

- 1、アップロードしたいファイルに xml タグをつける
xml → 情報を記述するためのタグ

```
<bookstore>
  <book category="COOKING">
    <title lang="en">Everyday Italian</title>
    <author>Giada De Laurentiis</author>
    <year>2005</year>
    <price>30.00</price>
  </book>
  <book category="CHILDREN">
    <title lang="en">Harry Potter</title>
    <author>J K. Rowling</author>
    <year>2005</year>
    <price>29.99</price>
  </book>
  <book category="WEB">
    <title lang="en">Learning XML</title>
    <author>Erik T. Ray</author>
    <year>2003</year>
    <price>39.95</price>
  </book>
</bookstore>
```

<w3schools.com(http://www.w3schools.com/xml/xml_tree.asp)より>

(i) ヘッダー (開始タグ)

```
<xml>
<doc Level="○○" Title="テキスト名">
<text Types="○○">
```

(ii) フッター (終了タグ)

```
</text>
</doc>
</xml>
```

- 2、スケッチエンジンへのアップロード

(i) 新規のコーパスを作成する

Corpora: Recent My own Featured Parallel All

Language	Name	Words
No corpora found		

+ Create new corpus | + WebBootCaT | + Upload TMX

(ii) コーパスの名前と扱う言語の設定

The screenshot shows the Sketch Engine interface. At the top, there's a blue header bar with the Sketch Engine logo, user information ('user: Prof. Yukio Tono used words: 20 % / 10,000,000 days left: 267'), and navigation links ('About', 'Home', 'Settings', 'Change password', 'Log out'). Below the header is a search bar ('Search') and a link to 'Kaken RLD'. The main content area is titled 'Create new corpus'. It contains a form with 'Corpus name' (empty input field), 'Language' (dropdown set to 'English'), and 'Cancel'/'Create' buttons. On the left, a sidebar lists various corpus-related functions: 'Corpora', 'Parallel corpora', 'Configuration templates', 'Sketch grammars', 'Subcorpus definitions', 'User groups', 'Support', 'Help index', and 'Report an error'.

3、ファイルのアップロード

(i)

The screenshot shows the Sketch Engine interface. The left sidebar has a 'Corpus' section with options: 'Corpus page', 'Add new file' (highlighted with a red arrow), 'Add web data (BootCaT)', 'Compile corpus', 'Search corpus', 'Extract keywords & terms', 'Configure corpus', 'Change sketch grammar', 'Set subcorpus definitions', 'Expert mode', 'Download corpus', 'Access privileges', and 'View index'. The main content area is titled 'English: Add new file: Step 1'. It contains instructions about supported file types (.doc, .docx, .htm, .html, .pdf, .ps, .tar.bz2, .tar.gz, .tgz, .tmx, .txt, .vert, .xml, .zip) and how to upload multiple documents. It also states that you are responsible for copyright issues. The 'Add new file' form includes fields for 'Upload from disk' (radio button, 'Select file' button), 'Download from location' (radio button, URL input field), 'Use file or directory on the server' (radio button, dropdown, checkbox 'show files in subdirectories'), and 'Paste text' (radio button, text input field). A note at the bottom explains how to upload via FTP to the server.

→ライブラリからファイルを選択し、Nextをクリックしてアップロード

(ii)

The screenshot shows the Sketch Engine interface with a sidebar containing 'Corpora' (Create corpus, WebBootCaT, Upload TMX), 'Parallel corpora', 'Configuration templates', 'Sketch grammars', 'Subcorpus definitions', and 'User groups'. Under 'File', there are options for Edit file, Delete file, View plain text, View vertical, Download original file, Download plain text, and Download vertical. Under 'Support', there are links for Help index and Report an error.

English: Add new file:
001_A1_International_English_for_Speakers_of_Other_Languages_Book_1_P...
File added successfully:
001_A1_International_English_for_Speakers_of_Other_Languages_Book_1_Preliminary_Listening.xml.txt
Detected character encoding: utf_8

File type: Plain text
Character encoding: UTF-8 (all languages)
If some characters are not displayed correctly in the preview, changing this may help.
Cancel Update preview Finish

File preview (plain text)
Showing bytes 1..1500 / 54928

```
<xml>
<file CEFR="A1" Title="International English for Speakers of Other Languages">
<text Skills="Reading">
How do we say the letters A to Z in English? Look at the letters. Do you know
how we say them? Do you know them when you hear them? Put a circle around the
```

A large arrow points from the 'Finish' button in the dialog to the 'Finish' button in the preview window.

(iii) すべてのファイルをアップロードし終えたらコーパスを compile する

The screenshot shows the Sketch Engine interface with a sidebar containing 'Corpora' (Create corpus, WebBootCaT, Upload TMX), 'Parallel corpora', 'Configuration templates', 'Sketch grammars', 'Subcorpus definitions', and 'User groups'. Under 'Corpus', there are options for Corpus page, Add new file, Add web data (BootCaT), Compile corpus, Search corpus, Extract keywords & terms, and Configure corpus.

ELT-CourseBook-01
kaken_rld

Add new file / Add data from web using WebBootCaT / Compile corpus / Search corpus

#	Original file	Plain text	Vertical	Tokens	Owner	
1	001_A1_Internati...stening.xml.txt	✓	✓	12,255	Prof. Yukio Tono	
2	002_A2 Internati...2 Access.xml.txt	✓	✓	18,559	Prof. Yukio Tono	
3	003_B1 Internati...stening.xml.txt	✓	✓	23,818	Prof. Yukio Tono	
4	004_B2 Internati...or Listening.txt	✓	✓	36,756	Prof. Yukio Tono	
5	005_C1 Internati...5 Expert.xml.txt	✓	✓	47,526	Prof. Yukio Tono	
6	006_C2 Internati... Mastery.xml.txt	✓	✓	34,859	Prof. Yukio Tono	
7	007_B1 Close-Up.xml.txt	✓	✓	16,776	Prof. Yukio Tono	
8	008_A1 English Explorer 1.xml.txt	✓	✓	8,699	Prof. Yukio Tono	
9	009_B1 English Explorer 4.xml.txt	✓	✓	17,214	Prof. Yukio Tono	
10	010_A1 Holiday Explorer 1.xml.txt	✓	✓	3,660	Prof. Yukio Tono	
11	011_B1 Just Right...rmediate.xml.txt	✓	✓	10,587	Prof. Yukio Tono	
12	012_B1 Just Right...o Script.xml.txt	✓	✓	4,642	Prof. Yukio Tono	

A large arrow points from the 'Compile corpus' button in the top navigation bar to the 'Compile corpus' button in the table row for item 3.

