

1日目

2010/1/23-24
名古屋大学

日本語コーパスの最新の検索 エンジンと分析

李 在鎬 (り じ え ほ)



JAPAN FOUNDATION 国際交流基金

全体スケジュール

一日目	前半	後半
時間(目安)	13:00～14:30	14:45～18:00
区分	講義	実習
全体テーマ	コーパス分析の理論と方法	文字列基盤のコーパスツール。コーパスツールとしてのエクセル
主な項目	コーパス基盤の言語研究の特徴、良いコーパス調査のために、コーパス調査の一般的なサイクル、操作のデモ	正規表現を覚えよう、KWIC Finderを使う。テキスト抽出用の関数を使う、条件式を使う、ピボットテーブルを使う

二日目	前半	後半
時間(目安)	10:00～12:30	13:30～15:20
区分	講義・実習	実習
全体テーマ	コーパスツールの紹介	コーパスデータ紹介
主な項目	形態素解析、ChaSen, KH Coder, E-Kwicなど	様々なコーパスの紹介

配布データ

- ¥nagoya¥ソフトウェア
 - khcoder-2b22-f.exe /56.4M
 - kwic329.exe /2.3MB
 - hm711_signed.exe /1.8M
- ¥nagoya ¥コーパス 終了後は削除
 - 書籍サンプル, 国会議事録サンプル, 白書サンプル, Yahoo知恵袋, 読売新聞サンプル, KYc.zip
- ¥nagoya ¥temp
 - SQL.txt, hinshi_chasen

- 2010.1.23-24名古屋大チュートリアル資料.pptx
- <http://jhlee.sakura.ne.jp/trans/1.pdf>
- ID: misokatsu, PW: daisuki



1/23のお品書き

- 自己紹介
- 前半
 - 全体的な話
 - 理論, 実践, 方法
- 後半
 - 実習: 「漢語+する」の調査
 - Kwic Finderや正規表現

自己紹介

- 李在鎬（りじえほ）
 - 日本語学（助詞・深層格）→認知言語学→理論言語学→構文研究→コーパス研究・応用言語学
 - 国際交流基金日本語試験センター：出題基準、コーパスに基づく作題支援システム作成
 - 最近の主な関心分野
 1. コーパス基盤の語彙意味論
 2. テキストの難易度抽出、テキスト比較
 3. 構文使用に関する計量言語学的研究
 4. 実験的手法による言語研究
 5. 学習者コーパス



別の説明

- コーパス：辞書と並んで、もっとも基本的かつ**中核的な言語資源**。辞書は言語の知識に関わる言語資源だが、コーパスは言語が**実際に書かれて話されたりして結果が記録されたもの**。言語の**使用実態**に関わる言語資源

言語処理学会(2009)『言語処理学事典』共立出版 pp.58



今日の話では

Before

- 消極的コーパス言語学：PCに適当に**単語**を入れてみたら**用例**が出てきた。良いなあ～



After

- **積極的**コーパス言語学：コーパス言語学の**ロジックと技術**を知ろう **自分の研究に応用**してみよう！



コーパス言語学の導入 (1/2)

- 考え方(Leech 1992)
 1. 言語能力より **言語運用** に中心をおくアプローチ
 2. 言語の普遍的特徴の解明より、**個別言語の記述** に中心をおくアプローチ
 3. 質的な言語モデルのみならず、**数量的な言語モデル** にも中心をおくアプローチ
 4. 言語研究における合理主義的な立場よりも、**経験主義的** 立場に立つアプローチ

コーパス言語学の導入 (2/2)

- メリット (Biber, Conrad and Reppen 1998)
 1. 具体的な言語の使用実態をパターン化し、調べることができる。
 2. 網羅的に現象を収集することができ、データの偏りが解消できる。

→ コーパスによる語彙研究の手法は、その**生起文脈を客観的に記述**することができることから言語研究の単なる手法の域を超え、従来の言語研究では認識されてこなかった問題や現象を発掘し、解明していく**新たな言語研究のパラダイム**として確立しつつある(Tognini-Bonelli 2001)。

暗黙知

1. 近くで表れることは意味がある

→共起関係重要視

例) 他動詞の近くには「を」が表れることが多い

→ 他動詞と「を」は関係が深い

一般的にはキーワードの右5、左5を見る

小沢氏が土地購入代に充てたと^{キーワード}する資金について東京地検

左5 左4 左3 左2 左1 右1 右2 右3 右4 右5

2. よく使われるということには意味がある→頻度重視

コーパス言語学の実践

• 良い調査をするために、調査をデザイン！

1. どういう**目的**で、
2. どのような**コーパス**を利用し、
3. どのようなデータ処理を行うのか、
4. その結果に対してどのような**予測や仮説**を
持っているか (皆が頷くような)

→しっかりしたストーリー構成が重要


コーパス言語学の実践

- 良い調査をするため心掛けるべきこと (伊藤2002)
 1. 妥当性：まさに知ろうとする目的を正しくつく調査方法であること
 2. 信頼性：同じ対象に同じ操作を加えた結果があまり大きく変動するようなものでないこと
 3. 客観性：結果が主観によってまちまちになるような操作ではないこと
 4. 再現性：調べる対象の実際の姿が操作を加えた結果から正しく見極められること
 5. 適応性：その操作が実際に無理なく行え、かつ妥当な結果をもたらすようなものであること


ちょっと横道

- コーパスを使った研究の二分類
 1. コーパス駆動型研究（Corpus-driven Approach）：工学的な言語処理。全面的にコーパスに依拠。コーパスの中ですべての問題解決をはかる、コーパスで始まってコーパスで終わるタイプの研究→億単位のデータ
 2. コーパス基盤型研究（Corpus-based Approach）：人文科学的な研究。研究の補助的手段としてコーパスを利用。疑問に思う事項を検証する立場

コーパス分析の実践



コーパス分析の実践



コーパス言語学の実践

- 代表性の問題
 1. コーパスは、人の言語行動の結果を記録したもの
 2. 分析に用いるコーパスが人の言語行動の実態を正しく反映したもの. 例えば、新聞コーパスを利用→新聞は日本語の使用態を代表しうることが前提→「代表性(representativeness)」の問題

コーパス言語学の実践

- 代表性の問題
 1. 代表性の問題がクリアされない研究→**違うデータを使えば、調査結果が変わる**、結果の信頼性・妥当性は得られない
 2. コーパスを用いた研究のあらゆるステップにおいて問題視される
 3. きちんと答えてないといけない.
しかし・・・

困った！！！！

どんなに大きなコーパスであれ、どんなに多様なデータを含むコーパスであれ、現実問題として当該言語をそっくり代表しうるコーパスは存在しない。なぜなら、コーパスデータの母集団となる当該言語の使用の総体は潜在的には無限だからである。



代表性の問題をクリアする

- 英語などの一部の言語に関しては（代表性の要請を満足する）均衡コーパスを用意されているので、それを使えば良い。
- 日本語の研究では
 1. 自らがデータを用意する
 2. 自らが下処理を行った上で、サンプルをとる→何らかの戦略を立てるべし。

代表性の問題をクリアする

量の面から

- 収集データの量を増やすことで、代表性の要請に答えていこうとする考え方

- とりあえず沢山！
- 自然言語処理の考え方

質の面から

- 書き言葉や話し言葉を共に含めたり、様々なジャンルのデータをバランスよく取り入れることで代表性の要請に答えていこうという考え方

- とりあえず色々なもの
- 人文系のコーパス分析

代表性の問題をクリアする

- 絶対的な基準はない。
 - 量に関して
 - 大きければ無条件に良いのか：違う。大きいコーパスを使えば、得られるデータの量も大きくなり、作業に時間がかかる。データの規模が大きくなれば、人為的な**ミスの可能性も大きくなる**。
 - 示唆：5万語程度の小規模のコーパスで助詞「に」の用法を収集し、クラスタ分析を行ったが、そこで得た結果は、後に行った別の調査で、100万語のコーパスで調査した内容と大きく違わない。李(2003)
- 必要最適な量を見極めることが重要。数百程度

大規模でなければ できないものもある

	ウェブコーパス	日英新聞記事対応付けデータ
恐れる	1010	11
積む	1362	4
冷やす	664	3
寄与する	582	9
固まる	473	3
散る	289	1
心掛ける	178	0
賛成する	185	12
逃げる	388	0
逃れる	504	1
躍進する	70	2
合計	5705	46

黒田・李(2008)

質も大事

- (1) a. 地震に驚いた人々が部屋から廊下に出た。 →位置変化
b. 太郎が会議に出た。 →出現
c. 我が校から優勝者が出た。 →発生
d. 太郎は住み慣れた街を出た。 →離脱

李 (2008)

		文意				合計
		位置変化	出現	発生	離脱	
コーパス	新潮 新書	45	30	17	16	108
	読売 新聞	14	79	391	5	489
合計		59	109	408	21	597

代表性の問題をクリアする

- 絶対値
- 平均
- ある
- 相
- 統計
- 質実


	A	B	C
1	音韻	コーパスA	コーパスB
2	-k	1111	1086
3	-t	2222	2197
4	-r	3333	3308
5	-ng	4444	4418
6	-i	5555	4000
7	-a	6666	6641
8	-e	7777	7752
9	-ty	8888	8863
10	-re	9999	9975

ので
てい
用し、
い。

位の
。高

い相関が待られた→どのコーパスから調べても結果は変わらない（李・玉岡・林2008）

コーパス分析の実践



KWICって？

- KWIC形式

- － 「クイック」と読む.

- － **KeyWord In Context**

- 「文脈の中の鍵語」 のこと

KWICの見本

先行文脈	キーワード (鍵語)	後続文脈
に21年に準急として復活して江ノ島線にも	走る	ようになったが、
ンスカーによる臨時特急(特急料金不要)も	走る	ようになった。
区間は3線線路になっており、上下いずれも	走る	ようにして、
街なかをしばらく	走る	と片瀬江ノ島となる。
小田原線とほぼ同様な車両が	走る	。
車エクセは10両編成を分割した4両編成が	走る	。
特急「えのしま」、急行、各停の3種が	走る	。
庫した4両を増結して新宿まで10両編成で	走る	。

後ほど実習を！

Google 走る 検索 検索オプション

ウェブ全体から検索 日本語のページを検索

ウェブ 検索ツールを表示 走る に一致する日本語のページ 約 17,000,000 件中 1 - 10 件

他のキーワード: 走る男 走る男2 速く走る方法 早く走るには デゴイチよく走る

走る - Wikipedia

出典: フリー百科事典『ウィキペディア (Wikipedia)』。移動: ナビゲーション, 検索。自力で移動できる生物または無生物が高速で移動することを走る(はしる)というが(走る、走るとも)、歩くこととの違いは以下のように定義される。...

人間の「走る」・哺乳動物の「走る」・比喩的な用法・走ることに關する競技

ja.wikipedia.org/wiki/走る - キャッシュ - 類似ページ

走る男 - Wikipedia

走る男のスタッフ(番組内では「走る男たち」として紹介)の一部も「らくらぶR」時代からのスタッフである。... 番組ホームページはブログ形式で、リアルタイムで走る男の旅が見られるほか、書き込みもできるので、ウェブを通じて地元の情報提供されること ...

ja.wikipedia.org/wiki/走る男 - キャッシュ - 類似ページ

走る男

最終回をご覧になった皆様、ぜひこの記事の書き込み欄に感想をお寄せください。より多くの皆様の感想を聞きたいです。また特番、「走る男〜日本縦断2700キロの軌跡」近日放送です。チェックしてください。あと走る男2のサイト、どんどん盛り上げて ...

www.hashirutoko.jp/ - キャッシュ - 類似ページ

走る男2

TOP・走る男Ⅱとは？ 走る男Ⅱのルール・招待状BOX・各テレビ局放送時間・走る男のパワーアップアイテム・ダウンロード・森脇日記 [93]・森脇健児 [543]・P東郷 [1389] 「走る男 北海道→沖縄2700kmの旅」詳細はコチラ。九州・沖縄編 ...

www.hashirutoko2.jp/ - 8時間前 - キャッシュ - 類似ページ

走る！飲む！読む！

昨夜、いい朝で走ることができたので、その朝には、と意気込んでいました。1周目、おはし、おにぎりに飛び

日本語KWIC問題

1. 異表記の問題
2. 異形の問題
3. 複数の要素にまたがっている場合の問題
4. 一部が省略されている場合の問題

日本語KWIC問題

1. 異表記の問題

⇒ 友達, 友だち, ともだち

2. 異形の問題

3. 複数の要素にまたがっている場合の問題

4. 一部が省略されている場合の問題

日本語KWIC問題

1. 異表記の問題

2. 異形の問題

⇒ 走らない, 走ろう, 走った, 走り,

3. 複数の要素にまたがっている場合の問題

4. 一部が省略されている場合の問題

日本語KWIC問題

1. 異表記の問題
2. 異形の問題
3. 複数の要素にまたがっている場合の問題
⇒ 日**本**, **本**を読む, 三**本**
4. 一部が省略されている場合の問題

日本語KWIC問題

1. 異表記の問題
2. 異形の問題
3. 複数の要素にまたがっている場合の問題
4. 一部が省略されている場合の問題
⇒ 助詞や主語など, ハ・モとガの問題など

日本語KWIC問題

1. 異表記の問題

2. 異形の問題

3. 複数の要素にまたがっている場合の問題


4. 一部が省略されている場合の問題



形態素解析

形態素解析 の 実演

コーパス分析の実践



意外とすごいEXCEL

- Excelと言えば,
 1. 表組にしてくれる
 2. グラフを書いてくれる
 3. 決まった順番に並び変えてくれる
 4. 足し算や引き算などの計算ができる
 5. 文字数を数えてくれる


.....

