

Traiter le multilinguisme dans les discours politiques

Possibilités et limites d'une analyse lexicométrique dans un corpus composé des textes de différents langues

Ronny Scholz,

Université Paris XII

Université de Magdebourg (Allemagne)

Comment peut-on analyser un corpus multilingue avec des outils lexicométriques?

Pourquoi faire?

- pour analyser un champs discursif international. Présupposé que le champs discursif ne s'arrête pas à la frontière langagière.
 - Comparaison directe des textes appartenant au même discours dans différents pays.
 - Mesurer les caractéristiques lexicales d'un corpus multilingue représentant un certain discours indépendamment des langues contenues. Le corpus soit établi à partir des textes représentants un discours qui concerne un sujet international. Les caractéristiques lexicales du corpus sont représentatif pour le corpus et permettent des conclusions concernant un discours international.
-

3 démarches possibles pour un traitement lexicométrique du multilinguisme

- I. Approche multilinguistique
 - Composer un seul corpus avec des textes de différentes langues pour que l'analyse lexicométrique soit effectuée dans l'ensemble des textes multilingues

 - II. Approche morphosyntaxique à l'aide du logiciel *TreeTagger*.
 - Composer un corpus à la base des étiquètes représentant la structure morphosyntaxique du corpus. - Analyser la structure morphosyntaxique dans les textes des différentes langues. - Unifier l'étiquetage morphosyntaxique des différentes langues.

 - III. Approche de mesure croisée dans des corpus des différents langues
 - Composer plusieurs corpus chacun contenant des textes d'une langue particulière. - Comparer les résultats d'analyse lexicométrique des différents corpus dans la mesure possible.
-

Ensemble des textes qui forment le corpus
pour la période 1979 – 2004

corpus allemand:

REP*, CDU, CSU, FDP, Die Grünen, SPD, PDS*

corpus français:

FN, MPF, RPF, UMP (RPR, DL), UDF*, Les Verts,
PS, PRG*, PCF, LO*

corpus britannique:

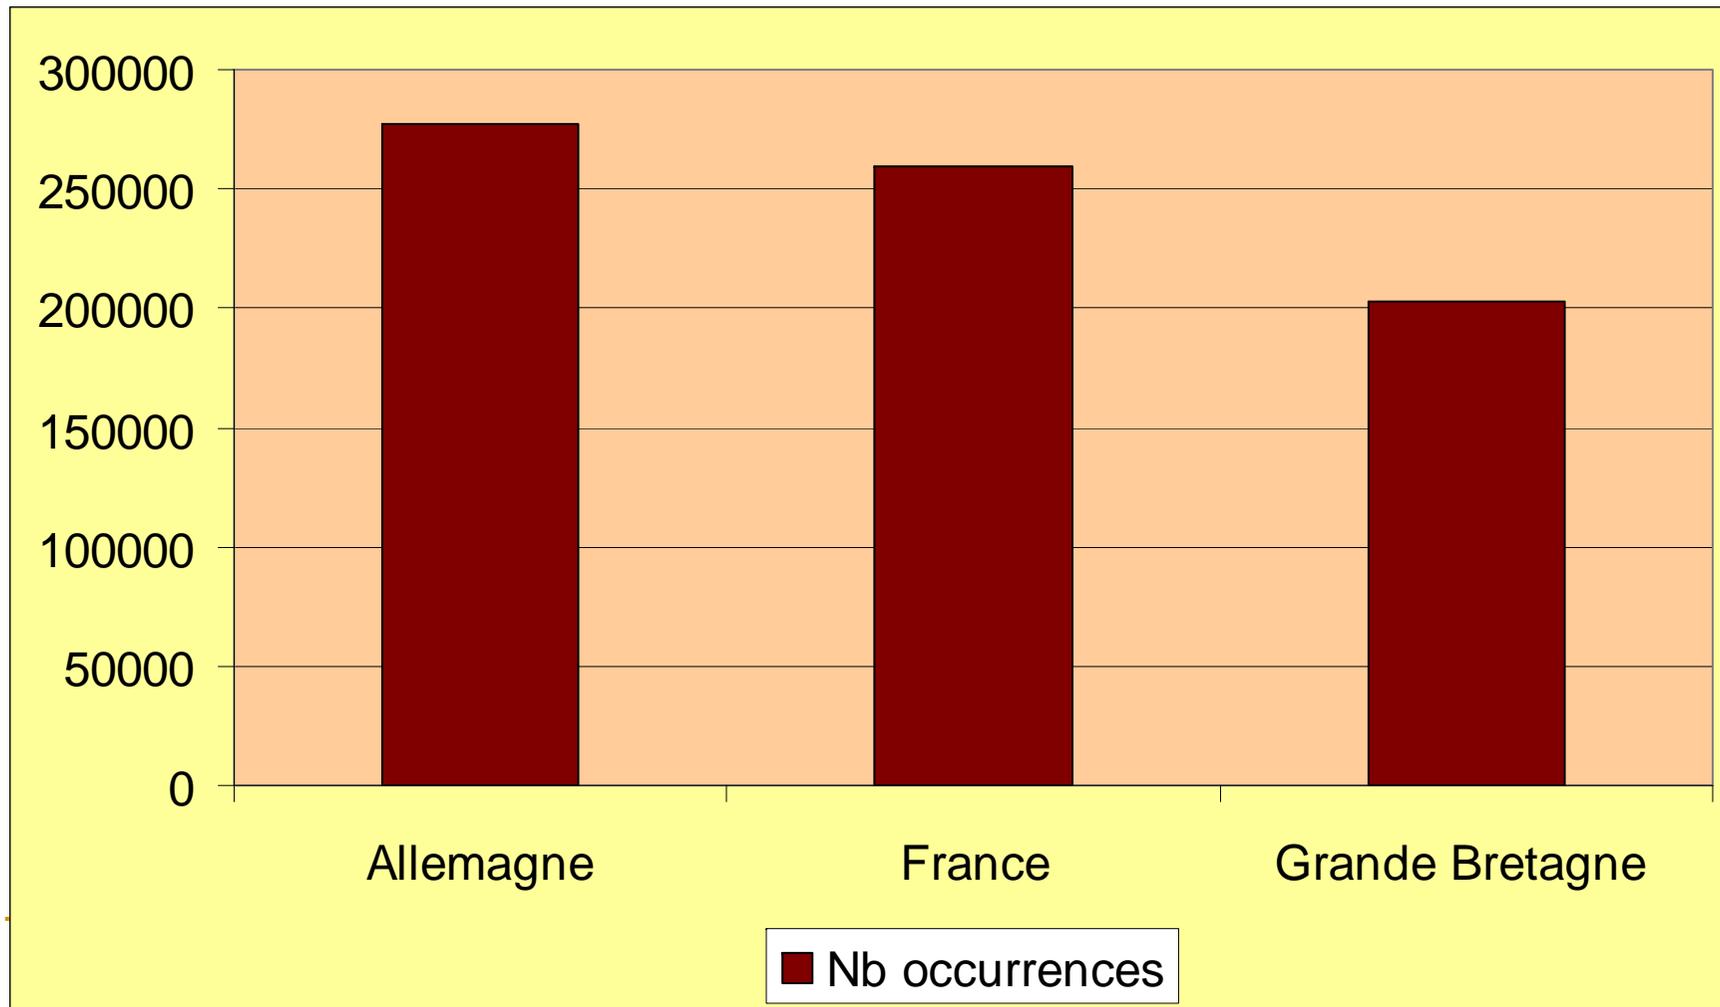
UKIP, CONS, LDP, LAB, GREENS, PC*, SNP*

Caractéristiques du corpus

Principales caractéristiques lexicométriques

Nombre des occurrences	805195
Nombre des formes	47468
Fréquence maximale	16391
Nombre des hapax	21976
Nombre des textes	121

Distribution des fréquences absolues des textes de la partition <land> dans le corpus de programmes des Élections Européennes