(1) 検索の基礎

- Simple query…単語、フレーズ検索（各単語の活用形も含む=lemma検索）
- Lemma…単語のみ。活用形も含む。品詞指定可。
- Phrase…表層形のみのフレーズ検索（=活用形は含まれない）。
- Word…表層形のみの単語検索。品詞指定可。大文字・小文字指定可。
- Character…特定のアルファベットの並びで検索（=接頭・接尾語の検索可）。

(2) 検索の応用

- Context

Lemma Filter…前後〇語以内の指定の単語（lemmaで）の有無によって絞り込み。

PoS Filter…前後〇語以内の指定の品詞の有無によって絞り込み。

※いずれも複数指定可で、**all**にするとその全てが含まれたもの、**any**にするとそのうち少なくとも1つが含まれたもの、**none**にするとそのうちどれも含まれないものがコンコーダンス上に現れる。

- Text types…サブコーパスによる絞り込みができる。サブコーパスを編集することもできる。

(2) コンコーダンスの活用

- Sort

Left…中心語の左隣（L1）の語のアルファベット順で並べ替え

Right…中心語の右隣（R1）の語のアルファベット順で並べ替え

Node…中心語のアルファベット順で並べ替え

References…ファイル情報で並べ替え

Query **write** 9,875 > Sort **Left** 9,875 > Sort **bncdoc.id/0>0** 9,875 > Shuffle 9,875 > Sort **Left** 9,875 (88.03 per million)

Page 1 of 494 Go Next | Last Concordance is sorted. Jump to: ▾

HR9	this Quigley gets too much,' he said, ' write here. Give me a bit of time to get settled
BNA	Madam'. </p><p> NB If an advertisement says, ' write for application form' then keep the letter
HH7	and had consequently been treated as a ' write off' by its insurer. </p><p> According to
EUS	the control unit of the computer sends a ' write ' signal to the store. After some delay
G00	original Canon laser engine is called ' write black' because it charges up those areas
FT0	longstanding tradition that Mozart could ' write down whole compositions, previously composed
HWF	times that the file has been opened for ' write '. the File Protection is updated to include
HAC	the Source disk or at least that it is ' write ' protected. If you leave it unmarked and
H7X	read only' memory. More strictly it is ' write once, read many times' memory. The pattern
J25	they find it. A bestseller in its own ' write ' - and no work of fiction either - Guinness

↑ ファイル情報

↑ L1 ↑ node ↑ R1

- Sample…ランダムに指定した数のコンコーダンスを出すことができる。

- Filter

指定した語が中心語の前後〇語に現れる (positive) もしくは現れない (negative) ものでコンコーダンスをさらに絞り込むことができる。

- Frequency

Frequency…中心語のみだけでなく、前後〇番目にある単語の指定した形での頻度集計ができる。

Node tags…中心語の時制ごとに頻度集計ができる。

Node forms…中心語の表層形ごとに頻度集計ができる。

Doc IDs…ファイルの種類ごとに頻度集計ができる。

Text Types…テキストの種類ごとに頻度集計ができる。

→さらに P/N (Positive/Negative)でコンコーダンスを絞り込むことができる。

- Collocation…共起語を調べる

Attribute…共起語を word/tag/lempos/lemma... のどれによって分類するか決定。

Range…共起するのが中心語の前後〇語以内にするか決定。

Minimum Frequency in corpus…共起語のコーパス内の総頻度の下限を決定。

Minimum Frequency in given range…中心語+共起語の頻度の下限を決定。

→さらに P/N (Positive/Negative)でコンコーダンスを絞り込むことができる。

- Visualize…全コーパス内における中心語の分布をグラフ化できる。全コーパスをどれくらいの束に分けるかは、グラフ下の数値で調節。

2 Concordance -CQL 検索-

機能：CQL(= Corpus Query Language)を使った検索式により、柔軟な検索ができる
CQL：1990年代初期に独 University of Stuttgart の IMS が開発

◆実際に見てみましょう ー 対象コーパス：BNC ◆

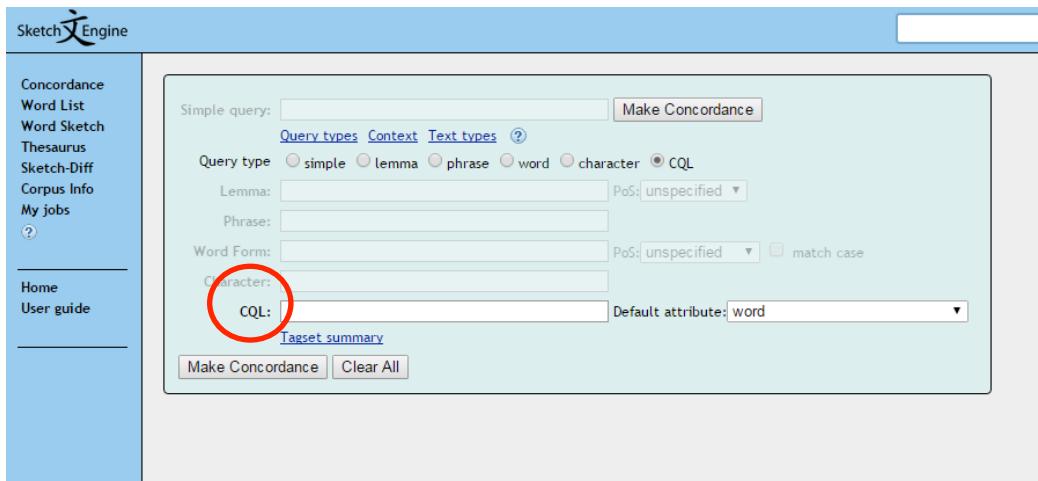


図1 検索画面

CQL の一般式： [attribute=" value"]