- それだけじゃないぞ！



意外とすごいEXCEL

- 文字列を切り取ってくれる。⇒探索の手助けをしてくれる
 - 太郎が学校に行った.
 - 太郎の自動車が壊れた.
 - 太郎の家のトイレがきれいだ.⇒主語だけ切り取ってデータを見やすくしたい.



コーディング

- テキストデータをより構造化し、ターゲットとなる言語現象を動的に理解し、把握するためのもの

言語表現	変数 1	変数 2	変数 3	変数 4	...
...					
...					
...					
...					




言語表現	主語	主語の特徴	動詞の語形	助詞	...
太郎が走る	太郎	人	る形	が	
花子も走っている	花子	人	ている形	も	
激痛が走った	激痛	抽象物	た形	が	
犬も走っている	犬	人以外の生物	ている形	も	

コーディング

- コーディングにおけるポイント
 1. どういう変数を立てるか
 - 調査全体に成否に関わる要因
 - 選択に関して責任を持つこと
 - 伊藤2002が言う「信頼性、再現性の高いもの」
 2. どう判断するか
 - 外部言語資源を利用する
 - 複数の被験者に判断させる

コーパス分析の実践



コーパス研究における分析

- 分析の基本
 - 数える
 - 多かった, 高かった
 - ⇒ きっと理由がある ⇒ 考察する
- 数える際の鉄則
 - 手で数えない。必ずミスる、不必要に時間がかかる
 - ソフトを使う。エクセル
 - 数えるための関数やピボットテーブル
 - 詳細は後半で。

コーパス研究における分析

- 色々な数え方
 - 語の数える；短単位か長単位か，延べか異なりか
 - 共起を数える；tスコア，MIスコア，エントロピーなどなど→目的に合わせて使う。
- 玉岡先生に！

論文化する

- 結果を報告
する際、留意すべき点
 - 調査の手順や各ステップにおける結果を可能な限り、クリアに報告する
 - 同じ解析方法を用いて調査を行えば、概ね同じ結果が再現できることが期待される
 - どのようなコーパスに、どのような下処理を行ったのか、どのようなデータ抽出方法を用いたのか

目次の見本

1. 導入：なぜその研究が行われなければならないのか
2. 先行研究と問題提起：その研究が答えようとしている問いは何なのか
3. データと調査方法：追試可能な形で調査の手順などを明記する
 1. 使用データ（コーパス）
 2. 解析方法
4. 結果：得られた結果を客観的事実として報告する
5. 考察：「結果」から「問題提起」に対してどのような答えが得られたかを述べる
6. まとめと課題

- お疲れ様でした。
- 休み時間に¥nagoya¥ソフトウェア
 - kwic329.exe /2.3MB
 - hm711_signed.exe /1.8M



後半

- ソフトウェアのインストール&確認
 - コンコーダンスソフト：Kwic Finder
 - テキストエディタ：秀丸エディタ

- 秀丸エディタ

- 機能・目的：テキストファイルを開くためのもの。超多機能の編集機！！。

- 入手：

- [ttp://hide.maruo.co.jp/software/hidemaru.html](http://hide.maruo.co.jp/software/hidemaru.html)

- インストール：

- <http://vision.ameba.jp/watch.do?movie=610709>

- Kwic Finder

- 機能・目的：キーワードと一致した文字列を集めるためのもの

- 入手：

- http://www31.ocn.ne.jp/~h_ishida/KWIC.html

『現代日本語書き言葉均衡コーパス』(BCCWJ)

- 書き言葉の均衡コーパス。特定領域研究
- 書籍、国会議事録、白書、Yahoo知恵袋のデータがバランスよく入っている
- チュートリアルのため少し加工した
 - 9000字～10000字の間で字数を統一
 - 改行コードを調整。一文に一改行
 - テキストIDやタグを削除




- コーパスの確認
 1. BCCWJから抽出
 2. 一文一行に整形
 3. 空行の削除
 4. 特殊記号の削除など



ちょっと横道

- どうしてもメモ帳ファイルなのか。
 - 正確にはテキストファイル (.txt)
 - マシン環境を選ばない、Win, Mac, Unix...
 - 編集・検索が楽、処理が速い→何かと便利。



サンプル調査

- 漢語+するの共起に関するコーパス調査
 - 勉強する、変形する
- 言語研究的観点から
 - 一つの形式でありながら多様な性質を持つ
 - 自他の混在、非対格性・意図性の有無、助詞の介在(勉強する・勉強をする/変形する・*変形をする) など (影山1996)


サンプル調査

- 概要
 - 「二文字の漢字+する」でなる用例をコーパススペースにみる。
 - コーパス間で分布の違いが見られるかどうか
- 使うソフトウェア
 - Kwic Finder, 秀丸, エクセル
- 使う技術
 - 正規表現 = > データ収集
 - エクセルのテキスト関数 = > データ整形
 - ピボットテーブル = > データ集計

・ ・ お詫び ・ ・

- エクセルの操作を覚えてもらうため、過剰に関数を使っている部分がある。
- 練習だと思ってやってみてください。
- Kwic finderのタスクも操作を覚えてもらうためのもので、検索対象によっては別の操作を加えたほうが良い場合もある

操作イメージ



KWIC FINDER とは

- KWIC Finder
 - もともとは複数テキストからの文字列検索ソフト
 - 検索結果に **KWIC 形式**を採用
 - **正規表現**を使用した検索に対応
 - テキストファイルの検索のみであれば、フリー：http://www31.ocn.ne.jp/~h_ishida/KWIC.html



正規表現とは

- せいきひょうげん、regular expression) とは、文字列の集合を一つの文字列で表現する方法の一つである。
- ある要素（文字とか単語など）の前後に特定のパターンを持ったものが接続していく形の記述
 - 戻って 買って 貼って いった
 - [戻買]って
 - .って

正規表現の記号


項目	意味
[]	キャラクタクラス
()	パターンをグループ化する
^	行頭
\$	行末
.	改行を除く任意の 1 文字
*	直前のパターンの 0 回以上の繰り返し
+	直前のパターンの 1 回以上の繰り返し
?	直前のパターンが 0 回または 1 回現われる
	パターンの論理和
¥	エスケープ文字



KWIC FINDER の画面



正規表現とは

- regular expression
列で表現する方法の一つである。
- ある要素（文字とか単語など）の前後に特定のパターンを持ったものが接続していく形の記述
 - 戻って 買って 貼って いった
 - [戻買]って
 - .って





C:\Users\lee\AppData\Local\Temp\KWC81C\KwicView.txt - 秀丸

ファイル(F)

編集(E)

表示(V)

検索(S)

ウィンドウ(W)

マクロ(M)

その他(O)

</

Book3 - Microsoft Excel

ホーム 挿入 ページ レイアウト 数式 データ 校閲 表示 Acrobat

貼り付け グリッドボード フォント 配置 数値

標準 条件付き書式 レーブルとしてセルの書式設定 スタイル 挿入 削除 並べ替え 編集

A2 D:\MY-DOC-data\名古屋国会議事録サンプル.txt

A	B	C	D	E	F	G	H	I	J	K	L	M
ファイル名	行	位置	先行文脈	直前語	キーワード	後続文脈						
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	3	159			木島則夫君が委							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	4	259			君及び秦豊君が委							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	5	333			また							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	7	420			委員長(石破二郎)							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	8	504			今期国会におきま							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	11	709			な							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	15	967			地先沖合における							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	15	1047			連邦政府との間の							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	15	1137			地先沖合における							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	15	1217			連邦政府との間の							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	15	1277			いて承認を便宜一括して							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	19	1504			地先沖合における							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	19	1584			連邦政府との間の							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	19	1676			地先沖合における							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	19	1756			連邦政府との間の							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	19	1810			結について二件につきして							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	20	1946			にも互に一括して							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	21	2106			地先沖合における							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	21	2256			地先沖合における							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	22	2524			効期間は、満了							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	22	2636			間にこの二延長							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	22	2668			らに延長す締結							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	23	2988			定の有効延長							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	23	3040			政府の代表閣							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	23	3078			閣して明年協議							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	24	3226			の沖合水先操業							
D:\MY-DOC-data\名古屋国会議事録サンプル.txt	24	3374			漁業水域に操業							

A列2行目にカーソルを置く
1.ウィンドウを固定する

Microsoft Excel - Book2					
ファイル(F) 編集(E) 表示(V) 挿入(I) 書式(O) ツール(T) データ(D) ウィンドウ(W) ヘルプ(H) Adobe PDF(P)					
A2 F¥¥場面別コーパス¥最終版¥各種¥					
	A	B	C	D	E
1	ファイル名	行	位置	先行文脈	直前語
2	F¥¥場面別	4711	654076	家族に	ご苦
3	F¥¥場面別	11872	1667633	はるばる、	ご苦
4	F¥¥場面別	12079	1693366	おすぎ、	お疲
5	F¥¥場面別	12236	1715458	板』に巻き	お疲
6	F¥¥場面別	12452	1746263	年間	お疲
7	F¥¥場面別	12489	1752365	お疲れさ	です。元気を
8	F¥¥場面別	12507	1755901	ってるんだ	です。今年
9	F¥¥場面別	12509	1756486	んファミリ	お疲れ様
10	F¥¥場面別	12665	1778846	されている	お疲れ様
11	F¥¥場面別	13189	1853389	お疲れさ	です。帰宅
12	F¥¥場面別	13351	1878187	本当に	お疲れさ
13	F¥¥場面別	14057	1975035	日曜日。だ	お疲れ様
14	F¥¥場面別	14425	2044480	更新作業	です。ラジ
15	F¥¥場面別	15174	2172113	日となるの	お疲れさ
16	F¥¥場面別	15312	2200035	ら、クリック	お疲れさ
17	F¥¥場面別	15628	2254895	ほとんど	お疲れ様
18	F¥¥場面別	15740	2274584	8月皆様	お疲れ様
19	F¥¥場面別	15755	2277036	らずで、お	お疲れさ
20	F¥¥場面別	15774	2279019	今日。	お疲れさ
21	F¥¥場面別	16040	2317059	、	お疲れさ
22	F¥¥場面別	16443	2384384	レテレ。観	ご苦労さ
23	F¥¥場面別	16445	2384762	「観、	ご苦労さ
24	F¥¥場面別	16451	2386278	フォーマー	お疲れさ
25	F¥¥場面別	16453	2386613	ある世田	お疲れ様
26	F¥¥場面別	16564	2402638	ます。	です。
27	F¥¥場面別	16643	2384384	盛大でし	お疲れ様
28	F¥¥場面別	16645	2384762	西さん、	お疲れ様
29	F¥¥場面別	16451	2386278	です。ほん	お疲れさ
30	F¥¥場面別	16453	2386613	まったん	お疲れ様
31	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
32	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
33	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
34	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
35	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
36	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
37	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
38	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
39	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
40	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
41	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
42	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
43	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
44	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
45	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
46	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
47	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
48	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
49	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
50	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
51	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
52	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
53	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
54	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
55	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
56	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
57	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
58	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
59	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
60	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
61	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
62	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
63	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
64	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
65	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
66	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
67	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
68	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
69	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
70	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
71	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
72	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
73	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
74	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
75	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
76	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
77	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
78	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
79	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
80	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
81	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
82	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
83	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
84	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
85	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
86	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
87	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
88	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
89	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
90	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
91	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
92	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
93	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
94	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
95	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
96	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
97	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
98	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
99	F¥¥場面別	16564	2402638	皆さん、	お疲れ様
100	F¥¥場面別	16564	2402638	皆さん、	お疲れ様

- 入力する
 - H 1 セル：文字数
 - I 1 セル：を
 - J 1 セル：と
 - K 1 セル：漢語名詞
 - L 1 セル：コーパス
- フィルターをクリック（データ→フィルター）

データ整形

- 目的
 - 見やすくする、数えやすくする
 - 統計処理(SPSS,JMPなど)にもかけやすくする
- 技術
 - テキスト関数：={find, len, left, mid}
 - 目で見えて作業可能なデータ(?数百程度)では手でやるのが良いが、
 - 千や万単位のデータを扱う際には強力
 - データの特徴を素早く把握するためには不可欠
 - 人為的なミスを防げる

用語について

- 関数=いろいろな機能を実現してくれる、便利な命令文

The image shows an Excel spreadsheet with a table of data. The table has two columns: '項目' (Item) and '頻度' (Frequency). The data rows are: 'aa' with frequency 10, 'bb' with frequency 30, and 'cc' with frequency 40. A '合計' (Total) row is at the bottom, showing a value of 80. The formula bar shows '=SUM(B2:B4)'. An orange callout box highlights the formula, with arrows pointing to its components: '関数 (かんすう)' (Function) points to '=SUM', '引数 (ひきすう)' (Argument) points to 'B2:B4', and '返回值' (Return value) points to the result '80' in the cell.