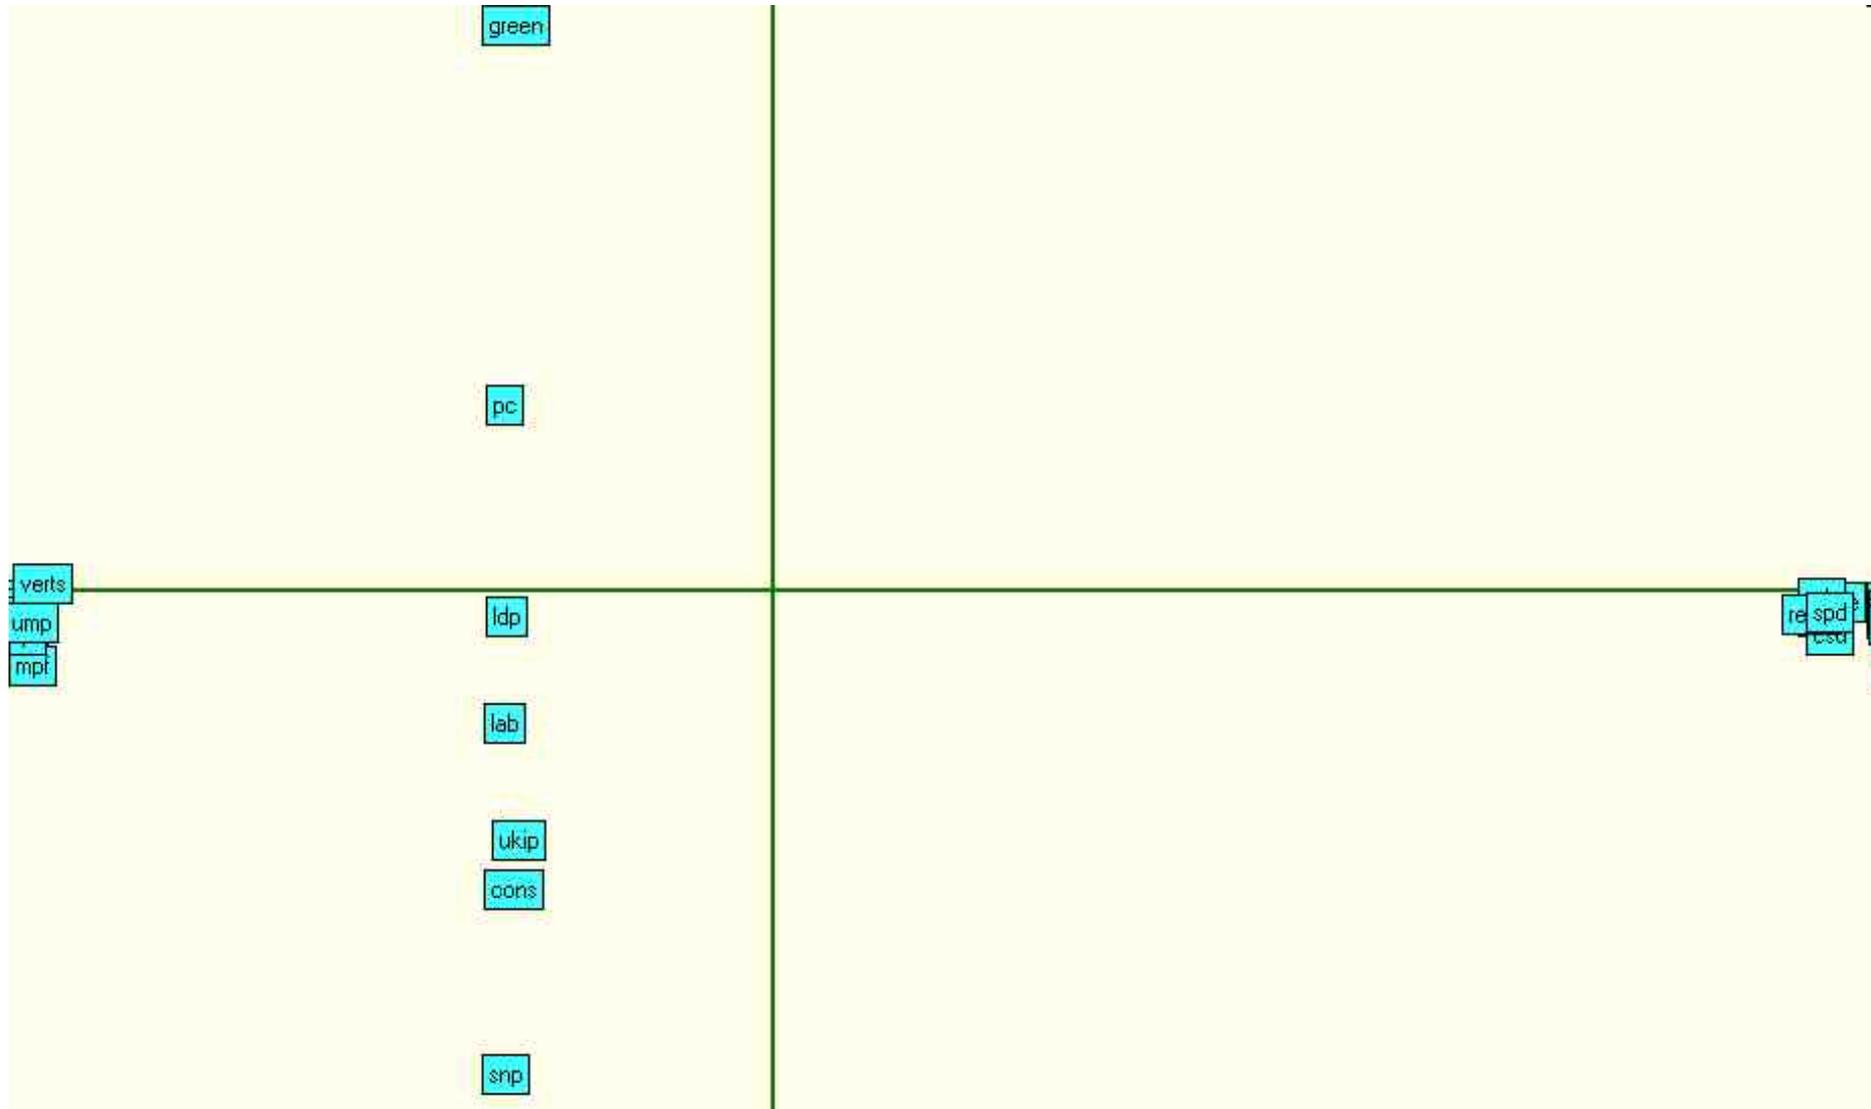
Mélanger les langues à condition que :

- le nombre d'occurrences soit équilibré entre les différentes langues
- la comparaison porte sur les caractéristiques sémantiques et pas sur les caractéristiques grammaticaux

(Une différence des caractéristique entre des différentes langues est évident et une analyse lexicométrique n'apporterait pas des résultats révélateurs. Par exemple Europe de l'est vs. Eastern Europe vs. Osteuropa)

Solution: Groupe de formes qui porte sur une caractéristique sémantique – par exemple: Tgen *europ+*