※attribute に word/lemma/tag/lempos がはいる

※value に検索したい正規表現を含む文字列がはいる

turn (表層形) を検索する場合の式

[word=" turn"]

"[tT]hank"

turn (レマ) を検索する場合の式

[lemma=" turn"]

turn の名詞を検索する場合の式

[lemma=" turn" & tag=" N.*"] または [lempos=" turn-n"]

※タグの記号に関しては図1 CQL のすぐ下の Tagset summary を参照

※ .(ピリオド) : 任意の1文字

※ * : 0以上n個 / + : 1以上n個 / ? : 0個または1個 / ! : ~以外

tag=" " を使った他の複雑な例

"confuse.*" [tag="IN" | tag="PP"]
"confuse.*" ([tag="IN"] | [tag="PP"])
"confuse.*" [tag="IN|PP"]

turn + 名詞 + 前置詞 の検索式

[lemma=" turn" &tag=" V.*"][tag=" N.*"]{1,2}[tag=" PRP"]

※[]と[]の間にはスペースがあってもなくてもok

※{}で検索スパンを指定 ({1,2}は1語から2語という意味)

この式で CQL 検索をしてみると・・・

The screenshot shows the Sketch Engine interface with a search query "turn, V.*, N.* , PRP" resulting in 620 hits per million. The results are paginated at page 1 of 31. The left sidebar contains various navigation links like Concordance, Word List, Word Sketch, Thesaurus, Sketch-Diff, Corpus Info, My jobs, Home, User guide, Save as subcorpus, View options, KWIC, Sentence, Sort, Left, Right, Node, References, and Shuffle. The main content area displays the search results with red highlights for the word "turn".

Turned	Example	Description
turned whales into	a sacred animal, like the Hindu cow... If	
turn rubbish into	energy and money <p> Plans have been unveiled	
turning land into	a freely saleable commodity like anything	
turned sex on	to its head and in those prepermissive	
turned Britain into	a more divided country. Homelessness and	
turning moans into	action. Really we're trying to give young	
turn auditors into	er snoopers or narks er and to do so l	
turn auditors into	snoopers and narks er er and make more	
Turning regions like	Angistri into wildlife refuges automatically	
turning Britain into	Europe's toxic dump. <p><p> Guardian 13	
turns bottles into	pipes <p> A company in South Australia, Rib	
turning plastic bottles into	pipes. The pipe-making process was first	
turn trees into	individual feeding territories and thus	
turned Blackpool into	a sort of electoral Convention a l'Americaine	
turning heads on	the island and was selected as Sheerness	
turned north to	the Tay in safety. With a tired army. But	
turn south past	Forteviot and march against us. By that	
turn CD-ROM into	a vehicle for multimedia, it is never likely	
turn CDTV into	an overt computer system. <p><p> Although	
turn egoism into	altruism, and <corr> aggression <corr> into	

でた～～～ 図2

✧複雑な検索式✧

“help to do” vs. “help do” のコンテキスト差を調べる為、文を抽出する式

[lemma="help"&tag="V.*"] [word="to"] ? [tag="V.I"]

※動詞の不定詞形タグは VBI (be)、VDI (do)、VHI (have)、VVI (lexical verbs)

名詞 + be + -ed 形で終わる動詞 の検索式

[tag=" N.*"] [lemma=" be"] [tag=" V.*" &word=" .*ed"]

look/bring + up/down の検索式

[lemma=" look|bring" &tag=" V.*"] [tag!=" V.*"] {0,5} up|down"

OR の意味のバー (|) の例

[tag="JJ.*"] [tag="N.*"] "and/or" [tag="N.*"]

✧within を使った検索式✧

文境界を指定した式

[word=" confus.*"] [tag!=" V.*"] *[word=" by"] within<s/>

動詞で始まり、動詞で終わる連鎖の中にあるすべての名詞句を抽出する式

[tag=" N.*"] +within [tag=" VB.*"] [] * [tag=" VB.*"]

(動詞句を一緒にとてこないための式)

※ Query within Query という式も可能である

※ Containing もある (cf. Sketch Engine)

参考資料

投野由紀夫 (2010) 「第 35 回英語コーパス学会ワークショップ Web コーパス検索ツール Sketch Engine の基本操作と活用」

投野ゼミ ゼミ合宿 2015

Sketch Engine 使用マニュアル

担当:中島詩菜

3. Word List

コーパス（サブコーパス）内から語彙表を抽出できる。

The screenshot shows the Sketch Engine interface with the 'Word List' option selected in the sidebar. The main area contains a search form for a 'Simple query'. It includes fields for 'Query type' (set to 'simple'), 'Lemma', 'Phrase', 'Word Form', 'Character', and 'CQL'. Below the form are buttons for 'Tagset summary', 'Make Concordance', and 'Clear All'. The top right corner shows the corpus name 'jEFLL-topic-year', the user 'Prof. Yukio Tono', and the Lexical Computing logo.

クリックすると↓

The screenshot shows the 'Word list options' configuration form. The sidebar lists various corpus management options like 'Concordance', 'Word List', 'Word Sketch', etc. The main panel is titled 'Word list options' and contains several sections: 'Subcorpus' (set to 'create new'), 'Search attribute' (set to 'word'), 'Filter options' (with frequency filters for minimum and maximum), 'Output options' (with frequency figures set to 'Hit counts'), and 'Change output attribute(s)' (with three dropdown menus). A note at the bottom states: 'You can select one or more output attributes. Please note that this option can be time-consuming.' At the bottom left is a 'Make Word List' button.