項目	頻度
aa	10
bb	30
cc	40
合計	80

Formula: **=SUM(B2:B4)**

Labels in image:

- 関数 (かんすう) - points to the function name 'SUM'
- 引数 (ひきすう) - points to the range 'B2:B4'
- 返回值 - points to the result '80'

エクセル関数とは



海水を真水に変える装置

海水を投入すると、真水が得られます

この装置に投入する**海水**が**引数（ひきすう）**にあたります。
海水を真水にする装置が**関数**です。
その結果出てきた**真水**が**返り値**です。

コピーで中の引数をいちいち修正する必要がない

This screenshot shows an Excel spreadsheet with a table. The formula bar at the top shows `=SUM(B2:B4)`. A red arrow points from this formula bar to cell B5, which contains the value 80. Another red arrow points from the same formula bar to cell C5, which is currently empty. This illustrates how the formula can be copied and pasted into another cell without needing to manually edit the range.

	A	B	C	D
1	項目	頻度		
2	aa	10		
3	bb	30		
4	cc	40		
5	合計	80		
6				
7				
8				

This screenshot shows the same Excel spreadsheet after the formula has been copied to cell C5. The formula bar now shows `=SUM(C2:C4)`. Cell C5 now contains the value 90, which is the sum of the values in cells C2, C3, and C4 (20 + 20 + 50 = 90). This demonstrates how the formula automatically adjusts its range when copied to a new location.

	A	B	C	D
1	項目	頻度		
2	aa	10	20	
3	bb	30	20	
4	cc	40	50	
5	合計	80	90	
6				
7				
8				

エクセル関数とは

- 値同士の関係を命令(指定)するための書式

=関数 (引数)

- 共通記号

1. = 関数であることの指定
2. \$ セルの固定する
3. & セルを結ぶ
4. “ ” 文字列であることの印

- H2のセルに
「=b2+c2」と入力してみよう

次に、

「=b2&c2」と入力してみよう

- H2の内容をH3, H4にコピーしてみよう
- H2を 2, 2, 3, 3にコピー

- \$ 記号を入れてみよう
=C2 → =\$C2, =C\$2, =\$C\$2

コピペしても、中の数字が変わらない！

- “ ” 記号を入れてみよう
K2のセルに
="aaaa"&C2

- ここから本番です

関数の説明

- ファインド
=FIND(検索文字列,対象,開始位置)：文字列が開始位置から何番目にあるかを返します
- レン
=LEN(文字列)：文字列の文字数を返します。半角文字と全角文字との区別はされません

関数の説明

- レフト
=LEFT(文字列,[文字数])：文字列の左端から指定した文字数だけ取り出す。
- ミッド
=MID (文字列, 開始位置,文字数)：文字列の指定した位置から指定した文字数だけ取り出す。
- ライト
=RIGHT(文字列,[文字数])：文字列の右端から指定した文字数だけ取り出す。

入れてみよう

- H2セルに **=len(e2)**と入力
- I2セルに **=find(“を“,e2)**と入力
- J2セルに **=find(“と“,e2)**と入力
- #VALUE!：関数が正しくない
- あとはコピペ
- Find(i2,e2), Find(j2,e2) → i\$2, j\$2

- フィルターを活用しよう
 - 文字数「2」
 - 「と」が「#VALUE!」

- 漢語名詞に
=e19
あとはコピペ。。。。

- フィルターを活用しよう
 - 文字数「3」
 - 「を」が「3」

- 漢語名詞 K53
=LEFT(E53,2)
あとはコピペ。。。。

入れてみよう

- L 2 に

=MID(A2,FIND("コーパス",A2)+5,LEN(A2))

B2		=MID(A2,FIND("名古屋",A2)+4,LEN(A2))									
A	B	C	D	E	F	G	H	I	J	K	
ファイル名	コーパス名	行	位置	先行文	直前語	キーワード	後続文	文字数を数え	“を”の本	“ど”の本	
2	D:\MY-DOC\国会議事録サンプル.txt	23	3040	政府の代	して	明年十一月		1	#VALUE!	#VALUE!	
3	D:\MY-DOC\国会議事録サンプル.txt	35	4574	日中平和	対	して	ソ連側では	1	#VALUE!	#VALUE!	
4	D:\MY-DOC\国会議事録サンプル.txt	35	4618	ソ連側では	対	して	不信感を抱	1	#VALUE!	#VALUE!	
5	D:\MY-DOC\国会議事録サンプル.txt	35	4652	本に対して	対	して	ソ連側の要	1	#VALUE!	#VALUE!	
6	D:\MY-DOC\国会議事録サンプル.txt	35	4692	してソ連側	対	して	は耳を傾け	1	#VALUE!	#VALUE!	
7	D:\MY-DOC\国会議事録サンプル.txt	48	7136	したときの	減	して	二十万トン	1	#VALUE!	#VALUE!	
8	D:\MY-DOC\国会議事録サンプル.txt	48	7206	サバを十	方	に	もらいたい	1	#VALUE!	#VALUE!	
9	D:\MY-DOC\国会議事録サンプル.txt	58	9303	鐘がくる	か	対	して	ソ連は非常	1	#VALUE!	
10	D:\MY-DOC\国会議事録サンプル.txt	59	9531	る。多少	無	押	して	きたのか。	1	#VALUE!	
11	D:\MY-DOC\国会議事録サンプル.txt	60	9789	は問題を	配	対	して	は巷間、い	1	#VALUE!	
12	D:\MY-DOC\国会議事録サンプル.txt	75	12589	っかり追	っ	対	して	、専門的な	1	#VALUE!	
13	D:\MY-DOC\国会議事録サンプル.txt	77	13019	いかと思	い	対	して	どのような	1	#VALUE!	
14	D:\MY-DOC\国会議事録サンプル.txt	77	13471	から、転	換	示	して	もらいたい	1	#VALUE!	
15	D:\MY-DOC\国会議事録サンプル.txt	103	17930	土問題と	し	対	して	日本の水産	1	#VALUE!	
16	D:\MY-DOC\書籍サンプル.txt	19	1020	味期限も	短	と	して	は考えませ	1	#VALUE!	
17	D:\MY-DOC\書籍サンプル.txt	43	2034		と	して	ガンガン飛	1	#VALUE!		
18	D:\MY-DOC\書籍サンプル.txt	83	4602		出	して	ズバリ言う	1	#VALUE!	#VALUE!	
19	D:\MY-DOC\書籍サンプル.txt	111	5820		そ	して	、わたし流	1	#VALUE!	#VALUE!	
20	D:\MY-DOC\書籍サンプル.txt	123	6256		そ	して	、この恋愛	1	#VALUE!	#VALUE!	
21	D:\MY-DOC\書籍サンプル.txt	135	7112		に	して	も、結婚し	1	#VALUE!	#VALUE!	
22	D:\MY-DOC\書籍サンプル.txt	156	8286	躍動的な	前	そ	して	儼しくて母	1	#VALUE!	
23	D:\MY-DOC\書籍サンプル.txt	171	9052		そ	して	、残った科	1	#VALUE!	#VALUE!	
24	D:\MY-DOC\書籍サンプル.txt	181	9638	言葉はい	と	して	必須のキー	1	#VALUE!		
25	D:\MY-DOC\書籍サンプル.txt	211	11174	を騙すタイ	隠	して	話す癖です	1	#VALUE!	#VALUE!	
26	D:\MY-DOC\書籍サンプル.txt	248	13290		出	して	はいけませ	1	#VALUE!	#VALUE!	
27	D:\MY-DOC\書籍サンプル.txt	332	17288		愛	して	いるからこ	1	#VALUE!	#VALUE!	
28	D:\MY-DOC\書籍サンプル.txt	332	17340	すべてを許	愛	して	いるからこ	1	#VALUE!	#VALUE!	
29	D:\MY-DOC\書籍サンプル.txt	332	17374	「愛してい	許	して	はいけない	1	#VALUE!	#VALUE!	
30	D:\MY-DOC\書籍サンプル.txt	336	17580		お許	して	あげる。	1	#VALUE!	#VALUE!	
31	D:\MY-DOC\書籍サンプル.txt	337	17604		愛	して	いるんだも	1	#VALUE!	#VALUE!	
32	D:\MY-DOC\書籍サンプル.txt	363	18710	性はこと	ろ	そ	して	飽きたらボ	1	#VALUE!	
33	D:\MY-DOC\書籍サンプル.txt	364	18744		許	して	しまう女性	1	#VALUE!	#VALUE!	
34	D:\MY-DOC\書籍サンプル.txt	370	19006		恋	して	いる間は桂	1	#VALUE!	#VALUE!	
35	D:\MY-DOC\白書サンプル.txt	49	4713		そ	して	それらは多	1	#VALUE!	#VALUE!	
36	D:\MY-DOC\白書サンプル.txt	71	6941	年度より	増	示	して	いる。	1	#VALUE!	

その他便利な関数

- =セル番地&セル番地：文字列をくっ付ける
- =セル番地&“文字列”：セルに文字列を追加する
- =PHONETIC(セル番地)：発音をかえす
- =EXACT(文字列1,文字列2)：文字列の異同をチェックする

ピボットテーブル

- エクセルに備わっているデータの集計や分析をマウスのドラッグ操作で簡単に行うことが出来る機能
- 主な用途
 - － 度数表：タイプ、トークン頻度
 - － クロス集計表
 - － 平均や合計なども計算可能

1

2

3

4

ピボットテーブル/ピボットグラフ ウィザード - 1/3

分析するデータのある場所を選択してください。

- ☒ Excel のリスト/データベース (M)
- ☐ 外部データ ソース (E)
- ☐ 複数のワークシート範囲 (C)
- ☐ ほかのピボットテーブル レポートまたはピボットグラフ レポート (A)

作成するレポートの種類を指定してください。

- ☒ ピボットテーブル (T)
- ☐ ピボットグラフ レポート (ピボットテーブル レポート付き) (B)

キャンセル < 戻る (B) 次へ (N) > 完了 (F)

ピボットテーブル/ピボットグラフ ウィザード - 2/3

使用するデータの範囲を指定してください。

範囲 (R): \$A\$3:\$G\$43 参照 (M)...

