



HAL
open science

L'exploitation de la BDTS (Banque de Données Textuelles de Sherbrooke) au moyen d'HYPERBASE

Étienne Brunet

► **To cite this version:**

Étienne Brunet. L'exploitation de la BDTS (Banque de Données Textuelles de Sherbrooke) au moyen d'HYPERBASE. Mots: les langages du politique, 2003, Les discours de la guerre (73), pp.119-138. hal-01570515

HAL Id: hal-01570515

<https://hal.science/hal-01570515>

Submitted on 30 Jul 2017

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Etienne Brunet

L'exploration de la BDTs
(Banque de Données Textuelles de Sherbrooke)
au moyen d'Hyperbase

Parmi les grands projets de recherche que suscite l'intérêt passionné du Québec pour sa langue, les uns sont d'ordre terminologique¹, d'autres envisagent l'aspect diachronique², et certains étudient la langue, telle qu'elle est *hic et nunc*, sans s'interdire de montrer ce qu'elle devrait être. La base que nous nous proposons d'explorer est de cette dernière espèce³. Ses deux promoteurs, Pierre Martel⁴ et Hélène Cajolet-Laganière, visent à établir, à partir de l'observation, le français standard du Québec, c'est-à-dire « la variété de français socialement valorisée que la majorité des Québécois francophones tendent à utiliser dans les situations de communication formelle. » Le but ultime est la réalisation d'un dictionnaire du français au Québec, qui serait au Québec, mutatis mutandis, ce que le TLF est à la France. La méthode est en effet semblable et empruntée aux sciences de l'observation. On se propose, non pas de partir de dictionnaires existants, surtout s'ils viennent de France⁵, mais de constituer un corpus représentatif et d'y observer les usages, qu'ils correspondent ou non à ceux de l'hexagone. Ainsi avait fait Paul Imbs il y a quarante ans quand il fondait les bases du TLF, premier dictionnaire établi sur un corpus informatisé. Mais le projet québécois diffère dans la composition du corpus. Le TLF avait une assise principalement littéraire, même si quelques textes techniques (20 % du total) avaient complété la documentation, pour couvrir certaines zones de la terminologie scientifique, peu familières aux écrivains. Le rapport est inversé dans le corpus québécois où la part dévolue aux écrivains ne dépasse pas 20%. La cible n'est pas le français soutenu, non plus que le parler populaire, mais une norme standard dont la littérature, mais aussi les journaux, l'administration, les essais techniques portent témoignage.

¹ Le nom d'André Clas est lié à cette entreprise.

² Claude Poirier, responsable de la base *QuébéText*, a la charge du dictionnaire historique.

³ C'est l'un des onze corpus lexicaux que propose le réseau québécois, à l'adresse :


<http://www.spl.gouv.qc.ca/corpus/index.html>

⁴ Pierre Martel, du temps qu'il était à la tête du Conseil de la langue Française au Québec, recommandait dès 1990 la création d'un corpus original québécois. Libéré de sa charge administrative, il a mis en œuvre ce projet avec quelques collègues de Sherbrooke et de Laval.

⁵ On peut citer, parmi d'autres exemples, l'édition québécoise du *Petit Robert*. Ces tentatives ont reçu un accueil mitigé. Le temps de la colonisation linguistique est révolu. À l'image du Brésil pour le portugais et des États-Unis pour l'anglais, le Québec affirme son indépendance en matière de langue.

Le dosage des sources documentaires, retenues pour la BDTS, est le suivant : oral 10%, ouvrages didactiques 20%, textes littéraires 20%, articles de journaux 20%, textes spécialisés 30%. À l'heure actuelle les textes dépouillés constituent une masse de 37 millions de mots. D'ores et déjà, une partie de ce corpus est exploitable et disponible sur Internet. On trouvera en annexe la composition de ce corpus provisoire, qui est gros de 2 millions d'occurrences et qui répartit en huit parts égales l'oral, la littérature, les journaux, les textes sociopolitiques, administratifs, environnementaux, technologiques et scientifiques⁶. Ce corpus a été indexé et on peut l'interroger sur Internet, en lui proposant n'importe quelle entrée, comme le mot « yeule »⁷ dans l'exemple ci-dessous (figure 1).

Figure 1. Exemple de consultation de la base BDTS sur Internet



⁶ Comme le corpus littéraire n'est pas détaillé dans cette annexe, précisons qu'on y trouve un roman (*L'ange exterminé*, de Gérard Bodin), des contes et nouvelles (*Le cassé et autres nouvelles*, de Jacques Renaud, et *Contes sur la pointe des pieds*, de Gilles Vigneault), une pièce de théâtre (*La Dalle-des-Morts*, de F.A. Savard) et un essai de critique littéraire (*Écrire de la fiction*, de Noël Aubert). L'exemple de *yeule* qui fait l'objet de la figure 1 est emprunté au corpus littéraire, d'où le « joul » n'est pas absent. Mais si le joul peut à l'occasion se rencontrer dans la documentation, il n'entre pas dans la nomenclature du québécois standard.

⁷ En cinq mots l'orthographe pittoresque et suggestive de la citation évoque le parler du pays, qui n'est pas sans rappeler celui des campagnes dans l'Ouest de la France, où l'on observe pareillement l'allongement et l'épaississement du *a* précédé de *r* (*fârme*) et le relâchement articuloire qui transforme en yod une occlusive initiale : *gueule* > *yeule*, *dieu* > *yeu*, *queue* > *yeue*. Ajoutons que *pis* pour *puis* s'entend encore en France en milieu rural, et dans de nombreuses variétés sociolinguistiques.