この画面が出てきます。

上から順に

●Subcorpus: サブコーパスを選択・新たに作成できます。

●Search attribute: word, lemma, tag (POS)などが選べます。

use n-grams では n 語の連鎖の語彙表を作成できます。

ここまでで検索してリストを作成できます。また以下の options を使うこともできます。

ここで、コーパスを BNC、サブコーパスを Written_Medium_Book、Search attribute を lemma にして word list を作成すると以下のようになります。

The screenshot shows the Sketch Engine interface with the following details:

- Left sidebar (Sketch Engine menu):** Concordance, Word List, Word Sketch, Thesaurus, Sketch-Diff, Corpus Info, My jobs, Home, User guide, Save, Change options.
- Top right header:** Send feedback, corpus: British National Corpus.
- Central area:** A table titled "Word list" showing the top 50 most frequent lemmas in the British National Corpus (Written_Medium_Book). The columns are "lemma" and "Freq".

lemma	Freq
the	3,248,150
be	2,115,367
of	1,695,452
and	1,385,021
to	1,368,443
a	1,122,993
in	1,020,585
have	664,221
that	553,199
he	521,387
it	521,267
I	475,106
for	413,637
not	402,730
as	385,681
she	347,099
with	343,639
on	338,986
they	298,871
you	290,153
his	280,259
by	262,874
at	258,532
do	251,094
this	240,444
but	236,944
from	215,209
or	213,969
which	204,898
an	179,664

(頻度が高い順に lemma を並べた語彙表)

【Filter options】

●Regular expression: 正規表現で検索できます。”.*”がワイルドカード（何が何文字入っても OK）を表すので、”th.*”で検索すると the, that, this 等の語彙表が作成されます。

(その他、+、?、!などがあります)

●Minimum frequency: 最小頻度を指定できます。

●Maximum frequency: 最大頻度を指定できます。

●Whitelist: 語彙表に含めたい特定の単語リストがある場合、アップロードできます。

●Blacklist: 語彙表に含めたくない特定の単語リストがある場合、アップロードできます。

●Include non-words: 句読点や記号などを含めたいときに使います。

【Output options】

- Frequency figures: Hit counts→粗頻度 (= raw frequency)
 - Document counts→語彙表中の単語を含むドキュメントの数
 - ARF (Average Reduced Frequency)→ひとつの単語が近距離(e.g. 同じドキュメント内)で複数回現れる時に頻度を調節する機能です。
- Output type: Simple Keywords→他の(サブ)コーパスを参照して比較する場合にキーワードを抽出できます。
 - Reference (sub)corpus→比較するサブコーパスを選択できます。
 - Prefer: rare/common words→頻度が高い・低い単語に高いスコアが当たられるように調節できます。
- Change output attribute(s):

【検索例】

- ① BNC 全体で search attribute を pos、minimum frequency を 0

The screenshot shows the Sketch Engine interface. On the left, there's a sidebar with various navigation links: Concordance, Word List, Word Sketch, Thesaurus, Sketch-Diff, Corpus Info, My jobs, Home, User guide, Save, and Change options. The main area is titled "Word list" and displays a table for the "British National Corpus". The table has two columns: "pos" and "Freq". The data is as follows:

pos	Freq
p	31,231,967
n	25,381,663
v	17,873,969
a	14,696,091
c	7,469,132
j	7,270,424
d	4,350,430
t	1,604,608
x	771,213
u	410,905
i	376,973
o	336,128
e	246,264
z	161,248

②BNCの中のサブコーパス Written_Domain_Imaginative で search attribute を lemma、
regular expression を wh.*、minimum frequency を 1、maximum frequency を 0

Sketch Engine

Concordance
Word List
Word Sketch
Thesaurus
Sketch-Diff
Corpus Info
My jobs
?

Home
User guide

Save
Change options

Word list

Corpus: British National Corpus
Subcorpus: Written_Domain_Imaginative

Page 1 Go [Next >](#)

lemma	Freq
what	62,804
when	44,413
who	32,451
which	27,625
where	20,374
why	16,900
while	10,599
white	6,539
whole	4,787
whether	3,260
whisper	3,066
whatever	2,716
whose	2,228
whom	1,898
wheel	1,497
whenever	714
whisky	665
whistle	579
whilst	554
whip	533
whoever	520
wherever	410
whirl	342
whereas	290
whore	266
whine	250
whimper	202
wholly	195
whatsoever	174
whereabouts	161

③BNC の中のサブコーパス Written_Domain_Informative で search attribute を word、
regular expression を .*ing、Frequency figures を Document counts

Sketch 文 Engine

Concordance
Word List
Word Sketch
Thesaurus
Sketch-Diff
Corpus Info
My jobs
?

Home
User guide

Save
Change options

Word list

Corpus: British National Corpus
Subcorpus: Written_Domain_Informative

Page Go [Next >](#)

word	Doc freq
being	2,521
including	2,330
during	2,324
making	2,307
following	2,247
having	2,238
taking	2,186
working	2,182
using	2,120
going	2,098
bring	2,018
something	2,010
giving	2,002
doing	1,943
according	1,939
leading	1,915
nothing	1,914
looking	1,909
running	1,863
building	1,860
coming	1,850
anything	1,847
beginning	1,838
meeting	1,787
thing	1,745
providing	1,743
leaving	1,738
trying	1,733
becoming	1,719
growing	1,714

④BNC 全体で search attribute を word、use n-grams で n=4

Sketch Engine

Concordance

Word List

Word Sketch

Thesaurus

Sketch-Diff

Corpus Info

My jobs

?

Home

User guide

Save

Change options

Word list

Corpus: British National Corpus

Page [Next >](#)

word (4-grams)	Freq
I do n't know	11,901
the end of the	10,374
at the end of	7,843
I do n't think	6,984
at the same time	4,811
the rest of the	4,712
for the first time	4,711
per cent of the	4,522
as a result of	4,468
one of the most	3,286
is one of the	3,267
do n't want to	3,266
in the case of	3,245
I do n't want	3,239
the Secretary of State	3,221
to be able to	3,167
On the other hand	2,836
in the form of	2,756
on the basis of	2,743
the top of the	2,673
in the middle of	2,641
do n't know what	2,542
by the end of	2,512
as well as the	2,507
on the other hand	2,460
the way in which	2,425
a member of the	2,415
was one of the	2,328
at the time of	2,288
the middle of the	2,219
a great deal of	2,205

⑤BNC の中のサブコーパス Written_Medium_Book で search attribute を word、Output type を Keywords にして Reference subcorpus を BNC のサブコーパス Written_Medium_To-be-spoken

