

電子コーパスを使ったフランス語研究 今だからできることー

2001.9.19

1. 英語研究と電子コーパス :

<http://www.lang.nagoya-u.ac.jp/~takizawa/KokaiCorpusIntro.html>

- 始まり (1960 年代)

Brown Corpus (アメリカ英語)

LOB Corpus (イギリス英語)

1961 年に出版された 15 のジャンルを代表する各 2000 語の 500 のサンプルからなる約 100 万語のコーパス

- 大規模なコーパス (1990 年代)

The bank of English: 4 億 8 千万語

The BNC World Edition: 9000 万語の書き言葉と 1000 万語の話し言葉 (2001 年)

- コーパスを活用した文法書・辞書

1998 年 : コーパス言語学関係の書物の大量出版 (英語)

1999 年 : 本格的な文法書

- コーパスは記述研究むけ

言語学における経験主義と演繹主義, 実例と作例, 観察と直観

コロケーション

- コンピュータを使った研究 : データの大量・高速・正確な処理

2. フランス語の問題 (フランス語と日本語の文字コード)

日本語環境の中でフランス語を使うということにまつわるさまざまな問題がある。

情報が少ない。うまくいかない理由がわからない。OS によって動き方が違うなどの個別的な問題がある。英語で可能であっても、フランス語では不可能なのが普通。さまざまな試行錯誤、工夫が必要

例えば : Frantext を使っても、コピーができなければ役に立たない。

フランス語と UNIX:

http://www.lang.nagoya-u.ac.jp/~fujimura/memo/french_unix.html

3 . フランス語研究とコーパス

Benoît HABERT, Adeline NAZARENKO, André SALEM : Les linguistiques de corpus, Armand Colin (1997)

3.1.本来型のコーパス

A. FRANTEXT:

Centre National de la Recherche Scientifique(CNRS) に属する Institut National de la Langue Francaise (INaLF) が、1957 年から "Tresor de la Langue Francaise" の編纂のために作成したテキストデータベース。中世から 20 世紀までのおよそ 2000 タイトルを含む。大学などの研究機関が利用契約を結ぶ。

FRANTEXT peut se définir comme un vaste corpus, à dominante littéraire, constitué de textes français qui s'échelonnent du XVIe au XXe siècle. Sur l'intégralité du corpus, il est possible d'effectuer des recherches simples ou complexes (base non-catégorisée). Sur un sous-ensemble comportant des œuvres en prose des XIXe et XXe siècles, les recherches peuvent en outre répondre à des critères syntaxiques (base catégorisée).

テキストの種類に偏りがある： 「立派な」書き言葉、8割は文学作品
書簡集，弁論，隨筆，論文集，回想録，風刺文，詩，紀行文，散文，小説，戯曲，概論，韻文：

総語数: 187429462

ex. 1950 年以降のテキスト : 475 点

Nombre d'occurrences dans le corpus : 309610782970.

cf: Cobuild Direct

<http://www.cobuild.collins.co.uk/cdguide/svenguide.html>

Full title	Size (million words)
Australian news	5.3
UK ephemera	3.1
UK magazines	4.9
UK spoken	9.3

US ephemera	1.2
BBC World Service	2.6
National Public Radio	3.1
UK books	5.3
US books	5.6
Times newspaper	5.7
Today newspaper	5.2

1) est tombé : 1331, a tombé : 33

<http://prairie.lang.nagoya-u.ac.jp/~fujimura/shuchu/atombe.crp>

<http://prairie.lang.nagoya-u.ac.jp/~fujimura/shuchu/avortombe.crp>

Menu de Frantext Vous pouvez consulter des exemples complets de remplissage de formulaire

Remplissez le formulaire ci-dessous et pour soumettre la demande ou

1) Partie du formulaire à remplir obligatoirement

2) Partie du formulaire à ne remplir que si vous cherchez des co-occurrences

2.1) Définition de la séquence 1 : avoir (tombé/tombée)

2.2) Définition de la séquence 2 : la veste

2.3) Définition de la séquence 3 :

2.4) Définition du contexte de la co-occurrence

Toutes les séquences doivent être :