Cependant dans le prototype mis en place la base se borne à égrener des contextes, un par écran⁸, sans donner lieu à quelque synthèse, non plus qu'à une exploitation lexicométrique. Avec l'accord des auteurs⁹, les mêmes données ont été soumises à notre logiciel HYPERBASE pour constituer une base hypertextuelle et statistique.

On trouvera ci-dessous (figure 2) le menu principal. Comme on se propose de permettre le téléchargement de cette base – si les réalisateurs de la BDTS le souhaitent et si le copyright ne s'y oppose -, notre ambition est moins d'exploiter et de commenter les résultats auxquels elles conduisent que d'expliquer leurs fonctions et leur mode d'emploi, afin que les chercheurs du Québec en fassent un usage mieux qualifié.

Figure 2. Le menu principal de la base Québec




On distinguera deux séries de fonctions : les unes, documentaires, sont groupées horizontalement au haut de l'écran, les autres, vouées à la statistique, occupent la marge droite. On n'insistera guère sur les premières, car leur utilité

⁸ Cela ne va pas sans quelque lourdeur, lorsqu'un mot a une certaine fréquence et qu'on ne dispose pas d'un haut débit. Le défilement des contextes se faisant pas à pas et exigeant à chaque citation l'intervention de l'utilisateur, le dialogue s'en trouve ralenti.

⁹ Loin d'être hostile aux méthodes lexicométriques, Pierre Martel a publié en 1992 un *Dictionnaire de fréquence des mots du français parlé au Québec* (avec Normand Beauchemin et Michel Théoret).

s'accorde avec leur facilité. Il serait oiseux de s'appesantir sur les programmes de concordance ou de recherche de contextes. Un exemple, relatif au mot de *Cambronne*, suffit à illustrer cette fonctionnalité (figure 3). Les Québécois ne sont pas bégueules plus que d'autres, mais soucieux des genres et des convenances, ils n'emploient ce mot que dans les accès d'humeur, ce qui n'est guère autorisé qu'au théâtre, dans la conversation ou dans la presse (en réalité, presque tous les exemples sont relevés dans le même journal).

Figure 3. Les contextes du mot de *Cambronne*



Mais même dans cette fonction documentaire très traditionnelle la statistique pointe son nez. Quand un mot (ou un ensemble de mots) produit une moisson suffisante de contextes (par exemple plus de 5000 pour le mot *Québec*), la fonction THEME observe tous les mots présents dans l'entourage immédiat du mot choisi pour pôle et compare la fréquence de ces corrélats dans ce sous-ensemble à celle qui est la leur dans le corpus entier. Dans la liste qui en résulte (figure 4) on découvre une constellation thématique qui circonscrit ce pays (ou la ville qui porte le même nom), avec une coloration éminemment politique : tous les corrélats sont liés au problème constitutionnel de la fédération et le *Canada* est de loin le terme le plus souvent associé au *Québec*¹⁰, avec 572

¹⁰ Les relations sémantiques ne sont pas seules en cause. La syntaxe explique la présence de certains éléments, comme *du* et *au* qu'impose l'accord avec le mot-pôle.


mentions sur 1854 (la *France* en regard fait piètre figure, avec 23 citations sur 190 et un écart réduit qui dépasse à peine le seuil).

Figure 4. L'environnement lexical du mot *Québec* (5476 contextes relevés)

Environnement d'un mot (ou groupe de mots)					seuil				
Cliquer sur un mot pour voir les contextes									
écart	corpus	texte	mot	HIERARCHIQUE	écart	corpus	texte	mot	ALPHABETIQUE
255.38	6419	5512	QUÉBEC		7.34	192	38	SCIENCES	
59.93	28364	4387	DU		3.57	202	26	SCIENTIFIQUE	
41.97	1854	572	CANADA		6.19	100	22	SCOLAIRE	
41.26	318	204	CONSTITUTIONNEL		3.93	433	49	SÉCURITÉ	
40.44	514	262	HYDRO		9.15	204	46	SEIN	
39.03	606	279	AVENIR		3.10	167	21	SEPTEMBRE	
36.83	1025	361	POLITIQUE		4.00	980	96	SERA	
34.53	120	102	SOUVERAIN		3.35	893	84	SERAIT	
30.01	336	159	SOUVERAINETÉ		4.62	737	80	SERVICES	
29.33	14864	1873	AU		11.38	3323	383	SES	
29.12	171	106	FÉDÉRATION		5.87	690	84	SEUL	
29.04	1538	385	GOUVERNEMENT		3.71	751	75	SEULEMENT	
27.44	245	123	SCIENCE		21.05	22	26	SFPQ	
25.31	1005	266	SOCIÉTÉ		3.32	222	27	SIÈCLE	
25.08	146	85	CONSTITUTIONNELLE		6.40	654	84	SITUATION	
24.92	677	206	RÉGIONS		6.10	317	48	SOCIAL	
24.33	277	119	POUVOIRS		4.92	195	30	SOCIALE	
23.68	1463	322	DÉVELOPPEMENT		5.94	174	31	SOCIALES	
23.67	184	92	INDÉPENDANCE		5.88	253	40	SOCIAUX	
23.54	278	116	GÉOGRAPHIQUE		25.31	1005	266	SOCIÉTÉ	
23.18	1405	309	QUÉBÉCOIS		5.15	2229	208	SOIXANTE	
23.15	383	138	ASSOCIATION		3.78	408	46	SOLEIL	
22.88	51	44	OMNIPRATICIEN		4.25	415	49	SOMMES	
22.51	254	106	CONSTITUTION		6.21	5166	453	SOM	
22.27	459	149	CANADIENNE		34.53	120	102	SOUVERAIN	
22.10	576	170	FÉDÉRAL		30.01	336	159	SOUVERAINETÉ	
21.67	497	153	POLITIQUES		6.65	99	23	SPÉCIALISTES	
21.05	22	26	SFPQ		17.97	207	78	STATUT	
20.86	283	106	OTTAWA		3.25	193	24	STRATÉGIE	
20.39	355	119	PROVINCES		6.93	494	71	SUD	
20.20	37	33	UQAM		10.94	64	26	SUPRÊME	
20.07	966	219	CENTRE		3.76	11931	892	SUR	