Analyse Factorielle des Correspondances (AFC) dans la partition *parti*



Accroissement vocabulaire

Comparaison des différents langues



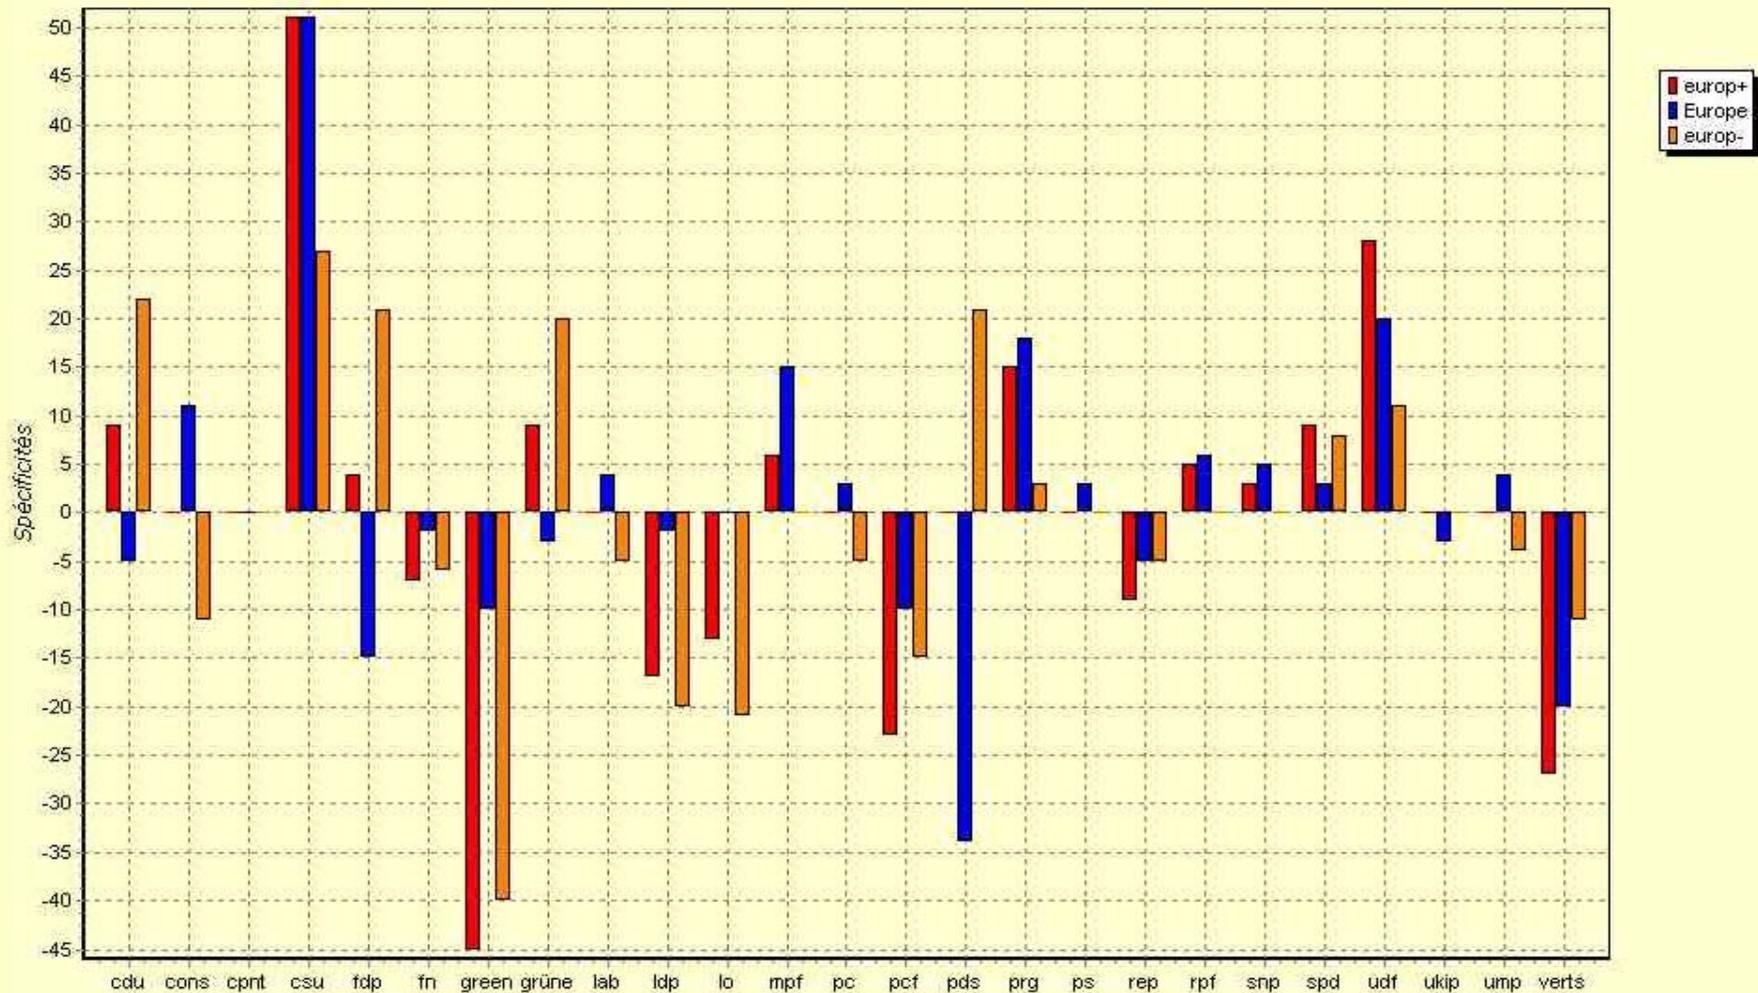
La Tgen europ+ (les premières formes)

Tgen europ+	
Forme	Fréquence absolue
europa	4080
europäischen	2362
european	1945
europa	1533
europäische	1371
europäische	1334
europäer	903
europäer	544
europas	473
europäische	371
europäer	201
europol	73
europäer	72
europäer	69
osteuropa	56
osteuropas	52
westeuropäischen	52
europapolitik	47
osteuropäischen	40
gesamteuropäischen	36
westeuropa	36
gesamteuropäische	31

Spécificités des Tgen *europ+*; *europ-*; *Europa/Europe* dans la partition *année*