Sketch Engine

Word list

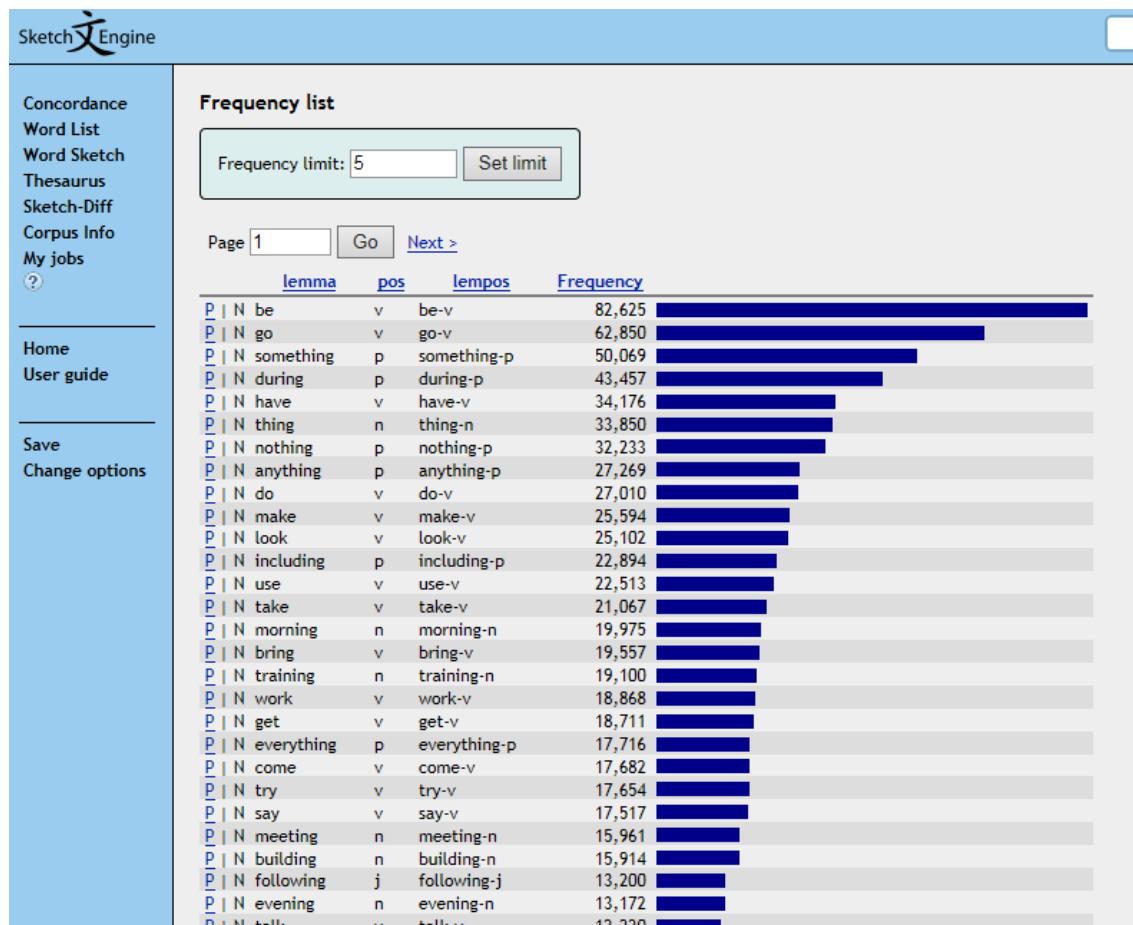
Corpus: British National Corpus
Subcorpus: Written_Medium_Book

Reference corpus: British National Corpus
Reference subcorpus: Written_Medium_To-be-spoken
[Switch focus and reference \(sub\)corpus](#)

Page 1 [Next >](#)

British National Corpus : Written_Medium_Book			British National Corpus : Written_Medium_To-be-spoken		
word	Freq	Freq/mill	Freq	Freq/mill	Score
p.	4,628	79.9	0	0.0	80.9
thus	7,757	133.9	1	0.7	79.9
defined	3,812	65.8	0	0.0	66.8
Figure	3,583	61.8	0	0.0	62.8
et	3,348	57.8	0	0.0	58.8
i.e.	3,301	57.0	0	0.0	58.0
Fig.	3,168	54.7	0	0.0	55.7
Thus	7,395	127.6	2	1.4	54.1
glanced	2,597	44.8	0	0.0	45.8
Moreover	2,548	44.0	0	0.0	45.0
realized	2,465	42.5	0	0.0	43.5
q.v.	2,325	40.1	0	0.0	41.1
whispered	2,262	39.0	0	0.0	40.0
organization	3,816	65.8	1	0.7	39.6
assumption	2,228	38.4	0	0.0	39.4
Chapter	5,372	92.7	2	1.4	39.4
latter	5,313	91.7	2	1.4	39.0
v.	2,133	36.8	0	0.0	37.8
Section	2,125	36.7	0	0.0	37.7
categories	2,123	36.6	0	0.0	37.6
smiled	6,603	113.9	3	2.1	37.5
plaintiff	2,098	36.2	0	0.0	37.2
patterns	3,574	61.7	1	0.7	37.1
e.g.	3,518	60.7	1	0.7	36.5
Similarly	2,038	35.2	0	0.0	36.2

⑥BNC 全体で search attribute を word、Regular expressions を.*ing、Output type を Change output attributes にして lemma, pos, lempos を選択
※この三つだと微妙、最後 word にしたり



Concordance
Word List
Word Sketch
Thesaurus
Sketch-Diff
Corpus Info
My jobs
[?](#)

Home
User guide

Save
Change options

Frequency list

Frequency limit: [Set limit](#)

Page [Go](#) [Next >](#)

lemma	pos	lempos	Frequency
P N be	v	be-v	82,625
P N go	v	go-v	62,850
P N something	p	something-p	50,069
P N during	p	during-p	43,457
P N have	v	have-v	34,176
P N thing	n	thing-n	33,850
P N nothing	p	nothing-p	32,233
P N anything	p	anything-p	27,269
P N do	v	do-v	27,010
P N make	v	make-v	25,594
P N look	v	look-v	25,102
P N including	p	including-p	22,894
P N use	v	use-v	22,513
P N take	v	take-v	21,067
P N morning	n	morning-n	19,975
P N bring	v	bring-v	19,557
P N training	n	training-n	19,100
P N work	v	work-v	18,868
P N get	v	get-v	18,711
P N everything	p	everything-p	17,716
P N come	v	come-v	17,682
P N try	v	try-v	17,654
P N say	v	say-v	17,517
P N meeting	n	meeting-n	15,961
P N building	n	building-n	15,914
P N following	j	following-j	13,200
P N evening	n	evening-n	13,172
D N talk	v	talk-v	12,220