Même la lecture est assistée par la statistique. La page courante où on lit le texte met en relief (grâce à la couleur) les mots qui sont caractéristiques de ce texte, comme les termes *habitat*, *pluies acides*, *mercure*, *polluants* dans l'exemple de la figure 5, emprunté à un document sur l'environnement. Dans d'autres pages du même texte la couleur désigne à l'attention les mots qui marquent ce souci de protéger notre planète : *hydrocarbures*, *pollution*, *concentration*, *assainissement*, *toxique*, *contamination*, *phosphore*, *eau*, *lac*, *rivière*, etc. Les mots ainsi soulignés le sont parce qu'ils sont reconnus comme appartenant au vocabulaire spécifique du texte considéré, qu'on peut atteindre directement en faisant appel à la fonction SPÉCIFICITÉS. Le calcul (fondé sur la loi hypergéométrique) peut s'exercer sur les graphies et sur les lemmes, mais aussi sur les codes grammaticaux et les structures syntaxiques.

Figure 5. Mise en relief des mots significatifs




On remarquera en effet que le corpus a été lemmatisé et catégorisé¹¹, le texte de la figure 5 apparaissant dans deux séquences alignées, à gauche les formes, à droite les lemmes. En réalité, deux autres champs, pareillement alignés, contiennent les codes grammaticaux et les structures syntaxiques. On peut ainsi choisir une forme et repérer immédiatement tous les passages où elle apparaît, mais le choix peut se faire aussi sur les trois autres objets. Ainsi en cliquant sur le code *Vmif3sv* (V=verbe, m=principal, i=indicatif, f=futur, 3 = troisième personne, s=singulier), qui correspond au premier verbe (*réduira*) du précédent extrait, on peut faire défiler les 4054 contextes où un futur est pareillement employé à la troisième personne du singulier. Mais leur nombre est tel qu'on préférera les compter, observer leur distribution dans les textes du corpus (ils se concentrent dans la prose journalistique ou sociopolitique) ou faire la comparaison avec d'autres catégories. Dans la phase de préparation et d'indexation, le logiciel s'emploie à de tels décomptes, en relevant dans le corpus 2875412 occurrences (mots ou ponctuations), 67690 formes différentes et 43326 lemmes. Naturellement ces relevés sont faits aussi pour chaque texte.

En prenant appui sur les lemmes (le calcul peut se faire aussi sur les graphies, sur les codes et sur les structures), il est possible de calculer la distance

¹¹ Cette lemmatisation, due au logiciel *Cordial*, est indépendante de celle dont certains textes du corpus ont pu bénéficier à l'Université de Sherbrooke, comme indiqué en annexe. Satisfaisante dans son ensemble, la catégorisation de *Cordial* présente néanmoins quelques faiblesses, par exemple ici *polluants* est indiqué comme adjectif.

qui sépare un texte de tous les autres respectivement. Pour chaque couple de textes, on prend en compte tous les mots rencontrés et leur répartition, partagée ou exclusive, dans les deux textes. En réalité le calcul peut se faire en tenant compte ou non de la fréquence. Si l'on travaille sur V, on utilisera la formule de Jaccard, améliorée par nos soins, et l'on se bornera à enregistrer la présence ou l'absence des mots (graphies ou lemmes). En prenant en considération la fréquence et donc en travaillant sur N, on pourra utiliser la formule de Labbé¹². La figure 6¹³ dessine la carte typologique qui résume l'ensemble de ces mesures de proximité ou d'éloignement. Ainsi pourrait-on représenter la carte géographique d'un pays quand on connaît le tableau des distances de ville à ville.

Figure 6. Analyse arborée de la distance (méthode Jaccard en bas, Labbé en haut)




¹² Le coefficient de proximité qu'on obtient et qui évolue entre 0 et 1 n'a pas la vertu différentielle que son auteur lui alloue. C'est une mesure globale qui ne distingue pas, dans la distance observée, ce qui tient à l'écrivain, au genre, à l'époque et au sujet et qui ne permet en aucune façon de dire si Molière et Corneille sont un seul et même auteur.

¹³ La synthèse et la représentation du tableau des distances sont dues à Luong et Barthélémy, inventeurs de l'analyse arborée, que nous avons incorporée au logiciel HYPERBASE.