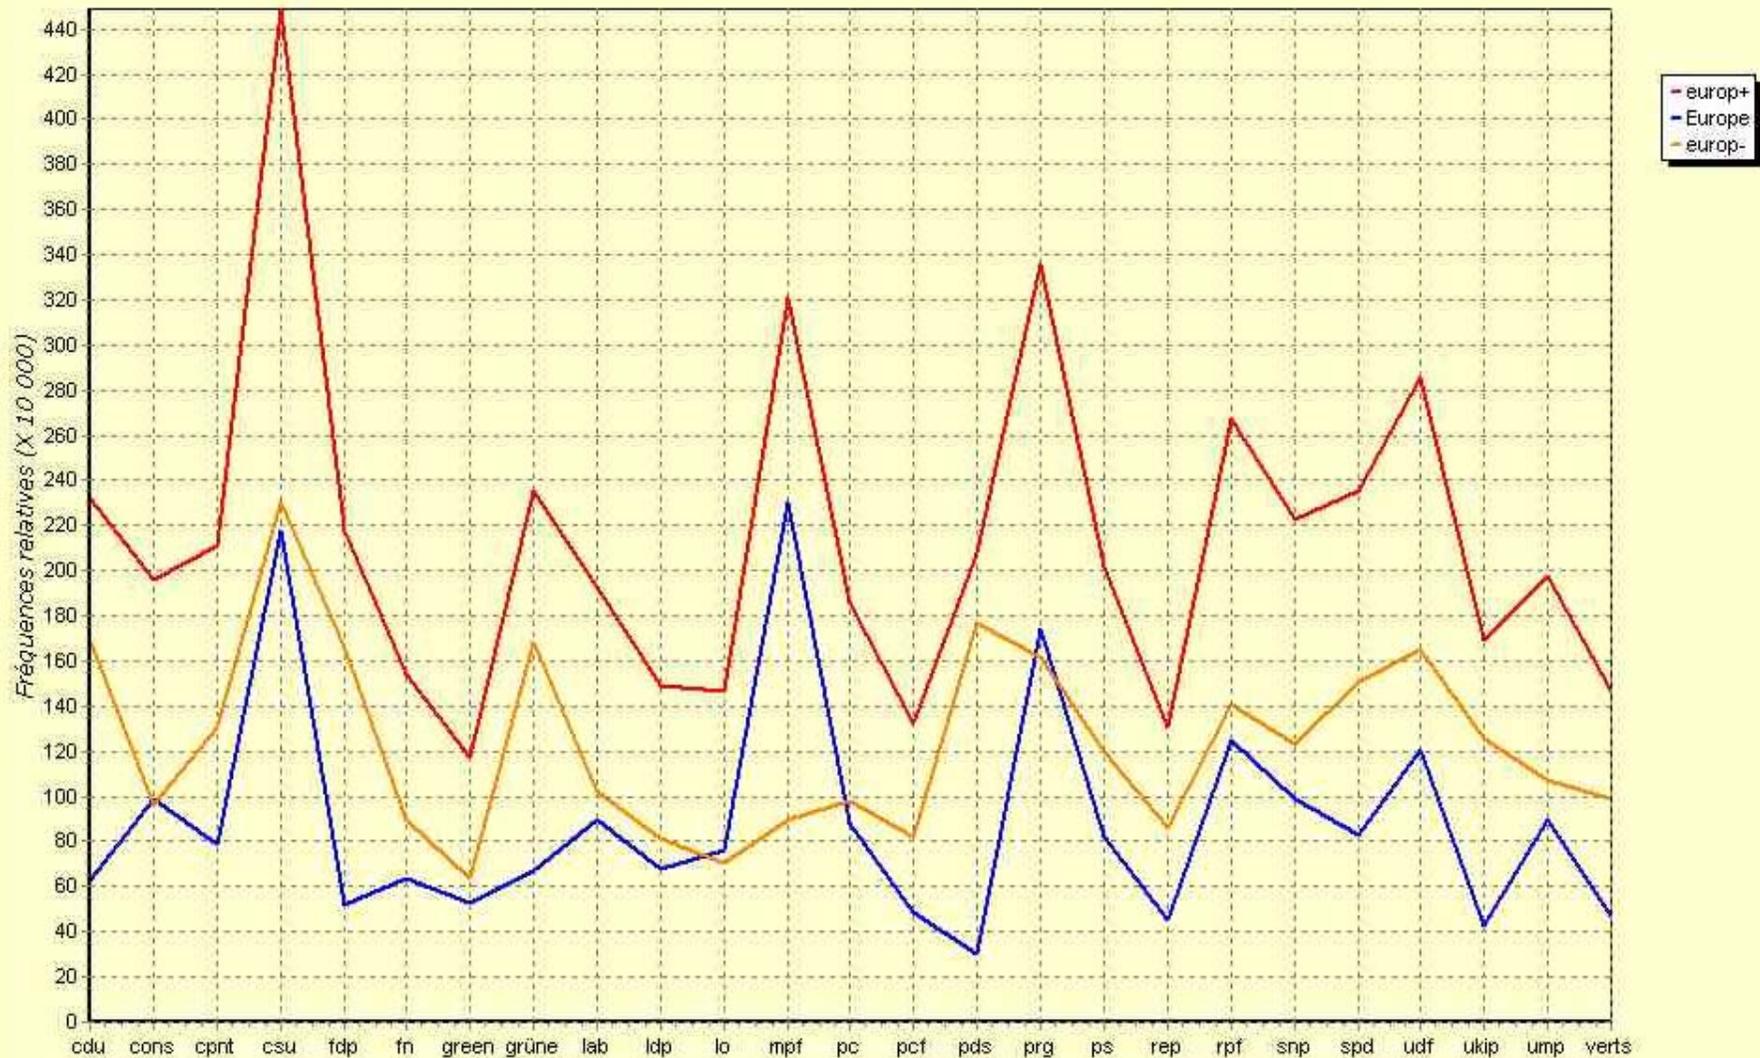
Spécificités des Tgen *europ+*; *europ-*; *Europa/Europe* dans la partition *parti*



Cooccurrences de Tgen *europ+* (liste élaguée)

Forme	Frq. Tot.	Fréquence	Coeff.
union	2445	2054	***
parliament	560	406	49
parlement	294	243	47
une	3707	1944	39
construction	227	189	38
et	7978	3841	31
la	10431	4929	30
d	5209	2574	29
einigung	111	99	26
pour	2924	1494	25
ein	1955	1040	25
parlaments	112	97	23
élections	116	97	21
peuples	227	161	19
eastern	59	55	17
un	2926	1440	17
starkes	46	45	17
voulons	160	117	16
dimension	146	109	16
ebene	233	156	15
gemeinschaft	1131	602	15
staaten	470	276	14
au	1905	956	14
espace	134	96	13
nations	294	183	13
institutions	345	210	13
centrale	72	60	13
modèle	107	79	12
citoyens	245	156	12
conseil	280	172	12
bürger	419	242	12
geeintes	30	30	12
doit	886	471	12
zentralbank	35	33	11
sécurité	296	177	11

Fréquence relative des Tgen *europ+*; *europ-*; *Europa/Europe* dans la partition *parti*

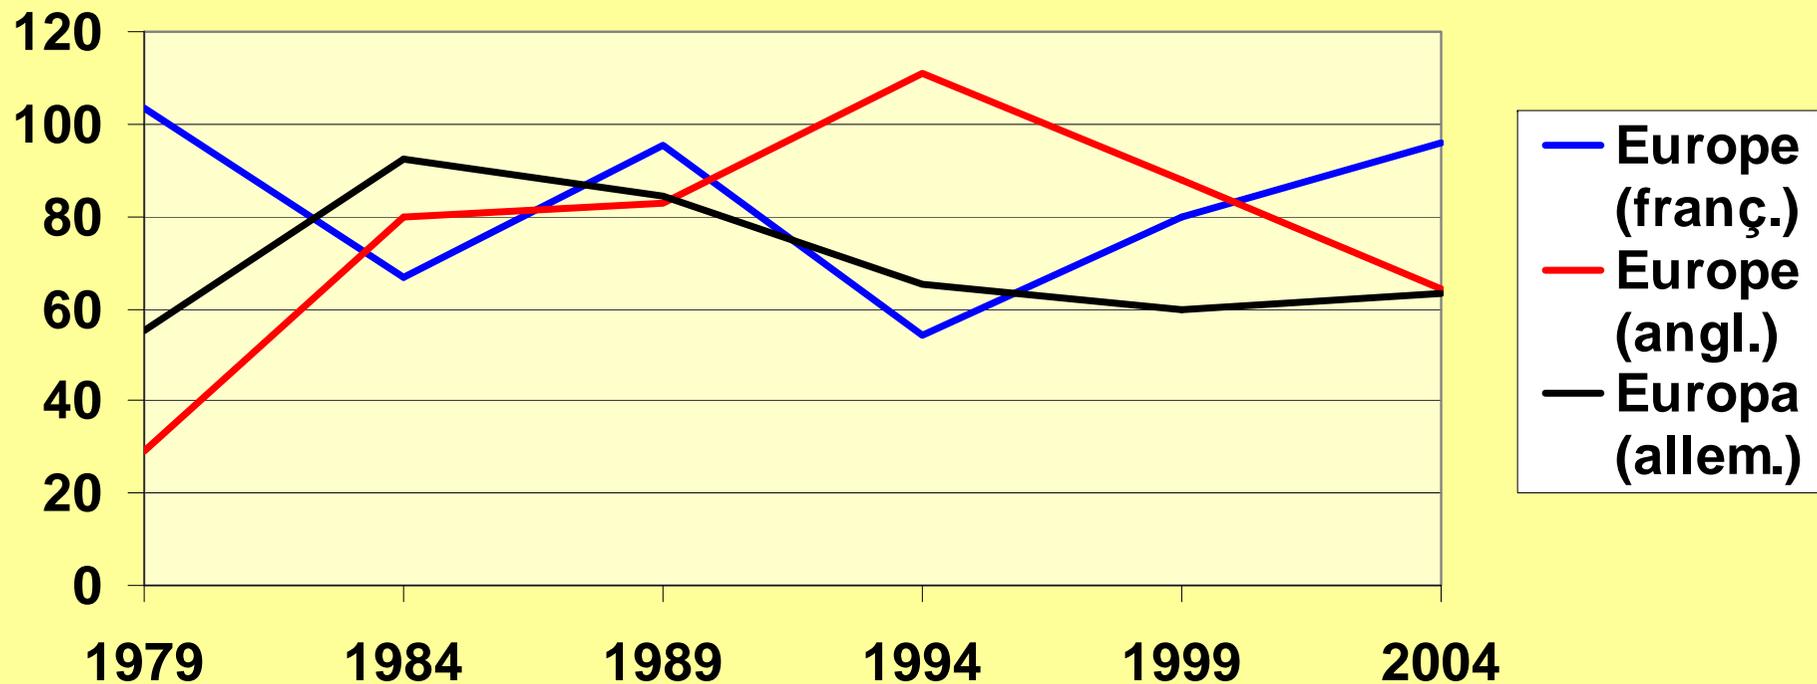


Fréquence relative des Tgen *europ+*; *europ-*; *Europa/Europe* dans la partition *année*