SketchEngine 演習 4. Word Sketch

ゼミ合宿 2 日目
外国語学部 フィリピン語専攻 4 年
安宅優希

◎Word Sketch とは？

ある語がコーパス内でどのような語と共に起しているかを検索できる機能。

◎Word Sketch の基本操作

1. 検索したいコーパスを選択。
2. Lemma に検索したい単語、Part of speech で品詞を選択。
3. 通常はこのまま Show Word Sketch をクリック(Advanced options で詳細な設定も可能)。
4. 青いラベル(図 1: 黄色の円): 左から

1. 文法関係

2. 用例全体における頻度

3. 構文全体の中でどのくらい特徴的な構造なのかを示すスコア値(他の動詞の同一パターンと比較)→スコア値が大きいほどその単語における特徴的な文法構造と言える。

The screenshot shows the SketchEngine interface with the search term "make" entered. The results table has four columns: subject, object, np_adj_comp, and modifier. The 'subject' column is highlighted with a yellow circle and an arrow pointing to the 'make' entry. The 'make' entry is circled in red, and an arrow points to it from the left.

subject	object	np_adj_comp	modifier
make	133,440	50.90	16,802
decision	3,276	9.24	1,875
sense	2,570	8.98	894
use	2,558	8.78	1,318
mistake	1,698	8.63	563
difference	1,787	8.50	498
attempt	1,610	8.38	813
effort	1,612	8.37	401
contribution	1,468	8.32	234
progress	1,370	8.27	275
point	1,842	8.22	459
statement	1,394	8.16	222
way	2,002	7.85	222
arrangement	997	7.76	157
change	1,276	7.70	156
order	1,089	7.67	147
profit	946	7.66	140
love	934	7.65	133
payment	915	7.63	126
provision	907	7.56	116
comment	822	7.53	127
claim	852	7.49	85
choice	837	7.48	redundant
money	989	7.45	84
contact	754	7.38	choice
reference	742	7.36	likely

図 1: make の検索結果

4. その他のオプション(図 1: 赤の円): 上から

- Change options…Word Sketch のホーム画面に戻る
- Cluster…クラスター分析を行う。
- Sort by freq/ Sort by score…頻度順あるいはスコア順でソートを行う。
- Hide gramrels…文法項目関係なしに全体をランキング化。
- More Data…1 column における表示データの量が増加。
- Less Data…1 column における表示データの量が減少。

◎Word Sketch の具体的な使用例

★動詞 make の文法関係を自動抽出する。

- コーパスは British National Corpus を選択。
- Lemma に”make”、Part of speech で”verb”を選択。
- 検索結果は図 1 参照。
- “np adj comp”的スコア値(50.90)が最も高い(図 2 参照)
→make は”make+O+C”の構文が特徴的と言える。

The screenshot shows the Sketch Engine interface with the search term "make" entered. The results are displayed in several tables. A red circle highlights the first table, which contains the following data:

	subject	42,698	3.20	unary_rels	object	133,440	5.50	np adj comp	19,099	50.90	adverb	16,802	0.20		
decision	714	8.08		np_VPbare	11,234	46.30	decision	3,276		clear	1,875	10.33	year	1,410	8.98
				Sbare	1,178	67.60									

Below this table are several other tables showing various grammatical structures and their frequencies.

図 2: make の検索結果

*一覧を見やすくするために“Less Data”で表示データ数を減らしている。

投野ゼミ合宿 Sketch Engine 演習
E4年 北出望

5 Thesaurus/sketch-Diff

機能：同義語、あるいは異なる2語間の共起関係調べることができる

❖ 実際に見てみましょう — 検索対象コーパス：BNC ❖

検索画面（名詞の"love"で検索、POS を指定）

図1

検索結果

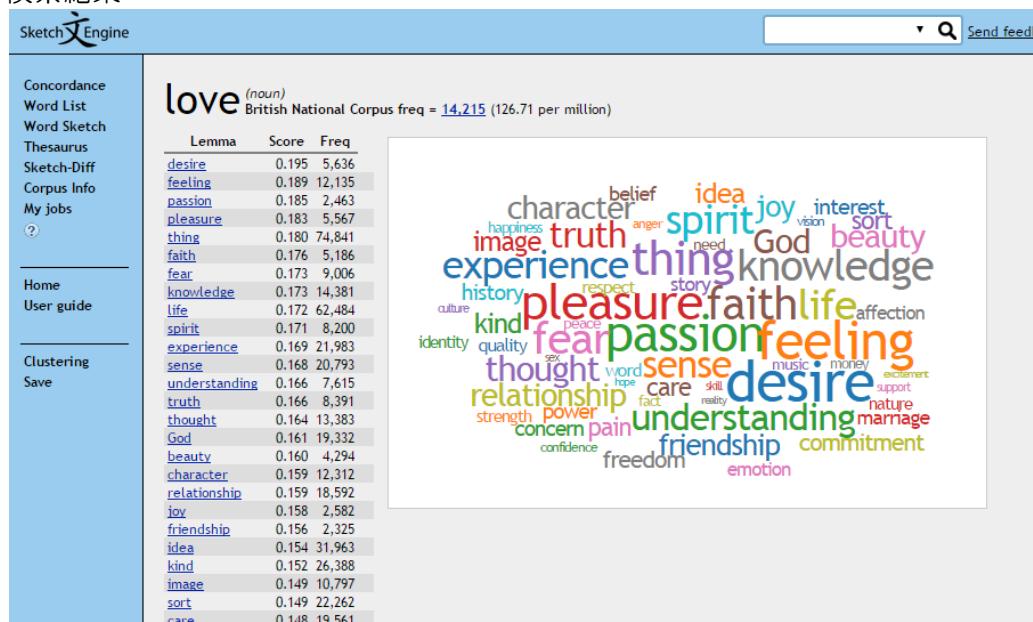


図2（下に結果が続く）

検索をすると、図2にあるように名詞 love の類義語リストが表示されるだけでなく、視覚的にも分かりやすく同義の語彙を表示してくれる。(大きさが大きい単語ほど、検索語彙により近い)