キャンセル < 戻る (B) 次へ (N) > 完了 (F)

ピボットテーブル/ピボットグラフ ウィザード - 3/3

ピボットテーブル レポートの作成先を指定してください。

- ☒ 新規ワークシート (N)
- ☐ 既存のワークシート (E)

[既定] をクリックすると、ピボットテーブル レポートが作成されます。

レイアウト (L) オプション (O) キャンセル < 戻る (B) 次へ (N) > 完了 (F)

商品	単価	数量	金額	担当
ビール	2,000	10	20,000	山本
ワイン	1,500	5	7,500	山本
日本酒	2,000	7	14,000	山本
酎	1,000	9	9,000	山本
ビール	2,000	15	30,000	緒方
酎	1,000	6	6,000	緒方
日本酒	2,000	7	14,000	緒方
ビール	2,000	10	20,000	緒方

オフィス2007の場合

1

2

ピボットテーブル

二文字の漢語.xlsx - Microsoft Excel



ホーム 挿入 ページレイアウト 数式 データ 校閲 表示 Acrobat

ピボットテーブル

折れ線 面 円 図形 SmartArt 表 図 グラフ ハイパーリンク リンク テキスト ボックス 署名欄 ヘッダーとフッター オブジェクト ワードアート 記号と特殊文字 テキスト

B2 =MID(A2,FIND("名古屋",A2)+4,LEN(A2))

	D	E	F	G	H	I	J	K	L	M
1	位置	先行文脈	直前語	キーワード	後続文脈	文字数を数え	"を"の有	"と"の有	二文字の漢語	
385	5315	では、公共	疑問視	する	見方も現わ		3 #VALUE	#VALUE		
386	13062	量の変化を	均衡化	する	。		3 #VALUE	#VALUE		
387	16491	加は総需要	分減少	する	ことを意味		3 #VALUE	#VALUE		
388	8374	少なく	する	ためのルー			3 #VALUE	#VALUE		
389	13229	何度プレイ	クリア	する	とD値が上		3 #VALUE	#VALUE		
390	13253	ないそして	クリア	する	楽しみが増		3 #VALUE	#VALUE		
391	17528	の新しい	長持ち	する	確率は高く		3 #VALUE	#VALUE		
392	6181	始されて、	一年延滞	する	議定書と滞		4 #VALUE	#VALUE		
393	5990	最初は一	憶れたり	する	でしょう。		4 #VALUE	#VALUE		
394	15448	必ずそう	する	から」			4 #VALUE	#VALUE		
395	17560	あなたの	する	ことはなん			4 #VALUE	#VALUE		
396	17736	なんでも	する	んだよ」な			4 #VALUE	#VALUE		
397	4543	最もしば	く	する	と、画面が		4 #VALUE	#VALUE		
398	8890	ら仲間が	増ワクワ	する	し、おす		4 #VALUE	#VALUE		
399	15898	ドラクエ	8でドロ	ップ	する	モンスター	4 #VALUE	#VALUE		
400	11380	上目遣い	する		と、いわ		5 #VALUE	#VALUE		
401	12800	ントを用	意し予約	した	する		5 #VALUE	#VALUE		
402	4617		修理など	する	所がある		5 #VALUE	#VALUE		
403	16188		以上値下	する	前に、新		5 #VALUE	#VALUE		



ピボットテーブルのフィールドリスト

レポートに追加するフィールドを選択してください

☐ ファイル名
☐ 行
☐ 位置
☐ 先行文脈
☐ 直前語
☐ キーワード
☐ 後続文脈
☐ 文字数
☐ を
☐ と
☒ 漢語名詞
☒ コーパス

次のボックス間でフィールドをドラッグしてください

レポート フィルタ 列ラベル

行ラベル Σ 値

漢語名詞 データの個数

レイアウトの更新を保... 更新

サ変名詞	トークン頻度	
存在	4131	
説明	3807	
利用	3636	
理解	3396	
紹介	2943	
確認	2383	
発見	2293	
結婚	2218	
主張	2089	
発生	2084	
参加	2051	
使用	2019	
意味	2007	
指摘	1960	
成功	1861	
登場	1817	
実現	1815	
判断	1775	
展開	1764	
表現	1718	
成立	1706	
用意	1660	
発表	1645	
心配	1634	

←BCCWJの書籍コーパス
全体で調べると、

正規表現とは

- 正規表現（せいきひょうげん、regular expression）とは、文字列の集合を一つの文字列で表現する方法の一つである。
- ある要素（文字とか単語など）の前後に特定のパターンを持ったものが接続していく形の記述
 - 戻って 買って 貼って いった
 - [戻買]って
 - .って

正規表現

- 「秀丸」でできる
- ワードではできない色々な操作が可能
 - 改行やタブを消したり、入れたり。
 - 空白行を見つけて消したり、
 - 特定の条件にマッチした表現だけを集めたり
 - 詳しくは：
<http://www.shuiren.org/chuden/teach/hidemaru/seiki/index-j.html>
- ワードに比べ、非常に高速であり、動作が軽い。

記号の説明

- [] キャラクタクラス
 - 一文字単位で指定するときに使用.
 - abc, abb, aba とあるとき, ab の後ろには, a, b, c のどれかがくるので, これらをまとめるときには, ab[abc] のように記述する.
 - 便利な方法
 - ひらがな全部: [あ-ん]
 - 漢字全部: [亜-黒]
 - 「-」は, その間にあるもの全てを表す.

記号の説明

- () パターンをグループ化する
 - 同じ種類の表現をまとめたいときに使用.
 - 今日, 明日, 明後日 のどれかを検索したいときは, []は使えない. [今明明後]日では, (明後日が拾えず)「後日」が検索されてしまう.
 - そこで, それぞれをまとめて(今日|明日|明後日)とする. 「|」は区切りの記号と覚える.
 - もう少しまとめて「(今|明|明後)日」としてもよい.

正規表現はすごい！

1.<E>.*</E>

2.<T.*¥n

3.<E>.*</E> | <T.*¥n

- お疲れ様でした！
- 明日は、
 - 形態素解析器をインストールします。
 - PC操作に自身のない方は、9:30に来ていただければ、李がインストール・形態素解析器の動作確認します。

2日目

2010/1/23-24
名古屋大学

日本語コーパスの最新の検索 エンジンと分析

李在鎬（りじえほ）
国際交流基金



1/24のお品書き

- 復習
- 前半
 - コーパスツール紹介：形態素解析
 - 実習
- 後半
 - タグ付きK Yコーパス
 - コーパスデータ紹介：ウェブからアクセス可能なフリーデータ

復習

- コーパスとは構造化された言語データの集積。
- コーパス言語学では、共起関係と頻度を重視。
- 調査を開始する際には、
 - コーパス選び：代表性のあるデータ選択
 - 用例抽出：KWIC形式。正規表現を活用
→Kwic finder
 - 用例集計：エクセルを活用→関数・ピボットテーブル

- 正規表現：さるでもわかる正規表現
 - <http://www.mnet.ne.jp/~nakama/>
- エクセル関数：
 - <http://www.eurus.dti.ne.jp/~yoneyama/Excel/kansu/itiran.html>

KWIC FINDERの問題点


- コーパス大きさが分からずに検索をする→得られたデータの位置づけがよくわからない。
 - 1 億語の中で100回使われている表現
 - 1 万語の中で100回使われている表現
- Kwic finderとエクセルで数える方法ではいずれも、同じくらいの表現として解釈！
- ウェブ検索と結果的には変わらない→コーパス研究とは言えない。

- 何とかしなければ・・・。
 - コーパスの大きさを知る
 - 文字数
 - 語数（延べか異なりか）
 - 一文の平均文字数や語数
- 形態素解析を使って、語数を調べる。

ソフトのインストール

– KH Coder

- これで、KH Coder(プログラム本体)とMySQL(データベース用ソフト), ChaSen(形態素解析ソフト), R(統計ソフト)が同時にインストールされたことになる。



形態素解析に基づく データ加工と抽出

形態素解析とは（

- 形態素解析（Morphological Analysis）

- コンピュータ等の計算機を用いた自然言語処理の基礎技術のひとつ。
- 対象言語の文法の知識（文法のルールの集まり）や辞書（品詞等の情報付きの単語リスト）を情報源として用い、自然言語で書かれた文を形態素（Morpheme; 言語で意味を持つ最小単位）の列に分割し、それぞれの品詞を判別する作業を指す。
- 具体例：「お待ちしております」

形態素解析とは（

文字列	読み	原形	品詞の種類	活用の種類	活用形
お待ち	オマチ	お待ち	名詞-サ変接続		
し	シ	する	動詞-自立	サ変・スル	連用形
て	テ	て	助詞-接続助詞		
おり	オリ	おる	動詞-非自立	五段・ラ行	連用形
ます	マス	ます	助動詞	特殊・マス	基本形
。	。	。	記号-句点		

*茶釜の場合

形態素解析とは


- どんなものがあるのか。
 - ChaSen（茶筌_(×茶筴)）：奈良先端大学
 - <http://chasen.naist.jp/hiki/ChaSen/>
 - Juman：京大で開発
 - <http://nlp.kuee.kyoto-u.ac.jp/nl-resource/juman.html>
 - Mecab（和布蕪）：京都大学・NTT
 - <http://mecab.sourceforge.net/>
 - 色々ある。。。

- やってみよう！ 形態素解析

ソフトを立ち上げよう

- 手順1：マイコンピュータをクリック
- 手順2：C:¥ドライブをクリック
- 手順3：c:¥KH Coder→dep →chasen → chasen.exe

この画面が出てればOK




日本語を出すには？


「Alt」キーを押しながら「半角/全角」キーを押す！



この画面が出てればOK



- 文字を入力してみよう！
 - 「文字を入力してみよう」と入力



結果と簡単な仕組み


- 最初のウィキペディアの説明に戻ると、
 - 対象言語の文法の知識（文法のルールが集まり）や辞書（品詞等の情報付きの単語リスト）を情報源として用い、自然言語で書かれた文を形態素の列に分割し、それぞれの品詞を判別する作業を指す。



- 何に使える？、どんなことに役立つ？
 - 直接的な利用法：解析結果をエクセルファイルなどに読み込んで品詞や語単位で数える
→計量的調査に利用
 - 二次的な利用法：コンコーダンサー (concordancer)を使って高度な検索を行うことができる
- 例えば、

何ゆえ形態素解析か

- タスク
 - 動詞の用法確認とデータの収集
e.g., サ変名詞+する
- Before
 - Googleで文字列検索 ⇒ゴミが大量。
 - 秀丸で「検索」 活用形別に正規表現を組まないとい
 - KWIC Finder けないので面倒
- After



形態素解析を使う

・フリーで利用可能なツール

－ KH Coder

- ・立命館大学の樋口耕一氏が製作
- ・内容分析に特化。集計機能が充実

－ 茶器

- ・奈良先の浅原正幸氏が製作
- ・多言語コーパスに特化。カスタマイズ機能が充実

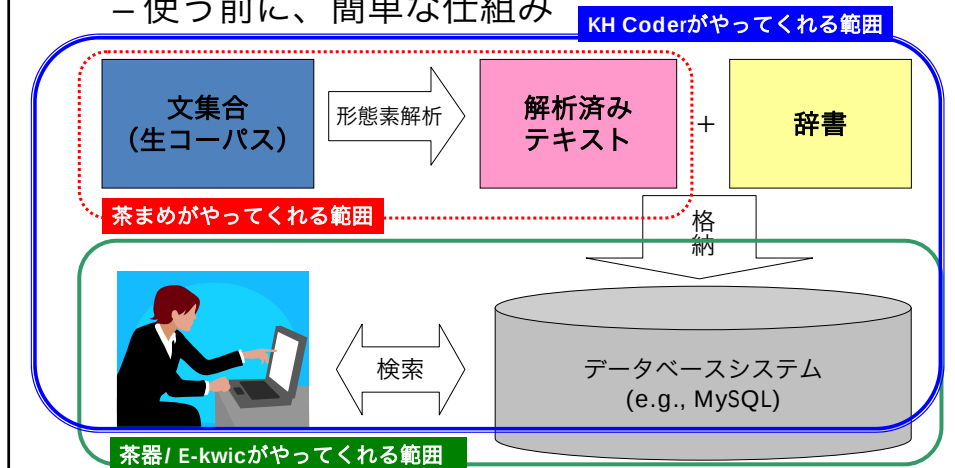
－ 茶まめ

- ・国研の日本語コーパス伝(他)が製作
- ・人文系への親和性重視。音声言語処理に有効。

－ E-Kwic


形態素解析を使う

- 茶まめ、茶器、KH Coder
 - 使う前に、簡単な仕組み



ツールの詳細情報

- 茶まめ
 1. 国研日本語コーパス電子辞書班
 2. 形態素解析補助ツール
 3. 形態素解析は茶筌かMecab
 4. 入手方法：
<http://www.tokuteicorpus.jp/dist/index.php>
 5. 関連情報：使用レポートなど
<http://www30.atwiki.jp/corpus-ling/pages/36.html>
 6. 関連論文：伝 康晴(他)(2006)
「多様な目的に適した形態素解析システム用電子辞書の開発」
('日本語コーパス'全体会議電子化辞書班報告)



ツールの詳細情報

- KH Coder

1. 樋口耕一（立命館大学）作成
2. 計量社会学ツール
3. 分析機能やデータ抽出機能が充実
4. 入手方法：
<http://khc.sourceforge.net/>
5. 関連情報： 使用レポートなど
<http://www30.atwiki.jp/corpus-ling/pages/28.html>
6. 関連論文： 佐野香織・李在鎬
(2007)「KH Coderで何ができるか~日本語習得・日本語教育研究利用への示唆~」、『言語文化と日本語教育』(No.33),pp.94-95.



