62	-3,808	0,000
	0,01	0,00	1	10	-2,221	0,001

Spécificités


- Informations 86,
- Information 45 sur représentée chez les administratifs au singulier
- Cahier 82 sous-représentée chez les
- Cahiers 16 spécifiquement positif au singulier et au pluriel infirmiers, négatif médecins
- Feuille 17 spécificité négative des médecins
- Feuilles 24 spécificité positive des infirmiers
- Note 10 spécificité positive des infirmiers
- Notes 14 spécifique positive des médecins, négatives des infirmiers
- Soins 43 sur-représentée chez infirmier
- Soin 13 sur-représentée infirmier, sous

La fonction discrimine le vocabulaire et l'emploi de certaines formes au singulier ou pluriel


Soins/soin



Soin



Aplatissement des spécificités




Cahiers/cahier


Cahier

Type de spécificité conservé à la limite







Retournement de situation



Réponses ouvertes: AFC



Réponses ouvertes: formes ramenées au singulier



Structure conservée avec réduction des spécificités.

Conclusion

- Perspective de Recherche documentaire, l'affichage multidimensionnel des formes, la création de dictionnaires par discipline? (Top-Down)
formes au singulier et tronquées!
- La mise en évidence de spécificités du corpus, voire de typologies supposerait que dans un premier temps les formes au singulier et au pluriel soient conservées
- Extraction de connaissances à partir des corpus, penser aux conclusions de L.LEBART! (Bottom-up)

Bibliographie articles...

AUBIN S., LELU A., “ Vers un environnement complet de synthèse statistique de contenus textuels”, Neuronav v2, *séminaire ADEST, 2005*

COURTIAL J.P., “ Analysis of Social Representations in Action Based on Words Associated by Scientific Articles”, European Review of Applied Psychology, 52, 2002, p.221-230

GOUADAIN D., “ Les mots de la Gestion ”, Gérer et Comprendre, n°66, 2001, p. 58-80, ESKA, Paris.

KRUSKAL J.B, “ Multidimensional Scaling By Optimizing Goodness of Fit To a Nonmetric Hypothesis”, Psychometrika Vol. 29, N°1, March 1964

LEBART L., “ Validation des visualisations de données textuelles” , *Actes des JADT 2004*

REINERT M., “ Approche statistique et problème du sens dans une enquête ouverte”, *Journal de la Société Française de Statistique*, tome 142, vol 4, 2001

Bibliographie articles...

AUBIN S., LELU A., “ Vers un environnement complet de synthèse statistique de contenus textuels”, Neuronav v2, *séminaire ADEST, 2005*

BRUNER S., pathologies psychologiques: l'emploi du singulier stigmatise un comportement de retrait face au monde, JADT 2004

GOUADAIN D., “ Les mots de la Gestion ”, Gérer et Comprendre, n°66, 2001, p. 58-80, ESKA, Paris.

LEBART L., “ Validation des visualisations de données textuelles” , *Actes des JADT 2004*

PINCEMIN B., Lexicométrie sur corpus étiqueté, JADT 2004

REINERT M., “ Approche statistique et problème du sens dans une enquête ouverte”, *Journal de la Société Française de Statistique*, tome 142, vol 4, 2001

Bibliographie ouvrages

- **LEBART L., SALEM A., Statistique textuelle, Dunod, 1994**
- **MULLER C., Principes et méthodes de statistique lexicale, Hachette, Collection Langues, Linguistique, 1970**
- **www.cavi.univ-paris3.fr/lexicometrica
Actes des JADT 2002, 2004,**
- **Logiciel téléchargeable gratuit:
LEXICO2**