Comparaison avec les Fréquences relatives dans trois corpus séparés

**Distribution des fréquences relatives
d'*Europa*/*Europe*
dans les trois corpus de la partition *année***



Limites d'une analyse lexicométriques dans un corpus composé des différents langues

- L'Analyse Factorielle des Correspondances n'est pas utile dans un corpus multilingue.
- Les mesures des spécificités et des cooccurrences peut être utile à condition que la distribution des occurrences soit équilibrés dans les partis comparé. Sinon le vocabulaire d'une partie avec une langue moins riche ou une longueur plus longues soit surreprésentée.
- En comparaison avec un corpus unilingue les spécificités des formes particuliers dans un corpus multilingues sont plus extrêmes du fait qu'on trait un corpus multilingue.

Une forme qui est spécifique chez un certain locuteur ne peut pas apparaitre chez un autre locuteurs à cause de la différence langagière. Donc forcément la forme doit être surreprésenté plus extrêmement que dans un corpus unilingue.

→ Solution: Tgen multilingue

- Des mesures des Fréquences relatives dans des corpus séparés peut relever des résultats plus détaillés.
 - L'analyse lexicométrique dans un corpus multilingue est utile pour une analyse d'un discours international mais elle n'est pas utile pour une comparaison des discours des différents pays.
-

Merci pour votre attention!

Démarches pour former un corpus multilingue expérimental

- Tree-Tagger
 - Microsoft Excel
 - Unification des tags et ses problèmes
 - Lexico3
-

TreeTagger

TreeTagger (Windows)

Language

- English
- French
- German
- Italian
- Spanish
- Russian
- Bulgarian
- Dutch
-

Trained on

- Latin-1
- WindowsWE
- Unicode

Task

- Tag text I/O filenames pairwise in file
- Output probability tree only
- Output suffix/prefix tree only

Output for each token

- the token
- the speech-parts
- best tag only
- all tags with probability > times best tag the tag probabilities

the lemma the token in place of unknown lemma

lexical information

- none gramotron format
- proto format proto format + probabilities

Suppress status messages

Input Options

- Manual tags have probability
- Manual tags have lemma
- SGML tags present
- End of sentence tag

Tokenization Options

- none built-in own own + built-in

Own Program

- Use abbreviations file
- Use multi-word file
- Auto-detach clitics
- Auto-detach a word-final apostrophe
- Convert Windows punctuation to Latin-1
- 1-letter word followed by period is abbreviation

Tagging Options

- Use capital heuristics
- Use hyphen heuristics
- Use only lexical probabilities
- Replace zero lexical frequencies by
- Ignore prefix tree
- Auxiliary lexicon

Input File

Output File

Tree Tagger developed by Helmut Schmid 
Version for MS Windows
Graph. Interface by Ciarán Ó Duibhín, 2008/03/09 

Corpus de vérification des tags

	A	B	C	D	E	F	G	H	I	J	K	L
1	Quatre	NUM	quatre									
2	raisons	NOM	raison									
3	de	PRP	de									
4	voter	VER:infi	voter									
5	Vert	NAM	<unknown>									
6	et	KON	et									
7	deux	NUM	deux									
8	interrogations	NOM	interrogation									
9	.	SENT	.									
10	La	DET:ART	le									
11	coordination	NOM	coordination									
12	générale	ADJ	général									
13	de	PRP	de									
14	la	DET:ART	le									
15	Nouvelle	NAM	<unknown>									
16	Gauche	NAM	<unknown>									
17	,	PUN	,									
18	le	DET:ART	le									
19	24	NUM	@card@									
20	avril	NOM	avril									
21	,	PUN	,									
22	s'est	NOM	<unknown>									
23	prononcée	VER:pper	prononcer									
24	pour	PRP	pour									
25	un	DET:ART	un									
26	soutien	NOM	soutien									
27	à	PRP	à									
28	la	DET:ART	le									
29	liste	NOM	liste									
30	«	PUN:cit	«									
31	Europe	NOM	<unknown>									

Microsoft Excel - 1989.xls
Datei Bearbeiten Ansicht Einfügen Format Extras Daten Fenster ? Adobe PDF
Frage hier eingeben
Arial 10
Bereit

Corpus de vérification des tags

Lexico3 - [TextPloreur]

Fichier Traitement Fenêtre

Navigation Rapport Dictionnaire

Sélectionnez une couleur : [bleu]

Recherche :

Formes (ordre lexicométrique)	Fréquence
pun_	17935
prp_de	14727
sent_	9821
detart_la	9322
detart_l	7379
kon_et	7180
prpdet_des	6918
detart_les	6757
prp_à	4953
detart_le	4720
prp_d	4081
prp_en	3279
detart_une	3225
prpdet_du	2690
detart_un	2462
prp_pour	2354
prp_dans	2279
verpres_est	2107
prorel_qui	1892
nam_europe	1774
kon_que	1726
prp_par	1713
prpdet_au	1670
pun_.	1665
adv_plus	1351
prp_sur	1336
-	1302
puncit	1302
proper_il	1260
proper_nous	1133
adj_européenne	1129
prpdet_aux	1060
adv_pas	1021
adv_ne	1018
prodem_ce	1018
nom_pays	959