Observons toutefois que seule compte la longueur des segments qu'il faut suivre pour aller d'un point à un autre ; les angles, les directions et l'orientation sont arbitraires et indifférents. Cela ne gêne en rien la lisibilité et la stabilité du résultat, les huit graphes obtenus étant superposables, quelle que soit la méthode utilisée et quel que soit l'objet analysé. Aux deux bouts opposés du graphe, on retrouve toujours les deux mêmes paires : enquêtes orales et littérature d'une part, textes scientifiques et techniques d'autre part. À ce dernier couple se rattachent étroitement les textes sur l'environnement. Deux types de texte sont toujours associés, dans une position médiane : les textes sociopolitiques et les journaux. Restent les textes administratifs : ils accompagnent, assez mollement, ce couple, tout en se rapprochant des textes techniques. Tout se passe comme si la typologie des discours était polarisée par l'opposition monde humain vs monde physique. De l'individu (oral et littérature), on passe à la société (presse et sociologie), puis à la gestion de l'État et de la planète (l'homme y tient encore un peu de place), et enfin aux objets physiques de la technique et de la science. En s'appuyant sur le même tableau de distances, l'analyse factorielle (de correspondance) propose une typologie tout aussi claire (figure 7).

Figure 7. Analyse factorielle de la distance intertextuelle




Comme les autres graphes se recoupent, seul est reproduit celui qui concerne les graphiques selon le calcul Jaccard. Cette fois l'espace est orienté et les points cardinaux ont une signification : le premier facteur, qui concentre la plus grande

part de la variance (82%) et qui oppose la droite et la gauche, met en relief la tension humain/non humain. Les points s'ordonnent en formant un croissant, comme il arrive souvent dans les données sérielles, et en suivant l'ordre proposé par l'analyse arborée.

D'aucuns penseront que le choix des sujets gouverne partiellement les alliances et les oppositions. Il est peu probable en effet que les conversations et les contes traitent des mêmes questions que les traités scientifiques. Tout ne se réduit pas pourtant au thème, puisque l'analyse des codes et des structures syntaxiques – d'où le sujet est radicalement absent – reproduit la même typologie. Il reste cependant une incertitude : les graphes qui précèdent montrent les positions, mais sans les expliquer. Or il est un moyen, au moins dans l'analyse des codes grammaticaux, de percer le secret. Constituons un tableau à deux dimensions, dont chaque case indiquera l'effectif d'une partie du discours dans un texte particulier. On élimine ainsi l'influence du thème en évacuant le sens des mots et en ne retenant du texte que l'aspect grammatical. Cette fois l'analyse factorielle peut représenter en même temps les lignes (les parties du discours) et les colonnes (les textes), ce qui permet de mettre en rapport les unes et les autres et de transformer l'observation en explication.

Figure 8. Les parties du discours. Analyse factorielle.



Considérons en effet les éléments qui figurent en rouge sur le graphe et qui représentent les lignes du tableau. Comment ne pas voir qu'ils s'ordonnent pareillement en deux camps, dont la rivalité a été maintes fois constatée dans d'autres corpus. Le verbe campe solidement à droite, en compagnie de ses acolytes habituels : pronoms, adverbes et subordonnants. Le substantif règne à

gauche, qu'il s'agisse du nom propre ou du nom commun. Les déterminants l'accompagnent, et aussi les adjectifs, les numéraux et les prépositions¹⁴. Or dans cet univers grammatical bipolaire, les types de discours s'ordonnent de la même façon que dans les analyses précédentes : l'oral et le littéraire à droite, dans la zone d'influence du verbe, le technique et le scientifique à gauche, parmi les catégories nominales. On retrouve ici comme ailleurs les lignes de force qui structurent le discours et qui sans doute ne sont pas propres au français, qu'il soit québécois ou hexagonal. Nous les avons observées dans le grand corpus de *Frantext*, qui recouvre cinq siècles de notre histoire, et aussi dans un corpus plus récent que nous avons constitué, sous le nom de *Francil*, avec des données extraites des pays francophones – et qui contenait certains textes du présent corpus. Nous renvoyons là-dessus à notre étude parue dans la *Nouvelle histoire de la langue française*¹⁵. Nous observions que la dichotomie traditionnelle qui a longtemps opposé l'oral et l'écrit a perdu de sa vigueur, et que s'y substitue une opposition grandissante entre le littéraire et l'utilitaire. Le français utilitaire, celui de l'information et de l'exposé scientifique, utilise systématiquement le substantif et ne recourt plus guère au verbe, simple copule de transfert ou d'égalité, analogue au signe = dans les développements mathématiques. Par opposition à ce troisième larron¹⁶, venu troubler la partie, l'oral et le littéraire, qui tous les deux exploitent les ressources expressives du verbe, ne se trouvent plus face à face, mais côte à côte. C'est exactement leur position dans le graphique 8.

D'autres faits linguistiques se lisent dans la même figure, qui influencent surtout le second facteur et dont la cause est aisée à découvrir. Passons sur les interjections, qui ne sauraient trouver refuge ailleurs qu'au voisinage de l'oral et de la littérature. Un scientifique qui se respecte ne saurait lâcher un « tabernacle¹⁷ » au cours de son exposé. Passons sur les ponctuations : qu'elles soient des pauses provisoires, comme la virgule, ou des haltes dans le discours, comme les points, elles produisent une segmentation beaucoup plus serrée dans le discours littéraire et plus encore à l'oral. La phrase de l'exposé technique est plus longue, alors même que les verbes y sont plus rares. Reste à expliquer l'antinomie marquée sur l'axe vertical entre les noms propres et les noms communs. Le discours scientifique ne connaît guère que ces derniers. Les rares

¹⁴ La syntaxe explique la liaison forte qui s'établit entre le substantif et les déterminants. Elle ne justifie qu'en partie la relation substantif-préposition, car la préposition peut introduire aussi bien un pronom et un infinitif. De plus beaucoup de prépositions entrent dans la composition des subordonnants et annoncent une proposition subséquente, et donc un verbe.