Dans une même phrase (option par défaut) Pas nécessairement dans la même phrase

2.4) Définition des positions relatives des séquences

Positions relatives des séquences 1 et 2 : 1 AVANT 2 Distance maximale: 4

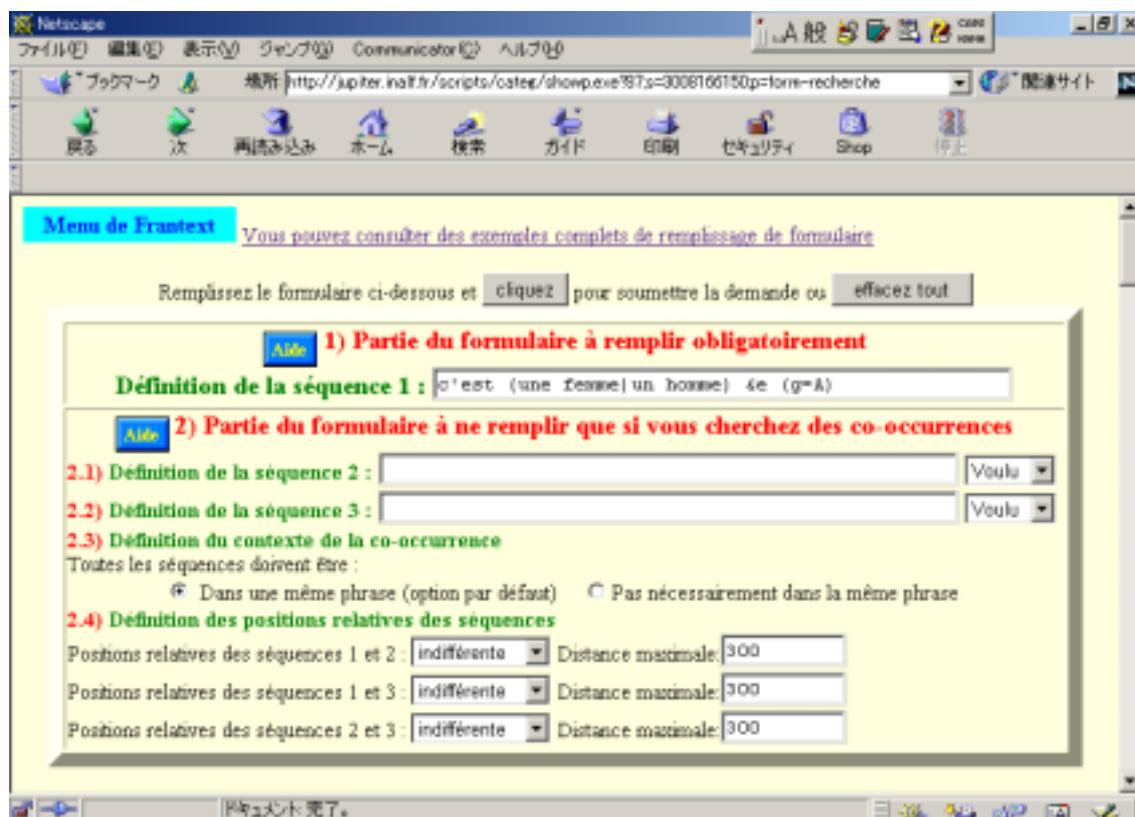
Positions relatives des séquences 1 et 3 : indifférente Distance maximale: 300

Positions relatives des séquences 2 et 3 : indifférente Distance maximale: 300

Rôle du catégoriseur

Un catégoriseur est un programme ayant pour fonction de découper un texte en une suite de segments auxquels il va attribuer une catégorie grammaticale. Généralement un segment comprend un seul mot, mais il peut arriver qu'un segment en

contienne plusieurs, dans la mesure où ce segment peut être considéré comme une entité grammaticale insécable (par exemple une locution adverbiale). Aucune norme ne définit l'ensemble des catégories attribuées: chaque catégoriseur possède donc son propre ensemble de catégories (voir l'ensemble des catégories définies dans le cas de Frantext).