18435 formes

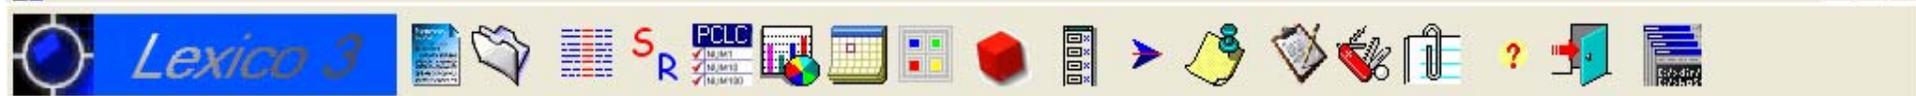
Prêt

C:\Programme\Lexico 3\1979 - 2004 F ET_forme Kleinbuchst.par

Feuille 1

<jahr=1979>
<partei=lo>
<text1=1979lo>
<text2=lo1979>
<land=frankreich>

_ " _puncit_ " prp_pour detart_les nam_états-unis adj_socialistes nom_d' europe _ " _puncit_ " nom_liste verpper_présentée prp_par nom_lutte adj_ouvrière kon_et detart_la nam_ligue nam_communiste nam_révolutionnaire pun_ (nom_section nom_francaise prp_de detart_la nam_quatrième nam_internationale pun_) sent_ . nom_liste nom_conduite prp_par nam_arlette nam_laguiller pun_ ; nam_alain nam_krivine sent_ . adj_travailleuses pun_ , nam_travailleurs pun_ , nam_l' assemblée nam_européenne kon_pour prorel_laquelle proper_nous verfutu_voterons detart_le num_10 nom_juin verpres_est verpper_présentée prp_par detpos_ses nom_partisans kon_comme detart_le nom_prélude prp_à nom_l' unification prp_de proind_tous detart_les nom_pays nom_d' europe sent_ . kon_mais proper_il nom_n' en verpres_est nom_rien sent_ . nam_l' assemblée nam_européenne versimp_n' aura proind_aucun nom_pouvoir adj_réel sent_ . detart_les nom_gouvernements kon_et detart_les adj_capitalistes nom_européens adv_ne verpres_sont adv_pas adv_près prp_de verinfi_supprimer detart_les adj_frontières prorel_qui verfutu_existeront adv_autant prp_après detart_le num_10 nom_juin adj_qu' avant sent_ . kon_et detpos_leur nam_marché nam_commun verpres_est verpper_construit prp_à nom_l' avantage prpdet_des adj_gros nom_industriels kon_et prpdet_des adj_multinationales sent_ . nam_c' est adv_pourquoi detart_les nom_travailleurs adj_manuels kon_et nom_intellectuels verfutu_n' ont nom_rien prp_à proper_en verinfi_attendre sent_ . adv_pourtant detpos_leur nom_intérêt verpres_est adv_bien verinfi_d' abolir prodem_ces adj_frontières prorel_qui verpres_ont verpper_été nom_l' objet prp_de adv_tant prp_de nom_guerres kon_et prorel_qui pun_ , adv_aujourd' hui pun_ , adv_ne verpres_servent adv_que prp_de nom_cadre prp_à detart_la nom_guerre adj_économique prorel_que proper_se verpres_font detart_les nom_trusts sent_ . kon_et adj_seuls detart_les nom_travailleurs verfutu_pourront adv_vraiment verinfi_unifier nom_l' europe pun_ , kon_car prodem_ce verpres_sont detart_les adj_seuls prp_à verinfi_pouvoir verinfi_créer detart_une adj_vaste nom_fédération prp_de nom_peuples nom_d' où verfutu_seront adv_définitivement adi_bannis nom_l' exploitation pun_ . detart_le nom_chômage kon_et detart_les



Navigation Rapport Dictionnaire

Sélectionnez une couleur: [blue box]

Recherche: [input field]

Formes (ordre lexicographique)	Fréquence
abr_i	5
abr_images	1
abr_insuffisances	1
abr_insulaires	1
abr_ivg	6
abr_km	9
abr_l	2
abr_livres	1
abr_mais	1
abr_monde	1
abr_n°	2
abr_nationalité	1
abr_nations	1
abr_natura	1
abr_nbc	1
abr_normes	1
abr_occidentale	1
abr_ocde	5
abr_on	1
abr_ong	1
abr_ont	1
abr_onu	33
abr_opa	3
abr_oser	1
abr_otan	3
abr_p	2
abr_paix	1
abr_pc	8
abr_pcf	14
abr_pci	1
abr_pdg	3
abr_pesticides	2
abr_pma	3
abr_pme	9
abr_pmi	1
abr_politique	1

18435 formes

Forme: [input] Tri: Aucun Regroupement: <Aucun> Largeur: 40

Expression rationnelle Type de documentation: Concordance Délimiteurs de séquence: ...!?/_\''"000\$

```
om_nitrates pun_ , adj_herbicides pun_ , abr_pesticides . . sent_ . pun_ ) verpres_dé
adj_chimiques pun_ ( nom_engrais pun_ , abr_pesticides . . sent_ . pun_ ) kon_et det
```

Nombre de contextes : 2

Unification des tags - quelques cas douteux

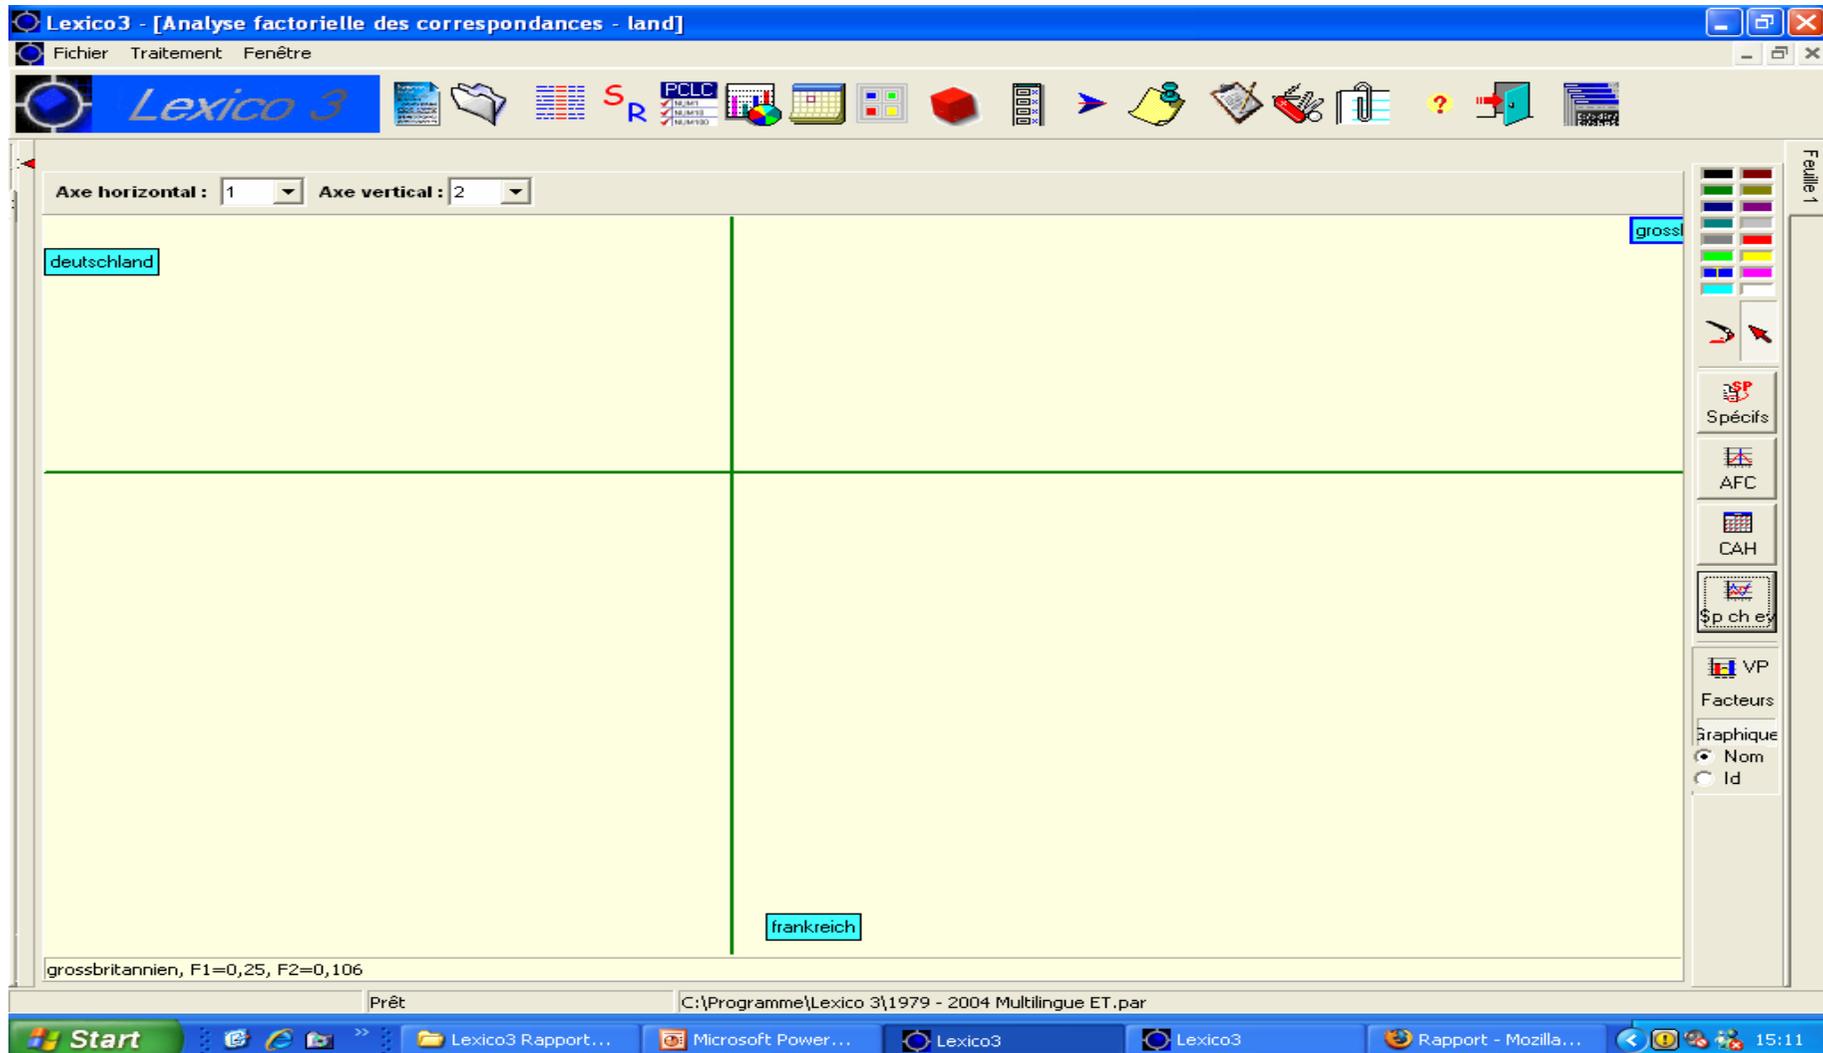
Langue taggée:	française	anglaise	allemande	Synthèse
Article	DET:ART	DT	ART	ARTPROIND
Pronom indéfini	PRO:IND	DT PDT	PIS PIAT PIDAT	
Pronom possessif	DET:POS (ma, leur) PRO:POS (mien, vôtre)	PPS (POS) WPS	PPOSS PPOSAT	PROPOS
Pronom démonstratif	PRO:DEM	(PDT)	PDS PDAT	PRODEM
Mot étranger		(FW)	(FM)	effacé
Parti verbale séparé du verbe [er kommt] an			(PTKVZ)	effacé
Particule d'infinitif avec zu [Er begann] zu [laufen].			(PTKZU)	effacé