ツールの詳細情報

- E-KWIC

1. 茶まめによる形態素解析済みのデータを検索
2. エクセル上で動作する。インストール作業は不要
3. 入手方法：
<http://www30.atwiki.jp/corpus-ling/pages/63.html>



形態素解析のツールを使う

- 実習 1 : KH Coder
- 実習 2 : E-Kwic

形態素解析のツールを使う

- 実習 1 : KH Coder
- 実習 2 : E-Kwic


ソフトのインストール

– KH Coder設定ファイルの差し替え


- 皆さんの研究テーマに合わせて抽出可能な形態素の設定を書き換える
- 方法：¥nagoya¥tempのhinshi_chasenをコピーして、c:¥kh coder¥configに張り付ける。
- 上書きするかどうか聞いてくるが、上書きを選択する。
- これで、格助詞や補助動詞、終助詞などが検索できるようになる。

起動してみよう

– C:¥khcoder¥kh_coder.exe をクリック！



操作イメージ




メニューバー


- 四つの基本操作
 - プロジェクト：コーパスの登録など
 - 前処理：「茶釜」による解析
 - ツール：データ抽出系や集計
 - ヘルプ

ごめんなさい

- テキストファイルの文字コードを変更




名前付けて保存



分析データの登録

- プロジェクト



前処理

- 茶釜の実行


KH Coderが分析対象として認識しているものの語数

異なり語数について
1059(941)

ChaSenによる解釈


総抽出語数：延べ語数
異なり語数が表示

文数：句読点を数えている



結果を確認

- 解析の結果を確認しよう
 - ツール > 抽出語 > 抽出語リスト




固有名词										
A	B	C	D	E	F	G	H	I	J	K
1	固有名词	サ変名詞	形容動詞	ナイ形容	否定助動詞	名詞				
2	毎日	4 恋愛	35 好き	12 さりげ	2 ない	59 女性				
3	オン	3 仕事	16 ダメ	9 違い	1 ん	31 男性				
4	しげ	1 結婚	11 大切	8 間違い	1 め	6 人				
5	マフィア	1 充実	9 元気	7 仕方	1 まい	1 女				
6	愛	1 教育	8 特別	4 問題	1	大人				
7	厳	1 オン	7 無意識	4		男				
8		イメージ	6 嫌い	3		恋人				
9		意識	6 自然	3		身体				
10		記念	6 いい加減	2		部分				
11		成長	5 家庭的	2		オーラ				
12		注意	5 簡単	2		ステップ				
13		電話	5 嫌	2		公園				
14		関係	4 真剣	2		恋				
15		誕生	4 素直	2		フェロモン				
16		遅刻	4 素敵	2		運命				
17		イキイキ	3 同様	2		顔				
18		デート	3 必要	2		最初				
19		一緒	3 不思議	2		周囲				
20		食事	3 明確	2		人間				
21		生活	3 ご苦労	1		素				
22		直感	3 しどやか	1		相手				
23		要求	3 ぞっこん	1		法則				
24		理解	3 エネルギー	1		魅力				
25		インプット	2 エレガント	1		理由				
26		パーティ	2 パワフル	1		うつ				
27		プレゼント	2 プライベート	1		ひとり				
28		化粧	2 圧倒的	1		ふたり				
29		気配り	2 下品	1		印象				

コンコーダンサーを起動


- KWIC



ー ツール>抽出語>コンコーダンス



コンコーダンサーを起動


- 検索しよう






パターン検索

追加条件



OKをクリック
して、もう
一度検索！




パターン検索

追加条件

- － 形容詞の連体修飾表現
- － やってみてください！







便利な機能

・ 集計

－ ツール > 抽出語 > 記述統計 > 出現回数の分布




- 関連語探索



ファイルを呼び出す

- プロジェクト > 開く



よくあるトラブル

- 一行が長すぎると処理が止まる（茶釜の問題）
- テキストの最初の一行目が空白だとエラーが出る。無駄な空白は消しておこう
- 文字コードは「Shift-JIS」「EUC」「JIS」のみ対応。Unicodeは非対応。Chasenの処理が止まる！


最後に

- 色々な分析機能がついている。Rによる統計処理なども可能だが、注意して使うべし
- テキストサイズ：無制限だが、大きいファイルを分析する場合は、十分なハードディスクの容量(100倍)と時間が必要
- KH Coderを使って論文を書いたら作成者に報告

応用研究 - Mozilla Firefox

ファイル(F) 編集(E) 表示(V) 履歴(S) ブックマーク(B) ツール(T) ヘルプ(H)

http://khc.sourceforge.net/bib.html KH coder



・KH Coder関連文献

KH Coderを用いて行われた研究(の中で樋口が把握しているもの)のリストです。学会発表も含んでいます。

池本淳一 2003「スポーツの中の日常、日常の中のスポーツーボクシングを事例としてー」
第54回 関西社会学会 5月25日

伊藤昌亮 2006「オンラインメディアイベントとマスメディアー2ちゃんねる・24時間マラソン監視オフの内容分析からー」『社会情報学研究』(ISSN:13429604) 10(2): 9-23

OSAKI, Azusa & LEE, Jae-Ho 2007 "A Hierarchy of Semantic Constraints in Japanese Fictive Motion" In 10th International Cognitive Linguistics Conference (Krakow, Poland)

大瀧友織 2001「夫婦間における『性格の不一致』という問題ー一身の上相談を資料としてー」
第11回 日本家族社会学会 9月8日

大瀧友織 2003「コンピュータ・コーディングによる夫婦問題の分析ー日常生活における妻の不満ー」第13回 日本家族社会学会 9月6日

完了



- お疲れ様でした。
- ちょっと休憩&質問お受けします。

日本語コーパスの最新の検索 エンジンと分析

李在鎬（りじえほ）
国際交流基金



使い分ける

- Kwic Finder：長い単位に強い。
- KH Coder: 長い単位は検索が面倒。
 - お疲れ様。ご苦労様
 - 併用しましょう。

形態素解析のツールを使う

- 実習 1 : KH Coder
- 実習 2 : E-Kwic

開発背景

- 研究パラダイムのシフト
 - 誤用分析→中間言語：誤用のみならず、正用をも含めた包括的観点から学習者言語の実態を知ることの重要性が強調（長友1993、長友1999、迫田2001、鎌田2006)
 - データの収集と体系的分析が必要：コーパス化(鎌田1999、大曾1999、宇佐美2005)

開発背景

- KYコーパス
 - OPIに基づく学習者コーパス
 - もっとも多くの研究において利用
 - フリーで利用可能
- 現状確認
 - 限定的調査：文字列を基盤にしたもの
 - 手作業による事例収集：ミスの可能性あり。計量的調査としての信頼性に関して必ずしも十分ではない

開発背景

- 具体的には、
 - 例1) 文字列検索で助詞「は」を調査
 - 得られたデータが学習者のものかどうか？
 - 助詞以外のものが混ざっている
 - 例2) 文字列検索で指示詞「あの」を調査
 - フィラーの場合と連体詞の場合はどうする？
- 人が見て必要なもののみを抽出することも可能だが、もっと効率よくいろんなデータを解析する

形態素解析器の問題2

- 例えば、

C:\krcoder\dep\chasen\chasen.exe									
EOS									
それか	ね	とても	おいしい	の					
それ	ソレ	それ	名詞-代名詞一般						
が	ガ	が	助詞-格助詞一般						
ね	ネ	ねる	動詞-自立	一段	連用形				
			記号-読点						
とても	トデモ	とても	副詞-助詞類接続						
おいしい	オイシイ	おいしい	形容詞-自立		形容詞-イ段				
基本形									
の	ノ	の	名詞-非自立一般						
EOS									
それが	ですね								
それ	ソレ	それ	名詞-代名詞一般						
が	ガ	が	接続詞						
です	デス	です	助動詞-特殊・デス		基本形				
ね	ネ	ね	助詞-終助詞						
EOS									
それを	ですね								
それ	ソレ	それ	名詞-代名詞一般						
を	ヲ	を	助詞-格助詞一般						
です	デス	です	助動詞-特殊・デス		基本形				
ね	ネ	ね	助詞-終助詞						
EOS									


形態素解析器の問題3

- 例えば、

C:\Program Files\ChaSen\chasen.exe									
早い	ハヤイ	早い	形容詞-自立	形容詞・アウオ段	基本形				
の	ノ	の	名詞-非自立一般						
ほう	ハウ	ほう	名詞一般						
が	ガ	が	助詞-格助詞一般						
良い	ヨイ	良い	形容詞-自立	形容詞・アウオ段	基本形				
じゃ	ジャ	じゃ	助詞-副助詞						
ない	ナイ	ない	助動詞-特殊・ナイ		基本形				
の	ノ	の	助詞-終助詞						
EOS									
たの、	楽しい、								
た	タ	た	助動詞-特殊・タ		基本形				
の	ノ	の	名詞-非自立一般						
楽しい	タノシイ	楽しい	形容詞-自立	形容詞・イ段	基本形				
			記号-読点						
EOS									
です	そうですね	で							
で	デ	で	接続詞						
す	ス	す	名詞一般						
く	ク	く	記号一般						
そうですね	ソウデスネ	そうですね	感動詞						
く	ク	く	記号一般						
で	デ	だ	助動詞-特殊・タ		連用形				
			記号-読点						
EOS									

データ加工

• 人手によるチェックと修正を行う



検索ツールの開発

- 既存のツールではうまく動作しない
- 既存のツールはインストールが難しい
- 高機能でなくても良いので、使いやすいツールを作る：エクセルで動作するツールを作成

E-KWIC

E-KWIC (KYコーパス検索)

検索語: 走る 品詞: 動詞 意味分類: 指定しない 検索 中断

正誤: ☒ すべて ☐ 正用のみ ☐ 誤用のみ

学習者のレベル: ☒ 初級 ☒ 中級 ☒ 上級 ☒ 超級

学習者の母語: ☒ 韓国語 ☒ 中国語 ☒ 英語

19件の用例が見つかりました。 Excel ブックに出力

ファイル名 行 正誤 左 キー 右

ここがすごい！

1. 他のソフトをインストールする必要なし
2. 意味分類も対応
3. 誤正別にデータを抽出できる
4. 結果をエクセルに出力
5. 自作データにも同じように使える



Microsoft Excel - Book1

ファイル(F) 編集(E) 表示(V) 挿入(I) 書式(O) ツール(T) データ(D) ウィンドウ(W) ヘルプ(H) 拡張機能(K)

MS ゴシック 9 B I U

1 2 3 4 5

1 2 3 4 5

2 3 4 5

3 4 5

4 5

5

6

7

8

9

10

11

12

13

14

15

16

17

18

19

20

コマンド

マクロ(M)... Alt+F8

新しいマクロの記録(R)

セキュリティ(S)... ←

Visual Basic Editor(V)... Alt+F11

Microsoft Script Editor(E)... Alt+Shift+F11

ツール(T) データ(D) ウィンドウ(W) ヘルプ(H)

スペルチェック(S)... F7

エラーチェック(E)...

ブックの共有(O)...

変更履歴の記録(I)

ブックの比較と反映(M)...

保護(P)

オンライングループ作業(N)

ゴールシーク(G)...

シナリオ(E)...

ワークシート分析(L)

Web上のツール(B)...

マクロ(M)

アドイン(I)...

オートコレクトのオプション(O)...

ユーザー設定(C)...

オプション(O)...