¹⁵ Sous la direction de Jacques Chaurand, *Le Seuil*, 1999, « Ce que disent les chiffres », 673-727.

¹⁶ En réalité ce troisième larron était déjà dans la place, aux temps anciens. Il régnait dans le sabir des gens de loi, d'église ou de médecine. Mais il est vrai qu'il parlait latin et que l'honnête homme s'en tenait éloigné.

¹⁷ Il y a 40 occurrences de « tabernacle » dans le corpus, toutes observées à l'oral, sauf six exemples relevés dans la presse et une citation – allusive – dans un texte sociologique.

noms propres qu'il accepte sont ceux des savants qui ont donné leur nom à une loi, à un théorème, à une mesure¹⁸ ou des marques qui revendiquent un brevet ou un produit ou ceux des collègues dont on approuve ou dont on conteste les dires. Dans les sciences sociales ou politiques au contraire, le discours est localisé et personnalisé, il est inscrit dans un cadre historique dont les références sont des lieux, des dates (les dates sont des sortes de noms propres dans le temps) et des personnages publics.

On vient de constater que les tendances aperçues dans la base *Frantext* trouvaient un écho dans la présente base. N'en concluons pas trop vite que les deux corpus se recouvrent. Nous avons vu que leur composition diffère. Dans le temps *Frantext* déborde la *BDTS* puisque cinq siècles y sont entassés, alors que le corpus *BDTS* est une coupe synchronique de faible épaisseur. Dans l'espace des champs disciplinaires, c'est l'inverse : *Frantext* paraît étroitement littéraire auprès de la *BDTS*, qui englobe une gamme étendue de discours diversifiés. Si on rapproche les deux corpus l'un de l'autre grâce à un calcul de spécificités (c'est le plus gros corpus, donc *Frantext*, qui sert de norme au plus petit), l'irrédentisme du Québec apparaît de façon irréductible (figure 9). Non que les coutumes locales soient mises en évidence : il n'y a guère que le premier mot de la liste (*Canada*) qui soit la marque d'un territoire et quelques indices (*pis, comté, dollars*), au reste peu significatifs¹⁹. Vu de *Frantext*, le corpus québécois semble un univers de comptables et d'ingénieurs, où les chiffres sont la préoccupation majeure (*cent, taux, neuf, zéro, mille, vingt, quatre, soixante*) et où l'activité, utilitaire et matérielle, évolue entre la recherche scientifique (*systèmes, données, particules, résultats*), la production industrielle (*acides, substances, traitement, processus, utilisation, développement*) et la gestion publique (*ministère, municipalité, constitution*). La liste est, bien sûr, beaucoup plus longue que le court extrait que nous présentons, mais les substantifs continuent à y exercer une écrasante majorité et leur tonalité ne varie pas. On risque donc de ne pas obtenir exactement ce que l'on recherchait, à savoir l'image contrastée des discours tenus en France et au Québec, mais le résultat trop prévisible de choix différents dans la constitution des corpus. On a souvent reproché à *Frantext* de ne pas être la référence extérieure, universelle et neutre dont on a besoin. C'est trop demander : un corpus, si vaste soit-il, même diversifié, même étalonné, ne sera jamais la référence absolue, comme le niveau de la mer. Cela est vrai pour *Frantext*, et, pour les mêmes raisons, de la *BDTS*.

¹⁸ Mais dans ce cas la minuscule est vite adoptée, ce qu'on observe avec joule, ampère, watt, ohm, berquerel, bel et décibel, etc.

¹⁹ Curieusement c'est la liste des spécificités négatives (colonne de droite du tableau 8), qui fournit l'indice le plus clair. Quand on connaît le sous-emploi au Québec de la négation *ne*, trouver ce mot en tête des déficits est un signe non trompeur.

Figure 9. Les spécificités de la BDTS par rapport à Frantext

N°	écart	corpus	texte	mot	N°	écart	corpus	texte	mot
644.41		120	1854	Canada	-90.92	267396	7435		ne
508.85	4092129924)			-90.89	235834	5859		elle
492.60	5023	9496	cent		-90.81	171164	2805		vous
416.15	68	902	acides		-84.51	141768	2140		me
372.60	70	820	taux		-80.36	147626	2819		lui
362.95	1898	4273	pis		-76.63	30059711191			qu'
336.23	3598	5537	neuf		-72.86	205106	6504		n'
292.07	310	1367	zéro		-67.62	92788	1460		m'
252.49	46	451	substances		-64.91	124605	3202		avait
250.03	6828	5904	mille		-63.86	30581613326			pas
248.53	100	657	utilisation		-62.93	148707	4626		était
247.37	7910	6334	vingt		-61.70	157060	5194		j'
239.23	236	978	dollars		-57.19	157506	5685		mais
224.58	222	891	lacs		-57.17	79885	1669		mon
222.52	11107	6949	quatre		-56.12	115651	3542		sa
220.75	1361	2229	soixante		-55.91	136791	4685		tout
219.57	36	347	particules		-54.90	43115922381			que
215.60	142	682	activités		-54.77	143578	5166		son
214.37	876	1723	ministère		-53.57	82020	2040		moi
213.05	646	1463	développement		-52.86	202774	8735		se
211.70	120	615	aval		-52.35	55831	885		ma
203.40	96	528	processus		-51.67	92692	2725		ai
195.06	73	441	municipalité		-50.90	97700	3048		bien
190.58	40	318	constitution		-50.57	72487	1788		dit
183.64	182	661	systèmes		-47.85	22922010919			ce
182.70	535	1144	données		-47.27	51679	1003		rien
180.85	670	1273	résultats		-46.69	182948	8275		s'
179.92	152	591	stations		-44.46	75370	2369		sans
173.88	122	511	augmentation		-43.92	36265	489		homme
172.39	46	309	comté		-42.69	90585	3323		ses
170.44	83	412	utilisé		-41.42	136680	6079		comme
168.11	404	913	traitement		-39.67	103601	4304		si