必ずしも類義語とは言えない単語も入っているが、単語の振る舞いが似ているものが提示される。

リストの一番上、かつ大きさ最大の desire のリンク先



図3（下に結果が続く）

Word sketch 機能の2単語比較バージョンで、Thesaurus からだけでなく、メニュー左の Sketch-Diff からもこの機能を使うことができる。

この図3では、名詞 love と desire の違いをコロケーションの観点から学び取られる。
 ⇣ 左から、 and/or で並列共起する名詞、主語のときに共起する動詞、そして修飾を受けて共起する形容詞の3つの観点から love と desire の違いが分かる
 (他にもたくさんの違いを示す表が下に続く)

- ✧ 緑であればあるほど love との共起が多く、赤であるほど desire との共起が多い
(ここで love には satisfied は修飾されていない・・・ということは・・)

参考資料

投野由紀夫 (2010) 「第 35 回英語コーパス学会ワークショップ Web コーパス検索ツール Sketch Engine の基本操作と活用」

SketchEngine 演習 7. WebBootCat

ゼミ合宿 2 日目
外国語学部 フィリピン語専攻 4 年
安宅優希

◎WebBootCaT とは？

インターネットをクロールしてテキストを自動収集し、コーパスを作成する機能。

◎WebBootCaT の基本操作(図 1 参照)

1. Home 画面の左側のメニューから WebBootCaT をクリック。
2. コーパス名と言語を設定。
3. Input type で Seed words/URLs のどちらかを選択(*後半で詳しく解説)。

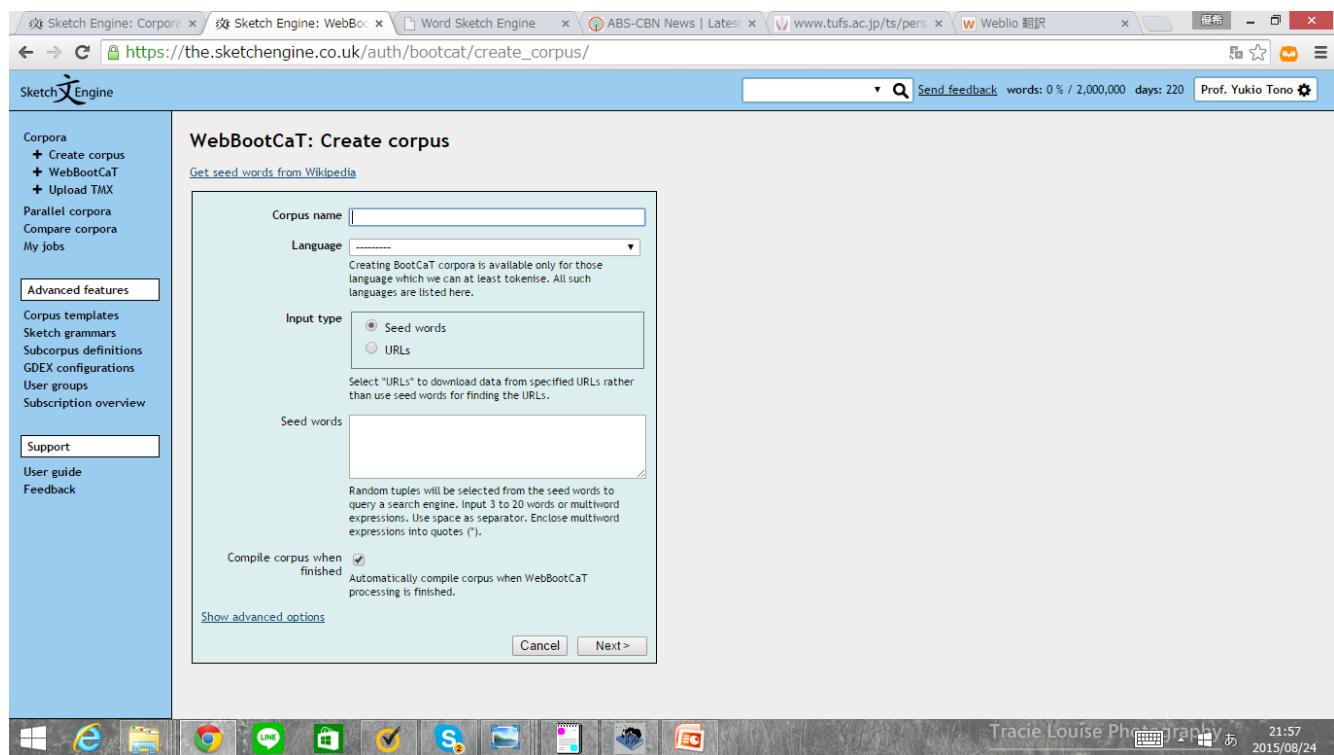


図 1: WebBootCaT の基本画面

◎WebBootCaT の具体的な使用例(Seed words/URLs)

★”Seed words”で Web corpus を作成する。

1. 上記の 1.~2.を経て、Input type の Seed words にチェックを入れる。
2. Seed words の欄にキーワード(3~20 個)を入力。