セキュリティ

セキュリティレベル 信頼できる発行元 以前の信頼できる発行元

☒ 最高(H) 信頼できる場所(インストールされたマクロだけを実行することができます。その他のマクロは、署名の有無にかかわらず実行不可になります。)

☐ 高(H) 信頼できる作成元からの署名付きのマクロだけを実行することができます。署名のないマクロは自動的に実行不可になります。

☐ 中(M) コンピュータに損害を与える可能性があるマクロを実行する前に警告します。

☐ 低(L) (推奨しません) コンピュータに損害を与える場合があるマクロを実行する前に警告します。ウイルス検査プログラムがインストールされているが、すべてのドキュメントが安全であると確認した場合のみ設定してください。

OK キャンセル

E-KWIC

検索の基本オプション

絞込みオプション

Excel ブックに出力

ファイル名	行	正誤	左	キー	右
ETH04	3029			走	
ENM02	455			走	
ENM02	501			走	
ENM02	507			走	
ENM02	523			走	
ENM02	567			走	
ES07	99			走	
ES07	187			走	
KAH02	956			走	
KAH02	1026			走	
KAH02	1059			走	
KS03	2562			走	
KS07	660			走	
KS07	835			走	
KS07	1245			走	

E-KWIC


- dataフォルダ内の学習者データに対して以下の基本検索ができる
 1. 形態素の検索
 2. 形態素と品詞の組み合わせによる検索
 3. 形態素と品詞と意味分類の組み合わせによる検索
 4. 品詞のみの検索
 5. 意味分類のみの検索

E-KWIC

- 絞り込みによる検索
 1. 形態素の検索
 2. 形態素と品詞の組み合わせによる検索
 3. 形態素と品詞と意味分類の組み合わせによる検索
 4. 品詞のみの検索
 5. 意味分類のみの検索

お品書き

- コーパス紹介：様々なジャンルのコーパス
 - ウェブコーパス
 - 書きことば（新聞・小説）
 - 話しことば
 - 学習者コーパス
 - その他のコーパス
 - シソーラス



ウェブ（基盤の）コーパス

1. 位置づけ

- ウェブ上のデータをコーパス化したもの
 - 自然言語処理の分野で利用。ブログなど
- * ネット検索とは異なることに注意

2. 短所と長所

- 長所：大規模でかつ、著作権フリー、簡単(ウェブブラウザ上で使えるため)、無料
 - 短所：書き手が不明,メンテなし,ノイズ多し
- 長所を生かし、(文法研究に特化した)コロケーションを見るなどの目的においては有効

コーパス紹介

3. 利用可能な資源

ウェブ検索ではないので、見た日によって結果が変わることはない

	格フレーム辞書	Sketch engine	ウィキペディア
内容	表層形としての述語と項を関係づけたデータベース	イギリスで作成された多言語データベース	ウィキペディアのデータをテキスト化し、コーパスとして利用
規模	約5億文 約5万用言	約4億語 (409,384,405語)	時期によって変動あり
下処理 (コーパス化)	不要 形態素・係受解析済	不要 形態素解析済	要 (テキスト化と形態素解析)
利用形態	ウェブブラウザ 無料	ウェブブラウザ 有料(年間1万円)	ダウンロード後 整形(データは無料)
備考		シソーラス搭載	固有名を多数含んでいる、特殊なデータ
元データ	条件付きアクセス可	アクセス不可	アクセス可能

格フレーム検索

[←](#)
[→](#)
[C](#)
[H](#)
[☆](#)
<http://reed.kuee.kyoto-u.ac.jp/cf-search/>

格フレーム検索

[ヘルプ](#)

☐ 名詞から検索,
☐ CSV出力(名詞検索のみ),
 上位 個までの単語を表示,
 頻度 以上の単語を表示

検索例: 「積む」, 「修行を 積む」, 「積む P」(受身), 「積む C」(使役)

©2009 Kurohashi Lab.

<http://reed.kuee.kyoto-u.ac.jp/cf-search/>

動詞による検索：格パターンと共起名詞

名詞による検索：共起する動詞

格フレーム検索

[←](#)
[→](#)
[C](#)
[H](#)
[☆](#)
<http://reed.kuee.kyoto-u.ac.jp/cf-search/>

格フレーム検索

[ヘルプ](#)

☐ 名詞から検索,
☐ CSV出力(名詞検索のみ),
 上位 個までの単語を表示,
 頻度 以上の単語を表示

検索例: 「積む」, 「修行を 積む」, 「積む P」(受身), 「積む C」(使役)

「走る」を検索しました。格要素をクリックすると原文が表示されます。
 (現在、一部要素が修正されていますが、近日中に修正する予定です。)

90%カバ...

走る/はしる

＊＜ガ格＞

車440, バス272, 電車264, 道路162, 列車151, トラック119, カー104, <数量>線103, 自転車85, バイク75, 自動車71, 鉄道63, 線路46, 国道42, 馬車40, <数量>40, 私37, 新幹線34, 機関+車33, タクシー33, ...

＊＜ヲ格＞

中12505, 道12159, 道路9227, 沿い6008, 上5979, 前5205, 街2749, 山道2575, 中2516, 国道2357, 林道2165, 後ろ2147, 廊下2077, 海岸+線1793, 歩道1785, 公道1729, 車道1546, 間1476, 下1450, 市1406, ...

<ニ格>

縦横163, 実際130, <補文>117, 南北106, 東西91, 方面76, ひたすら51, 沿い48, 方向47, 帰り45, 一直線41, 西38, 具?患36, 道34, 東33, 南33, 直走り32, 北27, 小走り26, 平行20, ...

<デ格>

車864, 自転車545, スピード219, バイク188, <数量>150, バス76, <数量>km69, <数量>人?人69, 全速力61, <時間>54, ベース44, 速度43, <数量>h39, レンタカー31, 運転30, 車28, カー28, タクシー27, 我が物顔27, 状態26, ...

<カラ格>

<時間>138, インター15, IC15, 辺り13, 駅7, 空港7, 方面7, 自宅6, 付近6, 向こう5, 函館5, 公園5, 家5, 方5, <数量>5, 釧路4, 大橋4, 温泉4, 先4, 東京4, ...

<マデ格>

<時間>84, インター26, 駅13, 最後9, 終点9, IC7, 端6, 空港6, 途中6, ホテル6, さっき6, <数量>6, <補文>6, 入り口5, 江の島5, 温泉5, 所5, 自宅5, 場所4, 手前4, ...

<ヘ格>

575, 北68, 車61, 方面57, 南41, 方28, 方向27, 北西6, 郊外5, 右5, 奥4, 駅4, 自宅3, 高層3, ...

項構造

共起名詞を意味別にクラスタリング

格フレーム検索

Google

http://reed.kuee.kyoto-u.ac.jp/cf-search/index.cgi?cokey=%C1%F6%A4%EB%2F

格フレーム検索

検索ヘルプ

☐ 名詞から検索☐ CSV出力(名詞検索のみ)上位 20 個までの単語を表示, 頻度 2 以上の単語を表示

検索例: 「積む」, 「修行を 積む」, 「積むP」(受身), 「積むC」(使役)

原文を検索しました。

そういえば、7月から境港ナンバーの車が走るようになりましたね。
ハワイでは早朝からこんな車があちこちで走っています。
細い一本道の路地を車で走っているとき、ずっと前から車が走ってきました。
歩く方向が少し斜めになってしまった結果歩いて歩いてもなかなか向こう側につけなくて、つまり車の方向と直角に歩いているつもりが、いつのまにか車と並行に向かって歩いてしまっていて、そのうちに信号が変わってしま
い、車が動き始めてしまって、自分の後ろや前から車が走ってくる。
朝から国道にも車がひんひん走っています。
朝から車がビュンビュン走っている。
19日から車がますます走らなくなりました。
昨日今日で車が走っているのでプラנקの黄色が路面をこすり黄色い色をとところどころにつけているため、くっきりとここを際立たせていました。
その一方、解けた雪を剥け上(ずて前の車が走りますのでフロントガラスがどんどん汚れ、ウオッシャーをかけても追いつかないくらいに汚れてきました。
ヤンゴンでは車の95%以上が日本の中古車、しかも10年未満の車はほとんどなく、15-30年前の車が走って
いる。
さつきの車が走って行く。
ここで20分くらい停車して前の車が走っていったので付いて走りましたが、結局下車線のトンネル内でした。
折角「80s」と名前がついて、その頃の車が走るのだから、そこらへんも考えて欲しかった。
さらにマシンナーチャングを狙う何組かの銃し屋グループに、保護するグループ、さらにはFBIなどが冒頭の10
分ほどで、まとめて紹介されるものだから、冒頭はなにがなにやらわからなくなりそうで、さらにはマフィアのドン
過去の逸話などが、挿入される上に、50年代に50年代の車が走るばかりか、携帯電話のある現代においても古
い車が走るものだから、状況を把握するのすでめんどくさくなる。
それも古い古い博物館へでも行かないと見られそうもない大昔の車が走っている。
反対側車線は空も角、わたくたちが走行していた道路は数分前までそれほど車が走っていなかったのに、事

格フレーム検索

Google

http://reed.kuee.kyoto-u.ac.jp/cf-search/

格フレーム検索

名古屋検索ヘルプ

☒ 名詞から検索☐ CSV出力(名詞検索のみ)上位 20 個までの単語を表示, 頻度 2 以上の単語を表示

検索例: 「積む」, 「修行を 積む」, 「積むP」(受身), 「積むC」(使役)

「名古屋/なごや」を検索しました。

格フレームID	格	頻度
行う/おこなう?行く/く動1	二格	2011
住む/すむ動1	二格	1557
来る/くる動2	二格	1395
帰る/かえる動1	二格	1357
戻る/もどる動5	二格	829
行く/く動4	へ格	716
行う/おこなう?行く/く動5	へ格	674
着く/つく動1	二格	628
開催/かいさい動P1	テ格	621
居る/いる?射る/いる?誇る/いる動13	二格	555
代表/だいひょう動1	ヲ格	417
居る/いる?射る/いる?煎る/いる?誇る/いる?要る/いる動16	二格	406
戻る/もどる動11	へ格	376
住む/すむ+る/る動1	二格	337
到着/とうちゃく動1	二格	336
開催/かいさい動1	テ格	266

cf-search.csv - Microsoft Excel

A1	格フレームID									
1	格フレームID	頻度								
2	行く/おこなニ格	2011								
3	住む/すむニ格	1557								
4	来る/くるニ格	1395								
5	帰る/かえニ格	1357								
6	戻る/もどニ格	829								
7	行く/いくニ格	716								
8	行く/おこなニ格	674								
9	着く/つくニ格	628								
10	開催/かいニ格	621								
11	居る/いるニ格	555								
12	代表/だいニ格	417								
13	居る/いるニ格	406								
14	戻る/もどニ格	376								
15	住む/すむニ格	337								
16	到着/とうニ格	336								
17	開催/かいニ格	266								
18	出発/しゅニ格	254								
19	行く/いくニ格	239								
20	時間/じかニ格	226								
21	引越/こ越ニ格	212								
22	行く/おこなマデニ格	186								
23	出る/でるニ格	186								
24	居る/いるニ格	175								
25	着る/きるニ格	175								
26	時間/じかニ格	168								
27	出張/しゅニ格	163								
28	分/ぶんニ格	151								
29	働く/はたニ格	125								

<http://www.sketchengine.co.uk/>

LEX COM Sketch Engine

Lexical Computing

user: leejaeho

Help Change passwd WebBootCat CorpusBuilder Bug reporting News Logout

Corpora

Language	Name	Tokens [?]	
Chinese	Chinese GW, simpl	706 427 624	info
Chinese	Chinese GW, trd	706 428 333	info
English	British Academic Spoken English Corpus (BASE)	1 252 256	info
English	British Academic Written English Corpus (BAWE)	7 474 757	info
English	British National Corpus	111 244 375	info
English	ukWaC	2 035 621 120	info
French	French web corpus	126 850 281	info
German	deWaC	1 644 785 836	info
Greek	GkWaC	149 067 023	info
Italian	itWaC	1 909 535 984	info
Japanese	jpWaC	409 384 405	info
Persian	wbc-per	6 375 735	info
Portuguese	Cetenfolha, Cetempublico	66 319 147	info
Russian	Russian Web Corpus	187 965 822	info
Slovenian	Fida PLUS 620m	738 503 185	info
Spanish	Spanish web corpus	116 900 060	info

<< less corpora

レンマレベルで検索し、用法を確認

Home **Concordance** Word List Word Sketch Thesaurus Sketch-Diff

View options Sample Filter Sort Frequency Collocation Save

Page 1 of 2137 Go Next Last

Corpus: JpWaC
Hits: 42732
conc description

http://www.1101.com/morikawa/index_AKUAKU.html
http://www.12kai.com/200603.html
http://www.12kai.com/200603.html
http://www.12kai.com/200603.html
http://www.12kai.com/200603.html
http://www.12kai.com/200603.html
http://www.12kai.com/200603.html
http://www.12kai.com/200603.html
http://www.12kai.com/200603.html
http://www.1000mile.cocolog-nifty.com/keio/2005/12/index.html
http://www.1omotesando.com/column/d1/409.html
http://www.1omotesando.com/column/d1/409.html
http://www.1omotesando.com/column/d1/409.html
http://www.1omotesando.com/column/d1/409.html
http://www.1omotesando.com/column/d1/409.html
http://www.1101.com/torino2006/index.html
http://www.1101.com/torino2006/index.html
http://www.12kai.com/200502.html
http://www.12kai.com/200502.html