B. Discotext: 1827 年から 1923 年までのフランス語の文学作品 300 点を収録した CD-ROM。1992 年。MS-DOS 対応。FRANTEXT の一部分を収録したもの。

C. European Language Resources Association

<http://www.icp.grenet.fr/ELRA/home.html>

3.2. 流用型のコーパス:

3.2.1.CD-ROM

Le Monde 1997-98: 320MB

Le Monde Diplomatique 1984-98: 約 1320 万語 , 82.6MB

3.2.2.Web 上のコーパス

3.2.2.1.Bibliotheque nationale de France

http://gallica.bnf.fr/textesListe.htm#_F

フランスの Bibliotheque nationale の電子化された資料（印刷刊行された著作と画像）を公開する圧倒的な規模をもつ画期的なサイト。当初はフランス 19 世紀を対象としていたが、"Gallica Classique" が新たに登場し、中世から 1914 年にまで至るフランスの著作の相当部分をカバーするようになった。

3.2.2.2.Le project Goutenberg

<http://promo.net/pg/index.html>

英語のコーパスが中心だが、フランス語の作品も現在のところ 23 点ある。他の言語のものもある。

3.2.2.3.GOOGLE:

<http://www.google.com>

"aller +au +coiffeur": 26	"aller +chez +le coiffeur":	396
"aller +au docteur": 47	"aller +chez +le docteur":	153
"aller au professeur": 1	"aller +chez le professeur":	18
"aller +au +mes parents": 0	"aller +chez +mes parents":	61
"travaille à Renaud": 6	"travaille chez Renault":	43
"travaille à IBM": 6	"travaille chez IBM":	73
"+à Coubertin": 499	"chez Coubertin":	2
"aller +en pied": 4	"aller +à pied":	1230
"aller +en vélo": 97	"aller +à vélo":	119
"aller +en voiture": 415	"aller +à voiture":	0

Leeman-Bouix, Danielle, 1994, "Les fautes de français existent-elles?", Seuil

4.ツール：フランス語の分析のためのプログラム

4.1.TEXTANA

<http://www.biwa.ne.jp/~aka-san/>

TEXTANA 用フランス語動詞活用辞書

<http://taweb.aichi-u.ac.jp/hnakao/txtana.html>

De 複数形容詞 名詞 s

(@avoir | @être) des* (bons | bonnes | beaux | belles)

Au pluriel, de bons fruits est le tour habituel dans la langue écrites; il s'entend couramment chez les gens qui ont un langage soigné; mais des bons fruits prévaut dans la langue parlée et se répand dans la langue écrite. (*Le Bon Usage*, 659)

本当にことばのレベルの問題だけがファクターなのだろうか?

corpus

Le Monde 97-98

Le Monde Diplomatique 84-98

L'Humanité 99

Les dernières nouvelles d'Alsace 99

Le télégramme 96

Proust A LA RECHERCHE DU TEMPS PERDU, TOME I, DU COTÉ DE CHEZ SWANN

総数: 718 occurrences

TXTANA Standard Edition 2.45 - depl.txt

File Tools Windows Help

New Open Close Main Query Collocation

3R	Count	No	Concordance Line	File Name
chances	107	338	dération générale du travail a de beaux jours devant elle. ? dna19990201	
raisons	106	339	radar normalement constitué a de beaux jours devant elle. I dna19990530	
jours	52	340	s grandes équipes, la France a de beaux jours devant elle. - dna19990702	
relations	27	341	utres comités, « L'opération a de beaux jours devant elle, s dna19990705	
résultats	23	342	gastronomie, la restauration a de beaux jours devant elle. E dna19990807	
rapports	13	343	nts. Je crois que ce circuit a de beaux jours devant lui. » dna19990914	
joueurs	12	344	et social âpre. Ce jumelage a de beaux jours devant lui. O R dna19991030	
restes	11	345	é de l'assistance à domicile a de beaux jours devant lui. -- dna19991106	
chooses	11	346	e unique en matière de ligne a de beaux jours devant elle, d hum19990401	
sensations	10	347	op cérébral. Malgré tout, il a de beaux jours devant lui. C' hum19990413	
yeux	10	348	s-vous: la série de France 2 a de beaux jours devant elle. L hum19990427	
idées	9	349	mulot pour surfer, le tapis a de beaux jours devant lui. FA hum19990622	
et	8	350	e ans. Alloës, Boris Eltsine a de beaux jours devant lui. . hum19990708	
arguments	8	351	ents incontrôlés du langage, a de beaux jours devant elle. N hum19991021	
occasions	7	352	welle, voilà une formule qui a de beaux jours devant elle. O hum19991112	
		353	ns. Le pagayage en eau salée a de beaux jours devant lui... brevet... 354 uste. le marché du rock nazi a de beaux jours devant lui. Fl dip92-93	
		355	de ses oeilères, l'horreur aura de beaux jours devant elle monde9707-08	