Verbe infinitif	VER:infi	VB (be) VH+ (have) VV	VVINFINF VVIZU VAINFINF VMINFINF	VERBINFINF
Verb présent	VER:pres VER:subp	VVP VVZ VBP VBZ VHP VHZ	VVFINFINF VAFINFINF VMFINFINF	VERBFINFINF
Verbe modal		MD		
Verbe futur	VER:futu			
Verbe passé	VER:impf VER:subi (imparfait) VER:simp	VBD VHD VVD		
Participe présent actif	VER:ppre	VBG VVG VHG	ADJD/ADJA	
Verbe impératif	VER:impe		VVIMP VAIMP	
Verbe conditional	VER:cond			

Index du corpus multilingue

Forme	Fréquence	Forme	Fréquence
NOM	182869	NUM	5916
PRÄP	110775	PRODEM	5843
ARTPROIND	107009	PRON	478
ADJ	83638	SYM	452
VERBFIN	54908	INT	74
KON	40095	,	40025
ADV	33800	.	35312
NAM	31941	:	3763
VERBINF	30698	(3367
PROPER	18077	”	757
PPP	17095	'	288
PROPOS	8391)	247
PROREL	7259		

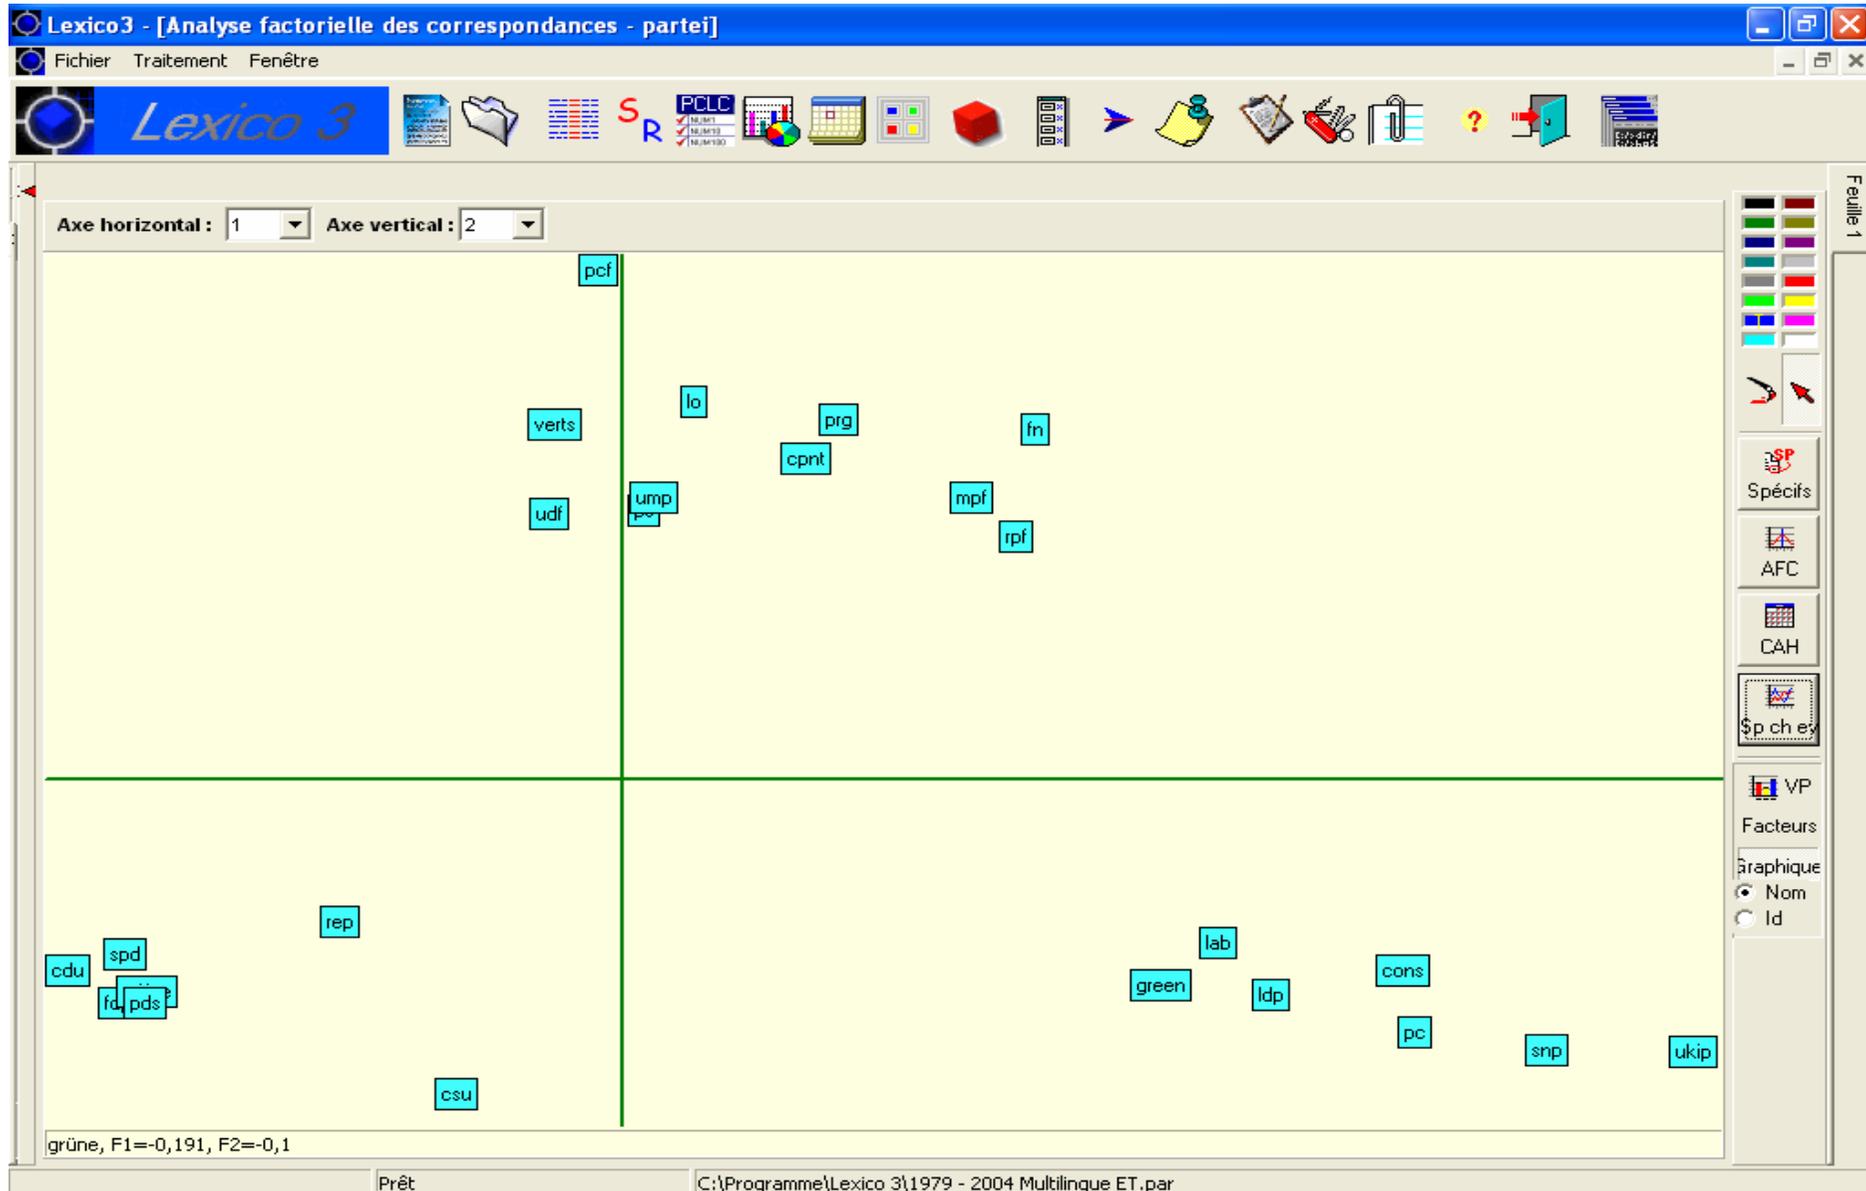
AFC de la partition <land> (pays)