さんは森川さんの釣り友。歩く釣りバカを降りて、大手町駅まで歩いてたら、別れて、渋谷の歩道橋を歩きながらギョ本道で、向こうから人が歩いてくるとき歩いてくるとき、その人は歩くものに存在に見える。人が無事に歩いてきたと、あなたの知らない未来を歩いてきた。画面左、すぐ手前から人が歩いてきて、旅姿の女性が遠くから歩いてくる様子。ミーティアは、たぶん、道を歩きながら息を吐いてその間をそぞろ歩く。欧州のが多くて、多様な人種が歩いています、ここから3分表参道まで歩いてみるショッピング街でないで歩く人あんまり御所の石垣、端から端まで歩くとなかなかものそこに行きますと、歩いていてき)なんかこう、トボトボと歩いてました。リビ湖を歩いた結果どうにか歩きたは。途中で下りて1時間ほど歩いていたらあちこちのユッカの木を歩いていた

共起語を調べる。様々な共起指標を表示

Home Concordance Word List **Word Sketch** Thesaurus Sketch-Diff View

Save

Corpus: JpWaC
conc description

Collocation candidates

	Freq	T-score	MI	MI3	log likelihood	min_sensitivity	salience
p/n ウェストハイランドウェイ	15	3.873	13.226	21.040	275.029	0.000	36.670
p/n ほっつき	38	6.164	13.116	23.612	675.297	0.001	48.052
p/n イバラキ	19	4.358	12.899	21.385	323.810	0.000	38.611
p/n ヨチヨチ	60	7.745	12.793	24.607	1007.475	0.001	52.590
p/n よちよち	114	10.675	12.719	26.385	1893.603	0.003	60.350
p/n テクテク	100	9.998	12.521	25.809	1616.246	0.002	57.786
p/n 外股	3	1.732	12.489	15.659	48.275	0.000	17.313
p/n スズシ	3	1.732	12.489	15.659	48.275	0.000	17.313
p/n 彷徨い	15	3.872	12.432	20.246	239.606	0.000	34.470
p/n 葛城川	3	1.732	12.226	15.396	46.688	0.000	16.949
p/n ゆうぜんと	3	1.732	12.226	15.396	46.688	0.000	16.949
p/n トボトボ	42	6.479	12.159	22.943	648.306	0.001	45.731
p/n てくてく	129	11.355	12.144	26.167	1987.991	0.003	59.113
p/n さ迷い	21	4.582	12.095	20.879	321.628	0.000	37.385
p/n のっしのっし	10	3.162	12.088	18.732	153.038	0.000	28.987
p/n オアマル	7	2.645	12.033	17.648	100.417	0.000	25.022
p/n fj	3	1.732	12.003	15.173	45.445	0.000	16.640
p/n とぼとぼ	93	9.641	11.926	25.004	1396.040	0.002	54.182
p/n スタスタ	32	5.655	11.904	21.904	479.070	0.001	41.622

シソーラスとしての使う：(生起文脈に基づく)類義語を調べる

Home Concordance Word List Word Sketch Thesaurus Sketch-Diff

Save

歩く JpWaC freq = 42732

走る	0.448
乗る	0.361
行く	0.361
通る	0.357
帰る	0.356
見る	0.344
探す	0.332
飲む	0.332
立つ	0.33
読む	0.33
思う	0.329
出る	0.325
話す	0.321
入る	0.32
言う	0.32
食べる	0.319
来る	0.319
戻る	0.318
みる	0.318
進む	0.313

似たような名詞や構文パターンが見られた場合、類義語と判定

語彙の類似性・非類似性を調べる

Home Concordance Word List Word Sketch Thesaurus Sketch-Diff

Word Sketch Differences Entry Form

Corpus: JpWaC

First lemma: 歩く

Second lemma: 乗る

Sort grammatical relations: ☒

Separate blocks: ☐ all in one block ☒ common/exclusive blocks

Minimum frequency: 5

Maximum number of items in a grammatical relation of the common block: 25

Maximum number of items in a grammatical relation of the exclusive block: 12

Show Diff

歩く/乗る

preloaded/jpwac freq = 42732/37665

[change options](#)

Common patterns

歩く	6.0	4.0	2.0	0	-2.0	-4.0	-6.0	乗る
nounまで	1829	444	11.4	2.9				
駅	212	33	7.2	4.6				
ホテル	29	9	5.1	3.5				
どこ	26	18	3.4	2.9				
いつ	13	6	3.4	2.3				
そこ	21	7	2.6	1.0				
ここ	29	11	2.6	1.2				
今	30	34	2.2	2.4				
最後	12	7	2.3	1.6				
nounに	2867	26425	1.1	10.2				
一緒	372	193	7.9	6.4				
片手	43	7	7.9	3.0				
いっしょ	46	18	7.4	4.2				
久しぶり	38	54	6.4	5.5				
風	7	148	2.2	6.0				
久しぶり	7	8	5.9	3.3				
後ろ	5	73	3.2	5.8				
帰り	24	33	5.8	4.8				
方向	91	11	5.7	2.2				
久々	11	32	5.5	5.0				
為	36	11	5.4	2.8				
背	5	28	4.3	4.8				
とき	28	89	2.8	4.3				
絶対	7	24	3.5	4.2				
夜	22	11	4.1	2.5				
こっち	7	5	4.0	2.1				
前	49	117	2.8	3.9				
nounへ	900	256	7.3	2.1				
駅	23	5	4.1	1.9				
学校	7	6	1.6	1.4				
どこ	6	6	1.3	1.3				
そこ	7	6	1.0	0.8				

ある/いる

preloaded/jpwac freq = 2954750/3574782

[change options](#)

Common patterns

ある	6.0	4.0	2.0	0	-2.0	-4.0	-6.0	いる
nounが	763890	90712	12.7	0.5				
こと	69993	219	9.7	1.8				
もの	25686	506	9.3	4.6				
人	1276	19826	4.6	9.2				
性	20073	20	9.0	0.2				
ところ	9462	35	8.2	1.7				
の	12026	962	7.9	5.0				
子供	77	1350	1.5	7.9				
事	6630	23	7.9	1.5				
効果	5218	5	7.7	0.1				
興味	4975	11	7.7	1.5				
子	72	868	1.5	7.6				
機会	4571	9	7.5	1.1				
人間	143	1174	2.4	7.5				
感	4768	10	7.5	0.7				
奴	33	507	0.5	7.4				
友達	25	606	0.0	7.4				
部分	4371	15	7.4	1.3				
V_bound	54322	4345340	0.5	12.3				
する	8367	1048404	4.5	11.0				
れる	1562	418244	4.1	10.9				
書く	15116	38530	10.1	8.1				
なる	652	196557	2.8	9.8				
置く	3275	8007	9.3	5.9				
思う	90	99612	1.1	9.2				
られる	333	75023	3.8	8.9				
持つ	100	60775	2.7	8.7				
言う	323	58503	3.7	8.6				
考える	113	56541	2.5	8.5				
貼る	852	1141	8.5	3.1				
やる	134	45141	2.9	8.2				
見る	168	45040	2.9	8.2				
知る	63	38965	2.5	8.1				
行う	36	37671	1.2	8.0				
使う	188	35140	4.0	7.9				
くる	120	36376	2.1	7.8				
nounは	182575	37481	5.0	0.3				
の	11800	1732	8.5	5.9				
こと	21324	431	8.3	2.8				
これ	4531	373	7.9	4.6				
人	1257	7311	5.1	7.9				
理由	1339	32	7.5	3.4				
事	1859	49	7.4	2.9				
それ	3307	347	7.3	4.4				
もの	3392	547	7.2	4.9				
奴	17	203	1.5	7.2				
私	3178	1230	7.1	6.1				
問題	2145	43	7.1	1.9				
今日	1072	266	7.0	6.1				
方法	1075	8	7.0	1.0				
ところ	1555	40	6.9	2.2				
原因	682	10	6.7	2.2				
人間	201	460	4.5	6.6				
僕	413	313	5.7	6.5				

緑：「ある」の共起語
赤：「いる」の共起語

見る/見える

preloaded/jpwac freq = 404633/85244

[change options](#)

Common patterns

見る 6.0 4.0 2.0 0 -2.0 -4.0 -6.0 見える

nounが	27716	27534	1.5	8.1	nounから	25405	4197	6.3	5.8	modifier_Adv	28139	5215	5.1	5.3
姿	391	943	7.2	8.4	視点	920	6	9.3	2.9	よく	3057	298	10.9	8.4
傾向	464	64	8.2	5.3	窓	296	376	7.8	9.1	初めて	1440	32	10.2	6.0
顔	186	696	5.9	7.8	車窓	59	69	6.2	8.8	(は)っきり	145	557	6.6	9.4
兆し	37	178	5.3	7.6	視点	649	26	8.6	4.6	実際	685	18	9.1	5.1
星	8	177	2.6	7.1	遠く	265	54	8.1	7.4	どう	2378	163	9.1	5.5
景色	18	132	4.1	7.0	角度	268	16	8.0	5.4	まだ	771	153	9.0	7.6
海	38	201	4.4	6.8	外	681	284	7.9	7.1	あまり	638	83	8.8	6.8
変化	257	43	6.8	4.2	立場	587	15	7.9	3.1	(ほと)んど	578	154	8.8	8.0
光	10	183	2.6	6.8	隙間	24	50	4.8	7.7	ちょっと	662	74	8.6	6.2
先	7	392	0.9	6.7	傍	171	9	7.7	5.5	ずっと	431	15	8.5	5.0
動き	217	99	6.6	5.5	正面	165	12	7.5	5.4	もっと	410	17	8.4	5.0
光景	93	31	6.5	4.9	側	724	35	7.4	3.2	ちゃんと	413	85	8.4	7.3
様子	119	154	6.0	6.4	(は)た	129	5	7.3	5.1	全く	242	210	7.5	8.3
影	6	92	2.4	6.3	端	153	8	7.2	4.3	しっかり	409	48	8.2	6.1
現象	107	11	6.3	3.0	横	171	9	7.0	3.8	まったく	142	136	6.9	8.2
周り	13	119	3.1	6.3	他人	151	19	6.8	4.7	ふと	269	6	8.1	4.4
僕	246	11	6.3	1.8	ベランダ	19	18	4.5	6.6	いつも	306	18	8.0	5.3

歩く/乗る

preloaded/jpwac freq = 42732/37665

[change options](#)

Common patterns

歩く 6.0 4.0 2.0 0 -2.0 -4.0 -6.0 乗る

nounまで	1829	444	11.4	2.9	nounに	2867	26425	1.1	10.2	nounへ	900	256	7.3	2.1
駅	212	33	7.2	4.6	一緒	372	193	7.9	6.4	駅	23	5	4.1	1.9
ホテル	29	9	5.1	3.5	片手	43	7	7.9	3.0	学校	7	6	1.6	1.4
どこ	26	18	3.4	2.9	いっしょ	46	18	7.4	4.2	どこ	6	6	1.3	1.3
いつ	13	6	3.4	2.3	久しぶり	38	54	6.4	5.5	そこ	7	6	1.0	0.8
そこ	21	7	2.6	1.0	風	7	148	2.2	6.0					
ここ	29	11	2.6	1.2	久しぶり	7	8	5.9	3.3					
今	30	34	2.2	2.4	後ろ	5	73	3.2	5.8					
最後	12	7	2.3	1.6	帰り	24	33	5.8	4.8					
					方向	91	11	5.7	2.2					
					久々	11	32	5.5	5.0					
					為	36	11	5.4	2.8					
					背	5	28	4.3	4.8					
					とき	28	89	2.8	4.3					
					絶対	7	24	3.5	4.2					
					夜	22	11	4.1	2.5					
					こっち	7	5	4.0	2.1					
					前	49	117	2.8	3.9					