Type: 234 725

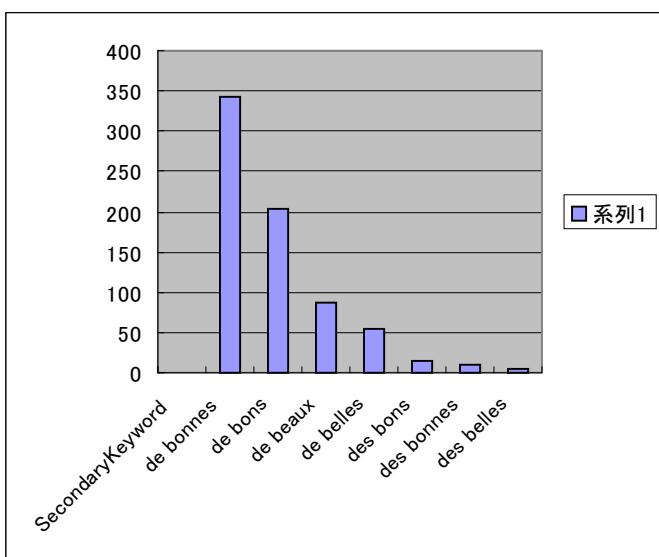
La restauration, pain bénit

Au pays de la gastronomie, la restauration **a de beaux jours devant elle.** Et les données du tourisme, secteur leader de l'économie mondiale auquel elle appartient, sont là pour le prouver.

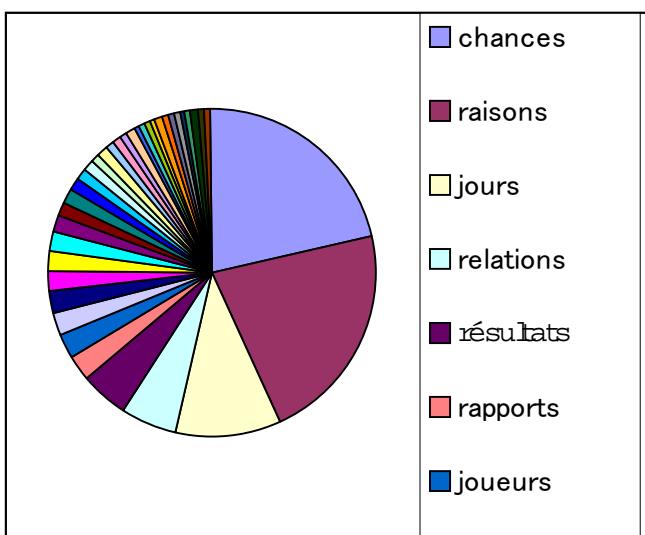
La France, pays phare de la cuisine, reçoit le plus de touristes étrangers au monde et les 122.067 restaurants et hôtels-restaurants répertoriés par l'INSEE dans l'hexagone ont réalisé un chiffre d'affaires de 198,6 milliards de

Line: 342/725 Marked: 0 Selected: 1 C:\corpora\dna1999\text\1999\dna19990807.crp (230)

de bonnes	343
de bons	203
de beaux	86
de belles	55
des bons	16
des bonnes	9
des belles	4
des beaux	2



<後続する名詞の分布>



3R Count

```

chances      107
@avoir de bonnes chances :107

raisons      106
avoir de bonnes raisons :105

jours         52
avoir de beaux jours devant :50

relations    27

```

avoir de bonnes relations avec :22
 résultats 23
 avoir de bons résultats :23
 rapports 13
 avoir de bons rapports :13
 joueurs 12、restes 11、choses 11、sensations 10 、
 yeux 10、idées 9、et 8、arguments 8 、
 occasions 7、notes 6、contacts 6、amis 5、
 jambes 5、moments 5

他のファクター

de bonnes	331
de bons	129
des bonnes	9
des bons	10

	il y a	他	総数
de	66	394	460
des	9	10	19
	75	404	479

72.03	387.97
2.97	16.03

0.000104

il y a の後は des が多い

p < 0.0005

des (bons|bonnes)...