Spécificités de la partition <land>

Formes	allemandes		français		britannique	
	Fréquence	Spécificité	Fréquence	Spécificité	Fréquence	Spécificité
NOM	74241	50	62901	-14	45727	-50
PRÄP	28364	-50	50387	50	32024	32
ARTPROIND	49374	50	35772	-35	21863	-50
ADJ	37420	50	24848	-50	21370	-41
VERBFIN	18988	-49	16836	-50	19084	50
KON	18159	50	12207	-50	9729	-50
ADV	12593	0	11863	0	9344	0
NAM	6226	-50	8459	-50	17256	50
VERBINF	11020	-9	9124	-50	10554	50
PROPER	6035	-31	7253	47	4789	-3
PPP	5824	-21	6124	2	5147	16
PROPOS	2772	-18	2885	0	2734	26
PROREL	2637	-2	3292	50	1330	-50
NUM	1196	-50	2879	50	1841	11
PRODEM	2222	0	3621	50	0	0
”	0	0	757	50	0	0
PRON	69	-29	88	-16	321	50
SYM	68	-26	286	34	98	-3
INT	24	0	39	3	11	-3

AFC de la partition <partei> (parti)



Spécificités de la partition <partei> des partis les plus extrêmes

Formes	CDU		CSU		PCF		UKIP	
	Fréquence	Spécificité	Fréquence	Spécificité	Fréquence	Spécificité	Fréquence	Spécificité
"		0		0	254	50		0
ADJ	7905	50	2132	22	3141	-36	329	-8
ADV	2200	-18		0	1349	-8	221	4
ARTPROIND	10566	50	2672	23	4619	-6	431	-9
INT		0	7	4	8	2		0
KON	3624	25	944	4	1592	-10	141	-7
NAM	955	-50	792	7	890	-50	438	50
NOM	15474	45	12207	-50		0	736	-16
NUM	337	-10	48	-15		0	51	4
PPP	1182	-5	302	-3		0	105	2
PRÄP	5754	-50	1549	-50	7035	50		0
PRODEM		0	328	-3	577	50		0
PRON	12	-7	85	-4	14	-2	9	3
PROPER	1184	-10	278	13	979	8		0
PROPOS	701	2	130	-2		0	78	6
PROREL	624	3	1	-4	387	3		0
SYM		0		0		0		0
VERBFIN	3642	-24		0	2020	-28	390	10
VERBINF		0	480	-12	1317	-3	197	3

Conclusions générales à partir de l'AFC

- Notre hypothèse:
« L'échelle de la ressemblance morphosyntaxique entre les partis politiques dépend de la ressemblance dans l'orientation politique de ces derniers, indépendamment du pays. » ne peut pas être confirmée. L'AFC montre bien que, au niveau morphosyntaxique, les partis se distinguent bien par rapport à la langue dans laquelle ils sont écrits. Mais sur le niveau morphosyntaxique il est possible de distinguer des partis « plus allemand », « plus français », « plus britannique » que les autres.
- Par rapport aux textes français et britanniques, la spécificité des textes **allemands** se situe au niveau des noms qui sont liés avec les articles, les adjectifs et les conjonctions.
- La spécificité des textes **français** se situe au niveau des différents pronoms. On peut dire que le discours français est pronominal, c'est-à-dire qu'il fonctionne sur des rapports entre les parties de phrase et les phrases mêmes. La grande spécificité des pronoms personnels indique un discours éthique dans le sens de la rhétorique aristotélicienne. La spécificité pronominale des textes français demande un plus grand effort de réflexion du lecteur que les textes anglais. Les pronoms créent en effet un espace virtuel tandis que les noms créent un espace plus direct et plus réel.
- La spécificité des textes **anglais** se situe au niveau des verbes conjugués et des verbes à l'infinitif, c'est-à-dire que le discours britannique suggère une plus grande activité que les textes français et allemand. Par ailleurs, les textes anglais contiennent ~~beaucoup plus de noms propres que les textes allemands et français.~~

Les oppositions linguistiques ?

Noms:	+A	-F(-14)	-GB	= A ↔ GB
Pronoms personnels	-A	+F	-GB (-3)	= A ↔ F
Chiffres cardinaux	-A	+F	+GB (+11)	= A ↔ F
Pronoms relatifs	-A (-2)	+F	-GB	= F ↔ GB
Articles et pronoms indéfinis:	+A	-F	-GB	= A ↔ F et GB
Adjectifs:	+A	-F	-GB	= A ↔ F et GB
Conjonctions:	+A	-F	-GB	= A ↔ F et GB
Prépositions:	-A	+F	+GB	= A ↔ F et GB
Noms propres:	-A	-F	+GB	= A et F ↔ GB
Verbes conjugués:	-A	-F	+GB	= A et F ↔ GB
Verbes à l'infinitif	-A (-9)	-F	+GB	= A et F ↔ GB