En revanche les comparaisons internes se justifient aisément, puisqu'un corpus est expressément conçu pour mettre en valeur les différences qui opposent les textes que l'on réunit dans le même ensemble. Si le corpus est hétérogène, l'intérêt est faible et les spécificités auront un aspect trivial. S'il est homogène, le calcul relèvera toujours des écarts et des nuances que la conscience linguistique peut n'avoir pas sentis au premier abord. Afin de rester dans une relative homogénéité, nous ne présentons dans le tableau 10 que quatre sous-ensembles « humains », en rejetant à l'extérieur les textes qui s'occupent d'autre chose : de science, de technique et d'environnement. Ce qui frappe d'abord c'est le parallélisme des deux premières colonnes, vouées aux enquêtes et à la littérature. Certes les expressions trop populaires qu'on relève dans certaines interviews (*pis, ben, pron, faque*) ne sont pas de mise chez les écrivains. Mais le discours fait appel aux mêmes embrayeurs, particulièrement aux pronoms des deux premières personnes, aux démonstratifs (*ça* ou *ce*), aux verbes simples (*être, faire, dire, penser*), à la conjonction *que*, aux ponctuations fortes (surtout le point d'interrogation). On pourrait songer à attribuer au théâtre ces points de convergence, si le théâtre était dominant dans le sous-ensemble littéraire. Or on n'y trouve qu'une pièce, de faible étendue. Une meilleure explication serait à rechercher dans le style des romans ou contes qui ont du succès au Québec et qui font la part belle au dialogue. Ceux qui ont été choisis

dans le corpus exploitent en effet cette veine populaire. Mais on aime à croire aussi que les mêmes ressources du langage sont communes à l'expression orale et à l'expression littéraire, comme on vient de le voir.

Tableau 10. Le vocabulaire spécifique de quatre sous-ensembles (extrait)