1. "IL Y ^^A^^ ^DES BONNES^ CHOSES à écouter ce soir ?" Dans son hôtel parisien, Clint Eastwood s'enquiert d'un possible programme auprès de ses visiteurs, "spécialistes" du jazz,
2. mais, "parfois, il ^^a^^ ^des bonnes^ idées".
3. "Nous avons l'avantage d'avoir des partenaires qui nous font confiance sur de longues périodes. Ils savent qu'il y ^^a^^ ^des bons^ et des mauvais moments. Ils nous ont fait part de leur soutien."

4. Pour moi, il y ^^a^^ ^des bons^ et des mauvais livres.
5. J'ai bossé j'ai ^^eu^^ ^des bonnes^ notes, explique Sophie, une fille d'ouvrier.
6. Nous avons ^^eu^^ ^des bons^ contacts avec la communauté chrétienne.
7. « Dans une négociation difficile, il y ^^a^^ ^des bons^ moments et des moments moins faciles.
8. Cette loi ^^a^^ ^des bons côtés.
9. "Il peut y ^^avoir^^ ^des bonnes^ politiques de gauche, des mauvaises politiques de gauche, des bonnes politiques de droite et des mauvaises politiques de droite".

(@avoir|@être)

a	ont	avoir	sont	avait	eu	être	avons	ai
aura	avaient		avais	est	aurait		as	ayant
étaient		avez	aurez	sommes		eut	ait	
seront		soient		avions		aviez	auront	
eurent		était	aurons		aurions		étions	
étant	soyons		seraient		auraient		soit	soyez
	aurai							

Type39

725

なぞなぞ：あるはずなのにない活用形はなんでしょう？

（教訓：コンピュータに頼るわけにはいかない。フランス語の知識と言語学の知識）

既存のプログラムの問題点：

4.2.エディタの検索機能を使う

秀丸 grep、

4.3.Unix のコマンドの組み合わせ

grep,sort, uniq など

```
% less kaigyo.sed  
s/ /¥  
/g  
  
$ tr '¥n' '' < html/proust/proust1.crp | tr '¥r' '' |sed "s/[ '¥.¥]¥(,!¥?:-)/ /g" |sed 's// /g'  
| sed 's/^ /g'| sed 's/¥*//g' |sed 's/¥+//g'|sed 's/ * /g' | sed -f kaigyo.sed | grep -v '^ *$'  
| sort -f | uniq -ci > html/proust/motsfreq.txt  
  
% sort -n r < corpus/proust2.txt > corpus/proust.4.txt
```

語彙頻度表:

アルファベット順 :

<http://prairie.lang.nagoya-u.ac.jp/~fujimura/proust/proust2.txt>

頻度順 :

<http://prairie.lang.nagoya-u.ac.jp/~fujimura/proust/motsfreq.txt>

頻度順 (大文字と小文字の区別をしない):