3. Seed words を 3 語ずつランダムに組み合わせたものをインターネット検索にかけた結果が表示される(図 2 参照)。
4. Next をクリック→自動的にテキストをダウンロード。
5. OK をクリック→コーパスの完成。

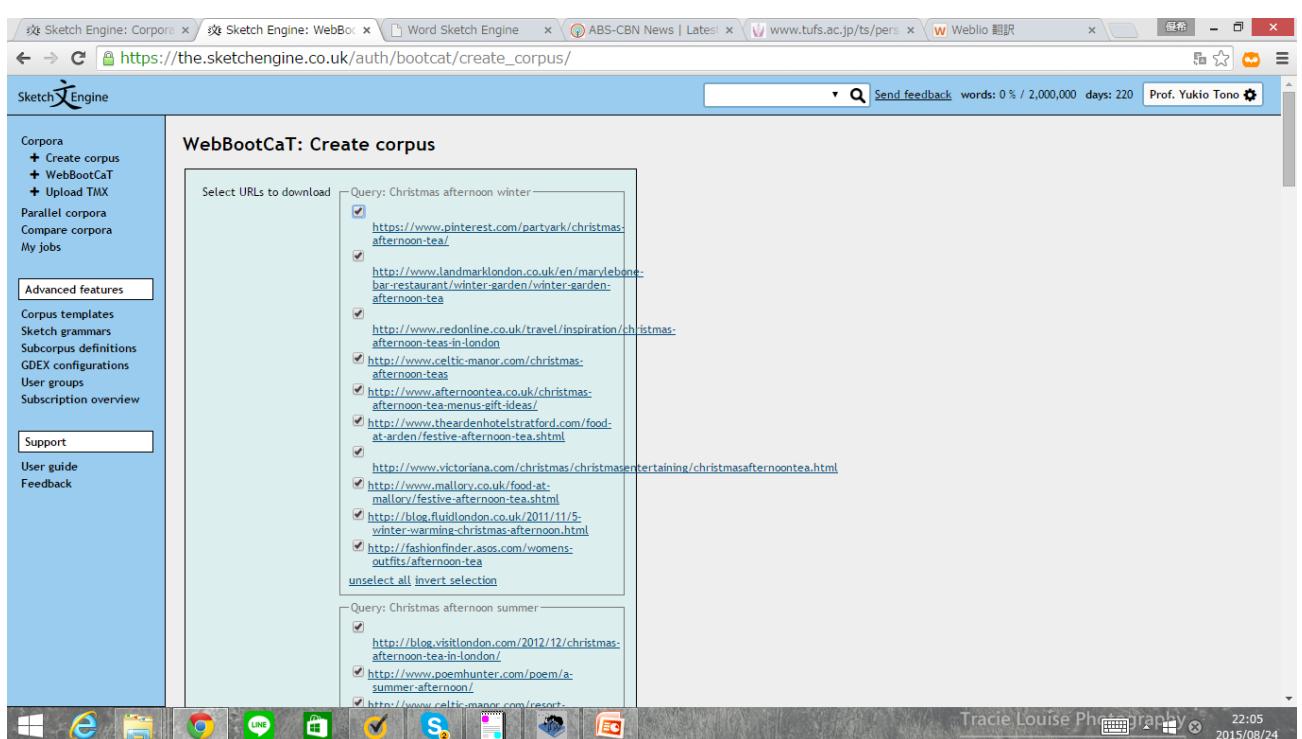


図 2: URL の一覧

★”URLs”で Web corpus を作成する。

1. 上記の 1.~2.を経て、Input type の URLs にチェックを入れる。
2. URLs の欄に指定する URL を入力(図 3 参照)。
3. Next→OK→コーパスの完成(図 4 参照)。

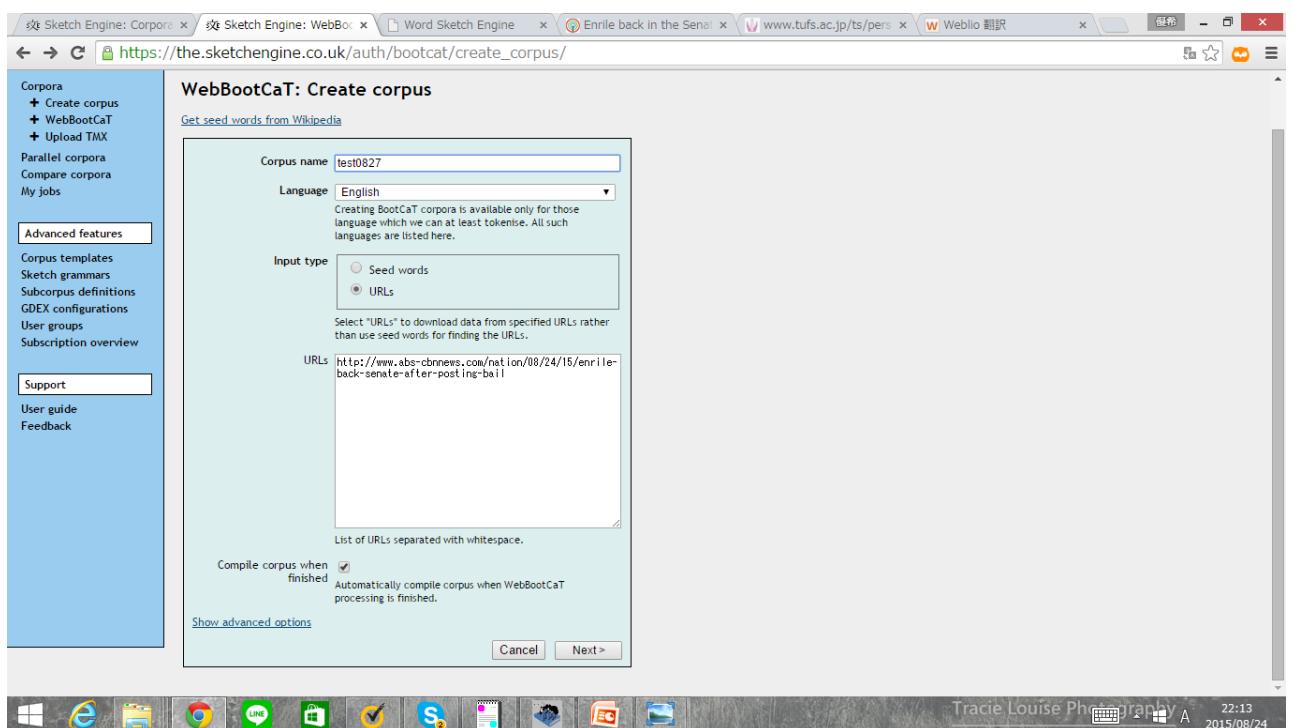


図 3: URL の指定



図 4: 完成したコーパス