Enquêtes (formes)	Littérature(formes)	JOURNAL (formes)	ADMINISTRATION (formes)
N° Ecart Corpus Texte Mot	N° Ecart Corpus Texte Mot	N° Ecart Corpus Texte Mot	N° Ecart Corpus Texte Mot
1 32.82 7059 5428 ça	2 32.82 345 345 Didace	4 32.81 966 571 centre	5 32.82 963 774 article
1 32.82 5394 4012 là	2 32.82 303 303 Phonsine	4 31.34 336 279 illustration	5 32.82 955 766 président
1 32.82 4273 4075 pis	2 32.82 273 248 ti	4 30.50 978 517 dollars	5 32.82 948 889 employé
1 32.82 1375 1118 ben	2 32.81 7626 2785 je	4 30.23 10163 2676 :	5 32.82 393 347 règlement
1 32.82 1341 1341 pron	2 32.81 5859 2604 elle	4 29.65 258 229 doc	5 32.82 317 296 employeur
1 32.82 1010 760 sais	2 32.81 5724 3668 !	4 24.24 48818 9650 -	5 32.82 312 284 syndicat
1 32.82 559 413 états	2 32.81 2819 1165 lui	4 23.39 444 266 parti	5 32.82 301 272 employée
1 32.82 398 398 faque	2 32.81 2805 1064 vous	4 22.76 972 426 Montréal	5 32.82 274 255 leader
1 32.82 213 201 cabane	2 32.81 2140 944 me	4 22.65 191 158 94	5 32.82 238 234 indemnité
1 32.81 13326 3655 pas	2 32.81 1669 721 mon	4 22.45 145 133 gène	5 32.82 225 224 motion
1 32.81 12624 3994 on	2 32.81 973 499 puis	4 22.33 245 181 science	5 32.82 201 201 alinéa
1 32.81 10297 4880 c'	2 32.81 816 532 t'	4 22.20 9496 2283 cent	5 32.81 1723 1108 ministère
1 32.81 7626 3350 je	2 32.81 447 342 yeux	4 21.10 5904 1525 mille	5 32.81 1426 619 travail
1 32.81 6671 2183 y	2 32.80 19893 4547 il	4 20.93 813 360 recherche	5 32.81 1210 882 loi
1 32.81 6307 2063 ?	2 32.80 6307 2078 ?	4 20.84 782 350 etc	5 32.81 1179 851 ministre
1 32.81 5194 3117 j'	2 32.80 6079 1679 comme	4 20.76 656 312 intérêt	5 32.81 1176 648 projet
1 32.81 4626 2269 était	2 32.80 3542 1124 sa	4 20.25 1665 575 ans	5 32.81 947 499 commission
1 32.81 4320 1218 fait	2 32.7914547526708 ,	4 19.91 203 149 photo	5 32.81 773 534 emploi
1 32.81 4282 1541 ils	2 32.7911482321653 .	4 19.88 133 116 actualité	5 32.81 572 436 avis
1 32.81 3535 2496 tu	2 32.55 195 195 Acayenne	4 19.77 470 245 1994	5 32.81 392 301 assemblée
1 32.81 3202 1538 avait	2 32.32 1460 625 m'	4 19.57 278 177 géographique	5 32.80 9235 2868 ou
1 32.81 2725 1554 ai	2 32.21 195 194 Philomène	4 17.94 85 82 Festival	5 32.71 224 211 travailleur
1 32.81 2471 1248 quand	2 31.31 5166 1418 son	4 17.80 408 209 Soleil	5 31.83 255 223 dispositions
1 32.81 2140 899 me	2 31.11 5194 1419 j'	4 17.48 579 258 longueur	5 31.64 291 239 vertu
1 32.81 2040 1305 moi	2 30.70 8735 2072 se	4 17.29 307 172 presse	5 31.60 16552 3252 a
1 32.81 1669 745 mon	2 30.42 1788 681 dit	4 16.79 245 147 Devoir	5 31.21 339 257 date
1 32.81 1460 619 m'	2 30.41 10297 2342 c'	4 16.59 229 140 milliards	5 30.96 215 198 congé
1 32.81 1357 569 va	2 29.08 4685 1274 tout	4 16.53 299 164 explique	5 29.50 423 277 revenu
1 32.81 970 441 eu	2 28.01 13326 2785 pas	4 16.37 469 216 université	5 29.32 441 282 municipalité
1 32.81 948 510 parce que	2 27.81 564 320 tête	4 16.29 178 119 Claude	5 29.27 881 415 droit
1 32.81 944 515 suis	2 27.81 448 281 coeur	4 16.04 192 123 sciences	5 28.74 383 257 employés
1 32.81 889 485 oui	2 27.55 489 293 homme	4 15.97 6334 1476 vingt	5 28.26 50642 8062 l'
1 32.81 713 483 vraiment	2 27.53 213 184 silence	4 15.31 115 88 libéral	5 27.46 1538 555 gouvernement
1 32.81 673 425 pense	2 27.26 1003 442 rien	4 15.16 70 65 photographe	5 27.44 283 210 régie
1 32.81 638 382 as	2 26.91 400 257 toi	4 14.92 66 62 éditorial	5 27.41 214 180 délai
1 32.81 619 415 avais	2 26.83 11191 2385 qu'	4 14.90 99 79 gènes	5 27.16 913 401 traitement
1 32.81 619 408 faisait	2 26.80 885 405 ma	4 14.63 203 119 Robert	5 26.50 285 205 prévu
1 32.81 584 344 hiver	2 26.26 313 220 rue	4 14.54 6504 1470 n'	5 26.38 369 235 décision
1 32.81 509 348 ah	2 25.52 3323 933 ses	4 14.42 173 107 août	5 26.03 133 131 n°
1 32.81 404 277 gars	2 25.33 8275 1839 s'	4 14.29 109 81 encadré	5 25.93 169 151 convention
1 32.8011482322632 .	2 25.32 140 135 demanda	4 14.26 295 147 équipe	5 25.73 871 375 jours
1 32.80 28436 5271 est		4 14.07 58 55 embryon	5 24.54 51597 7965 le
1 32.80 22381 3566 que			5 24.51 323 206 comité
1 32.80 19893 3995 il			5 24.30 194 155 prévue
1 32.80 16552 2837 a			5 23.32 156 133 copie

Nous laisserons au lecteur le soin de voir ce qui peut rapprocher ou opposer les deux autres colonnes, dévolues aux textes journalistiques et administratifs. Les textes sociopolitiques, si l'espace ne nous était pas mesuré, auraient trouvé place entre les deux. Ces trois sous-ensembles appartiennent à la langue générale, plus diversifiée et presque désordonnée dans la presse, plus spécialisée et concentrée dans l'administration.

On laissera pareillement au lecteur le soin d'interroger la base et d'y exploiter beaucoup de fonctions qu'on ne peut détailler ici. L'accès aux codes grammaticaux et aux structures syntaxiques permet des investigations jusque là

impraticables. Un exemple relativement simple de ces structures est montré dans la figure 11 : il s'agit des séquences adjectif+substantif et substantif+adjectif, autrement dit, de l'anté- ou post-position de l'adjectif. Certains adjectifs admettent les deux constructions, parfois en changeant de sens (*un grand homme* vs *un homme grand*), mais la plupart ont une préférence pour l'une ou pour l'autre. Le graphique indique que l'antéposition est le fait de ceux qui surveillent leur plume, écrivains ou journalistes, alors que la postposition est en faveur lorsqu'on veut seulement transmettre une information. Toutes les combinaisons qu'elles soient à deux, trois ou n éléments sont recensées et indexées par le logiciel, ce qui donne accès à des recherches documentaires ou statistiques fort complexes.