<http://prairie.lang.nagoya-u.ac.jp/~fujimura/proust/motsfreq1.txt>

1語1文のテキスト

<http://prairie.lang.nagoya-u.ac.jp/~fujimura/proust/proust3.txt>

4.4.fkwic

```

Tera Term - prairie.lang.nagoya-u.ac.jp VT
File Edit Setup Control Window Help
[fujimura@prairie fujimura]$ 
[fujimura@prairie fujimura]$ fkwic -w -k 1 president corpus/proust1.crp | more
[fujimura@prairie fujimura]$ fkwic -w -k 1 madame corpus/proust1.crp | more
-- *Mais si, madame, beaucoup, j'ai été ravi. Il est
m'exprimer ainsi. N'est-il pas vrai, madame? demanda Brichot à Mme Verdurin q
e disait en riant: *Madame sait tout; madame est pire que les rayons X (elle d
-- *C'est beau, n'est-ce pas, madame Françoise, de voir des jeunes gen
que vous êtes musicienne dans l'âme, madame, lui dit le général en faisant in
-- *Non, madame Octave.+
-- *Mais non, madame Octave, mon temps n'est pas si ch
-- *Mais, madame Octave, ce n'est pas encore l'heu
*Mais je ne veux pas dire la grande, madame Octave, je veux dire la gamine, c
nstant que Mme Goupil a de la visite, madame Octave, vous n'allez pas tarder
-- *Mais non, madame Octave, ils aiment bien ça. Ils r
-- *Comptez-y, madame Octave, répondait le curé. Mais c
-- *Mais il n'est pas cinq heures, madame Octave, il n'est que quatre heure
tre maladie comme vous la connaissez, madame Octave, vous irez à cent ans, com
-- *Ah! mais, madame Octave, je ne sais pas si je dois
ertitude où j'étais s'il fallait dire madame ou mademoiselle me fit rougir et
lara Forcheville à Mme Cottard. Merci madame. Un vieux troupier comme moi, ça
-- Ah! madame Verdurin, dit Cottard, sur un ton
-- Ah! si madame Verdurin commence à peloter les b
e sur le bas de son front. Est-ce que madame votre nièce porte le même nom que
[fujimura@prairie fujimura]$ 

```

名古屋大学コーパスプロジェクト：

<http://prairie.lang.nagoya-u.ac.jp/>

4;5.perl を使って自分でプログラミングする

```

Tera Term - prairie.lang.nagoya-u.ac.jp VT
File Edit Setup Control Window Help
[fujimura@prairie fujimura]$ perl plscript/ezkwic2_2.pl corpus/proust1.crp
SEARCH STRING: monsieur
left length: 10
right length: 10
 1 | proust1.crp |      A |Monsieur| Gaston Cal      A
 2 | proust1.crp | rai type, |monsieur| Swann!+ C| type, rai
 3 | proust1.crp | *Voyons, |monsieur| Swann, lu| *Voyons,
 4 | proust1.crp | avoir ce |monsieur| à dîner, | ce avoir
 5 | proust1.crp | n certain |monsieur| de Charlù| certain n
 6 | proust1.crp | qu'a donc |Monsieur| à pleurer| donc qu'a
 7 | proust1.crp | -- *Mais, |monsieur| Bloch, qui| *Mais, --
 8 | proust1.crp |     -- *Monsieur!, je ne pu|     *
 9 | proust1.crp |     -- *Non |monsieur|, mès pare|     *Non --
10 | proust1.crp |     --- *|Monsieur| le Curé, |     *
11 | proust1.crp | mme?+ --- *|Monsieur| le Curé a| * -- mme?+
12 | proust1.crp | sez-vous, |monsieur| le liseur| sez-vous,
13 | proust1.crp | nnaissez, |monsieur|, la... le| nnaissez,
14 | proust1.crp | quelle un |Monsieur| habillé d| un quelle
15 | proust1.crp | s plus ce |monsieur|. Et puis | ce plus s
16 | proust1.crp | ez bien, *|monsieur|+ Biche, r| * bien, ez
17 | proust1.crp | e de dire |monsieur|, à rendre| dire de e
18 | proust1.crp | férence: *|Monsieur| Swann, vo| * férence:
19 | proust1.crp | ue chose, |Monsieur| Swann?+ | chose, ue
20 | proust1.crp | is. Mais, |monsieur| Swann, vo| Mais, is.

```

ezkwic2_2.pl

```

print STDERR "SEARCH STRING: "; $string = <STDIN>; chomp $string;

print STDERR "left length: "; $left = <STDIN>; chomp $left;

print STDERR "right length: "; $right = <STDIN>; chomp $right;

$/ = "";

while(<>){

s/ *$n */ /g;

while(/$string/ig){

$count++;

$key = $&;

$post = $';

$pre = substr ($` , -$left);

$pre_revd = join (' ', reverse (split (/s+/ , $pre)));

$file = $ARGV;

$file =~ s#.*/([^\/]*)$#$1#;

printf "%5d | %-12.12s | %${left}s|${right}s| %${left}s\n",
$count, $file, $pre, $key, $post, $pre_revd;

}

}

exit;

```

.....

インターネットからのフランス研究--- 社会・文化の一般的情報から人文学研究
まで <http://www.lang.nagoya-u.ac.jp/~ino/index-j.htm>