Figure 11. Courbes de l'adjectif antéposé et postposé




La phraséologie, le rythme du discours, voire les sonorités, tout est sujet à mesure, et parfois à découverte, y compris même la thématique. Il ne s'agit pas seulement de circonscrire une constellation de corrélats autour d'un mot, comme indiqué dans la figure 4. Ni de caractériser un texte par un ensemble d'extraits spécifiques²⁰. L'ambition, permise par un traitement sémantique de *Cordial*, vise à rendre compte des idées, des sentiments, des actions, bref des thèmes exprimés dans un texte. En réalité *Cordial* fait appel à un thésaurus de référence, où sont cataloguées les disciplines, les concepts et les connaissances. Tout un jeu

²⁰ Le calcul des spécificités est appliqué non seulement aux formes, aux lemmes, aux codes grammaticaux et aux structures syntaxiques mais aussi aux phrases caractéristiques.

d'étiquettes hiérarchisées est mis en place, parmi lesquelles chaque mot du texte doit faire son choix. Sans doute ces étiquettes sont-elle parfois trop proches des représentations modernes, et s'appliquent-elles malaisément à certains corpus, sans compter les bévues auxquelles l'homographie et même la polysémie peuvent donner lieu. Derrière « cinétique » on peut comprendre « mouvement »; mais que recouvrent les termes d' « interdépendance », de « production » et de « grandes-notions »?

Figure 12. Analyse factorielle des thèmes



Pourtant, malgré les faiblesses et les incertitudes du codage sémantique, les résultats auxquels il conduit ne sont pas dénués d'intérêt. On les a reproduits dans la figure 12. On y découvre que la même aimantation des textes, déjà observée au niveau lexical et syntaxique, se retrouve au niveau thématique.

En conclusion, on pourrait s'étonner que l'on puisse obtenir la même image, alors que les objets considérés sont étrangers les uns aux autres. Certes entre les lemmes et les graphies, il y a une part commune. Les premiers sont un regroupement des secondes. De même un pont relie les codes aux structures, ces dernières étant des combinaisons de codes. Mais quel lien nécessaire existe-t-il entre les lemmes et les codes grammaticaux? Ou entre les graphies et les structures? Sans parler des codes sémantiques, dont la délimitation est incertaine. On pourrait imaginer que les sous-ensembles du corpus s'orientent différemment, selon le point de vue mis en œuvre, de même que la carte d'un

pays est susceptible de configurations variables, selon qu'on envisage les élections, les revenus, les convictions religieuses, l'espérance de vie ou la fécondité. Et pourtant les sociologues savent que les variables que l'on croit indépendantes sont parfois liées par des accords secrets ou par une commune soumission à une influence cachée. Ainsi en est-il de la surdétermination du langage.

Annexe : Composition du corpus BDTs

Source : Centre d'analyse et de traitement informatique du français québécois (CATIFQ).

Le présent corpus comprend quelques deux millions d'occurrences (61 843 formes) tirées de 1054 textes différents. Il constitue un sous-ensemble de la BDTs (qui contient plus de 37 millions de mots à l'heure actuelle). Ce corpus est composé de huit sous-ensembles d'environ 250 000 mots chacun et traités selon une norme commune, ce qui rend leurs données comparables; plusieurs d'entre eux sont en outre lemmatisés. Ils sont représentatifs de divers domaines, types de discours et niveaux de langue suivants :

1. Textes techniques : langue spécialisée

Corpus constitué par Normand Maillet. Corpus lemmatisé. 8384 vocables. 12 513 unités complexes ou syntagmes.

Composition : 100 textes extraits de rapports, guides, manuels de formation, normes, procédures, etc.

Domaines : aluminium, environnement, mines, pâtes et papier, télécommunication, transport, hydro-électricité, informatique, et autres.

2. Textes scientifiques : langue spécialisée

Corpus constitué par Linda Pépin. Corpus lemmatisé. 8653 vocables. 2257 unités complexes ou syntagmes

Composition : 100 textes extraits de mémoires, de thèses, d'articles scientifiques et de rapports de recherche.

Domaines : biologie, chimie, physique, génie chimique et génie mécanique.

3. Textes sociopolitiques : langue générale

Corpus constitué par Nadine Vincent. Corpus lemmatisé. 8355 vocables

Composition : 100 textes de mémoires sélectionnés à partir des 583 mémoires présentés à la Commission.

Domaines : mémoires ou extraits de mémoires de la Commission Bélanger-Campeau.

4. Textes administratifs : langue générale. Corpus non lemmatisé

Composition : 54 textes

Domaines : débats de l'Assemblée nationale, conventions collectives, textes juridiques, textes du Bureau d'audiences publiques sur l'environnement (BAPE), rapports du vérificateur général du Québec, etc.

5. Textes journalistiques : langue générale. Corpus non lemmatisé

Composition : 52 textes tirés de *L'Actualité*. 55 textes tirés du *Devoir*. 17 textes tirés d'*Interface*. 63 textes tirés de *La Presse*. 57 textes tirés de *Québec Science*. 75 textes tirés du *Soleil*

6. Textes littéraires : langue générale

Corpus non lemmatisé

Composition : 25 textes

Domaines : romans, chansons, essais, textes de poésie, pièces de théâtre, etc.

7. Textes environnementaux : langue générale

Corpus constitué par Steeve Tremblay. Corpus semi-lemmatisé

Composition : 107 textes

Domaines : textes divers du ministère de l'Environnement du Québec, journaux, périodiques et magazines spécialisés dans le domaine, etc.

8. Textes oraux : langue générale

Corpus constitué par Gérard Charland. Corpus lemmatisé

Composition : 20 enquêtes

Domaines : enquêtes sociolinguistiques effectuées dans la région des Bois-Francs