共起語をまとめる。格フレーム辞書同様

Home Concordance Word List **Word Sketch** Thesaurus Sketch-Diff

Save

歩く JpWaC freq = 42732 [change options](#)

nounまで 1829 11.4	nounへ 900 7.3	modifier Adv 4234 7.1	nounから 2226 5.1	bound V 16856 4.3
バス停 21 7.62	方角 7 6.7	ふらふら 172 10.15	駅 375 8.06	だす 173 6.93
駅 212 7.25	方面 31 6.59	ゆっくり 372 10.01	最寄り駅 7 6.43	始める 575 6.89
端 38 6.86	西 23 6.57	よちよち 105 9.63	端 29 6.42	出す 849 6.77
最寄り駅 5 6.18	東 18 6.03	てくてく 96 9.5	バス停 9 6.24	はじめる 112 6.44
停留所 5 6.07	北 23 5.93	ひたすら 111 9.25	九段下 5 6.14	つづなる 77 6.33
銀座 7 5.85	南 15 5.71	ブラブラ 75 9.06	向こう 32 6.07	ゆく 111 6.23
駅前 9 5.84	方向 56 5.07	しばらく 186 8.91	梅田 7 5.97	続ける 389 6.17
ぶん 6 5.83	奥 13 4.94	のんびり 96 8.84	終点 6 5.97	いく 1467 6.05
上野 6 5.79	右 10 4.8	ヨチヨチ 59 8.81	ホテル 52 5.95	にくい 120 6.02
渋谷 10 5.69	左 8 4.31	とぼとぼ 50 8.57	上野 7 5.86	行く 716 5.85
ビーチ 6 5.62	駅 23 4.07	まっすぐ 66 8.5	自宅 28 5.76	みる 817 5.81
鎌倉 5 5.59	こちら 15 3.5	少し 282 8.47	前方 7 5.58	いける 227 5.6
宿 11 5.55	ほう 33 3.43	早 56 8.46	そこ 9 5.58	あそぶ 923 5.59
隅々 5 5.36	方 137 3.17	そぞろ 40 8.25	池袋 5 5.57	いる 7645 5.36
新宿 7 5.16	村 5 2.47	ふらふら 41 8.18	広場 11 5.49	やすい 142 5.28
ホテル 29 5.13	先 10 1.74	再び 56 7.93	渋谷 9 5.45	回る 59 5.27

Wikipediaのコーパス化

yohasebe.com

ソフトウェア

以下は言語学研究のための自作プログラムです。プログラミング言語は主にRubyを用いています。いずれもオープンソースとして公開しますので、よろしければお使いください。質問・要望・バグ報告はこちらまでお願いします。

WP2TXT: Wikipedia to Text File

WP2TXTは、Wikipedia(日本語版)のデータベースダンプ(OML形式のbz2圧縮ファイル)をコーパス言語学研究で利用しやすいテキストファイルに変換するためのプログラムです。指定したサイズにファイルを分割したり、1行1センテンスの形式にするなどの機能があります。wxRubyを用いたGUIを備えています。

- 日本語ドキュメント
- ダウンロードサイト

Mcon: Morphological Concordancer

Mconは、テキスト形式の日本語コーパスから特定の形態的・文法的条件を満たすセンテンスのみを抽出してCSV形式で出力するプログラムです。内部での形態素解析にはMeCabを利用しています。GUIはwxRubyを利用しています。

- 日本語ドキュメント
- ダウンロードサイト

Search

Voichiro Hasebe

- プロフィール
- 研究業績
- 担当授業
- ソフトウェア
- 翻訳文書
- ものおき

Categories

- Cognitive Science (27)
- Corpus (23)
- Internet (54)
- Linguistics (84)
- Miscellaneous (99)
- Programming (40)
- Review (54)

Archives

- May 2008 (1)

書きことばコーパス

1. 書きことばコーパスの現状と位置づけ

- 新聞、小説など複数のジャンルのテキストあり
- 代表性の問題をクリアするのが難しい
- 利用には制限が多いため、要確認

2. 短所と長所

- 長所：書き手・出典が明確、表現の規範性が高い
 - 短所：手間・コスト高、データのバイアス強
- 複数のデータを比較評価しながら利用するのが望ましい

コーパスの紹介

1. 書き言葉（1）小説

	青空文庫	新潮文庫の100冊
内容	ネット上の電子図書館『青空文庫』の公開作品を一枚に収録	新潮文庫で絶版となった、入手不可能な100作品を収録
入手	『インターネット図書館 青空文庫』を購入するとDVD-ROM(¥1,500)	CD-ROMを購入 (¥2,600)
コーパス化	「青空文庫」変換スクリプトパッケージ (山口@国研)	エキスパンドブックテキスト化ツールをウェブでDL
その他	茶漣による青空文庫の検索	



<http://tell.fl.purdue.edu/chakoshi-wiki/>

『茶漣』日本語用例・コロケーション抽出システム(一般公開版)

[[プチ茶釜](#) | [マニュアル](#) | [wiki](#)]

コーパス指定: ☒

☐ 書空文庫(小説集)【[詳細](#)】

☐ 名大会話コーパス【[利用上の注意](#)】

検索パターン設定: ☒

スパン: 前 後 語

-3	語形:	☐	☐	☐
	品詞:	☐	☐	
-2	語形:	☐	☐	☐
	品詞:	☐	☐	
-1	語形:	☐	☐	☐
	品詞:	☐	☐	
kw	語形:	☐	☐	☐
	品詞:	☐	☐	
+	語形:	☐	☐	☐

コーパスの紹介

1. 書き言葉 (2) 新聞

	新聞記事データベース	日英新聞記事対応付けデータ	京都テキストコーパス
内容	毎日、朝日、読売新聞記事のデータ版	読売新聞と The Daily Yomiuri から自動作成された日英対応付けコーパス(NICT、内山氏)	毎日新聞1995年度版の記事と社説に各種言語情報を人手で付与したテキストコーパス (4万文)
入手	利用許諾契約後、研究目的での利用	ウェブから検索。フリーで利用可	ウェブよりダウンロード。フリーで利用可
コーパス化	テキストデータ	自分で加工する必要あり	毎日新聞データは別に購入し、対応づけが必要
その他	高価なため個人での購入は向かない		茶器で使用可能

http://mastarpj.nict.go.jp/~mutiyama/jea/index-ja.html

[English page](#)

日英新聞記事対応付けデータ (JENAAD)

—— 読売新聞と The Daily Yomiuri から自動作成された日英対応付けコーパス ——

文対応のサンプル

- ・ [一対一対応の日英文](#) (shift_jis-dos)
- ・ [一対多もしくは多対一対応の日英文](#) (shift_jis-dos)

覚書

日英新聞記事対応付けデータをダウンロードするには、覚書 ([日本語版](#) / [英語版](#)) で郵送して下さい。

〒619-0288 「けいはんな学研都市」 光台2-2-2
(独) 情報通信研究機構 知識創成コミュニケーション研究センター
言語翻訳グループ 内山 将夫

覚書が届き次第、アクセスのためのアカウントとパスワードをメールします。なお、アカウントは一定期間が経過したら削除しますので御注意下さい。

ダウンロード

- ・ [p11-1989-2001.txt.gz](#) (150000 一対一文対応, 23118450/バイト, euc-jp-unix)
- ・ [p11-1989-2001.zip](#) (150000 一対一文対応, 23335741/バイト, shift_jis-dos)
- ・ [pnm-1989-2001.txt.gz](#) (30000 一対多文対応, 7417253/バイト, euc-jp-unix)
- ・ [pnm-1989-2001.zip](#) (30000 一対多文対応, 7468055/バイト, shift_jis-dos)

pnm-1989-2001 * の [78対応](#) は、日英文のどちらかもしくは両方が欠けています。

- ・ [split.zip](#) (22919410/バイト) には以下のファイルがあります。
 - o p11-1989-2001-j.txt (日本語 150000行, 19751012/バイト, shift_jis-dos)
 - o p11-1989-2001-e.txt (日本語 150000行, 22522594/バイト, ascii-dos)
 - o pnm-1989-2001-j.txt (英語 29922行, 6458527/バイト, shift_jis-dos)

**利用に際しては覚書提出
規模：180万(文)対
日本語は約400万形態素**

<T ID="19930709J1TYEUB0400010/19930710E1TDY030000010/21" NM="1-1" SCORE="1.710796185">
<J>欧州は、エディンバラにおいて合意され、コペンハーゲンにおいて強化された成長イニシアチブを精力的に実行しつつある。</J>
<E>Europe is carrying out vigorously the Growth Initiative agreed in Edinburgh and strengthened in Copenhagen.</E>
</T>
<T ID="19930709J1TYEUB0400010/19930710E1TDY030000010/71" NM="1-1" SCORE="1.539716548">
<J>我々は、ロシアの経済発展にとって、改善された市場アクセスが重要であることを認識する。</J>
<E>We recognize the importance of improved market access for economic progress in Russia.</E>
</T>
<T ID="19920709J1TYMCD1300010/19920709E1TDY090000040/158" NM="1-1" SCORE="1.347403181">
<J>法人レベルでのパートナーシップ及びマネジメント支援は、特に効果的であり得る。</J>
<E>Partnerships and management assistance at corporate level can be particularly effective.</E>
</T>
<T ID="20000503J1TYMCA1200020/20000503E1TDY158000010/10" NM="1-1" SCORE="1.31897521">
<J>違憲の問題については、連邦憲法裁判所が決定する。</J>
<E>The Federal Constitutional Court decides on the question of unconstitutionality.</E>
</T>
<T ID="19920629J1TYMAA1400090/19920629E1TDY060000010/61" NM="1-1" SCORE="1.315772446">
<J>統合の実際のプロセスは、経済分野から始めなければならない。</J>
<E>The practical process of integration must begin in the economic sphere.</E>
</T>
<T ID="19930709J1TYEUB0400090/19930709E1TDY030000020/36" NM="1-1" SCORE="1.308626617">
<J>関連する安全保障理事会決議の諸条件が満たされるまで、制裁は維持されるべきである。</J>
<E>Sanctions should be upheld until the conditions in the relevant Security Council resolutions are met.</E>
</T>
<T ID="20010928J1TYMAC1400030/20010928E1TDY080000060/8" NM="1-1" SCORE="1.30335977">
<J>国際テロは、世界の平和と安全に対する重大な脅威だ。</J>
<E>International terrorism is a grave threat to world peace and security.</E>
</T>
<T ID="19920709J1TYMCD1300010/19920709E1TDY090000040/87" NM="1-1" SCORE="1.251160096">
<J>貧困、人口政策、教育、保健、女性の役割、及び児童の福祉は、特別の注意に値する。</J>
<E>Poverty, population policy, education, health, the role of women and the well-being of children merit special attention.</E>
</T>
<T ID="19930416J1TYMAD1400020/19930416E1TDY03A000020/33" NM="1-1" SCORE="1.21356667">
<J>国際市場に対するロシア産品のアクセス改善は、ロシアの構造改革を大いに強化する。</J>
<E>Improvement of access for Russian products to international markets strongly reinforces Russian structural reforms.</E>
</T>
<T ID="19931013J1TYEUB0400410/19931014E1TDY120000010/6" NM="1-1" SCORE="1.16174498">
<J>2 日本国政府及びロシア連邦政府は、市場経済への移行を目指すロシア連邦の努力に対する支援に当たって、戦後0
<E>2. The Government of Japan and the Government of the Russian Federation share the perception that Japan's support for the Russian Federation's transition to a market economy is essential.</E>
</T>
<T ID="19950709J1TYMAA1400040/19950709E1TDY050000010/43" NM="1-1" SCORE="1.126793067">
<J>また若い世代に自由の必要性を教えこまなければならない。</J>
<E>He must teach the younger generations the need for the freedom.</E>
</T>

<http://mastarpj.nict.go.jp/~mutiyama/align/index.html>

日英対訳文対応付けデータ

情報通信研究機構自然言語グループでは、[Project Gutenberg](#) や [青空文庫](#) や [プロジェクト杉田玄白](#) などの作品について、日本語と英語との対訳文対応を付けています。なお、これらの作品の一部には、明示的な許可がない場合の二次配布が禁止されているものがありますので御注意下さい([詳細](#))。

[AUTHORS.txt](#) / [README.txt](#) / [CONTRIBUTORS.html](#)

対訳文対応が付けられた作品のリスト

- [日本語タイトル順](#)
- [著者順](#)
- [訳者順](#)
- [ファイル名順](#)
- [英語タイトル順](#)

日本語：160ファイル, 117983行, 2388273形態素
英語：160ファイル, 117983行, 1406675単語

ダウンロード

- [データ一覧](#)
- [ダウンロード](#)

著作権について

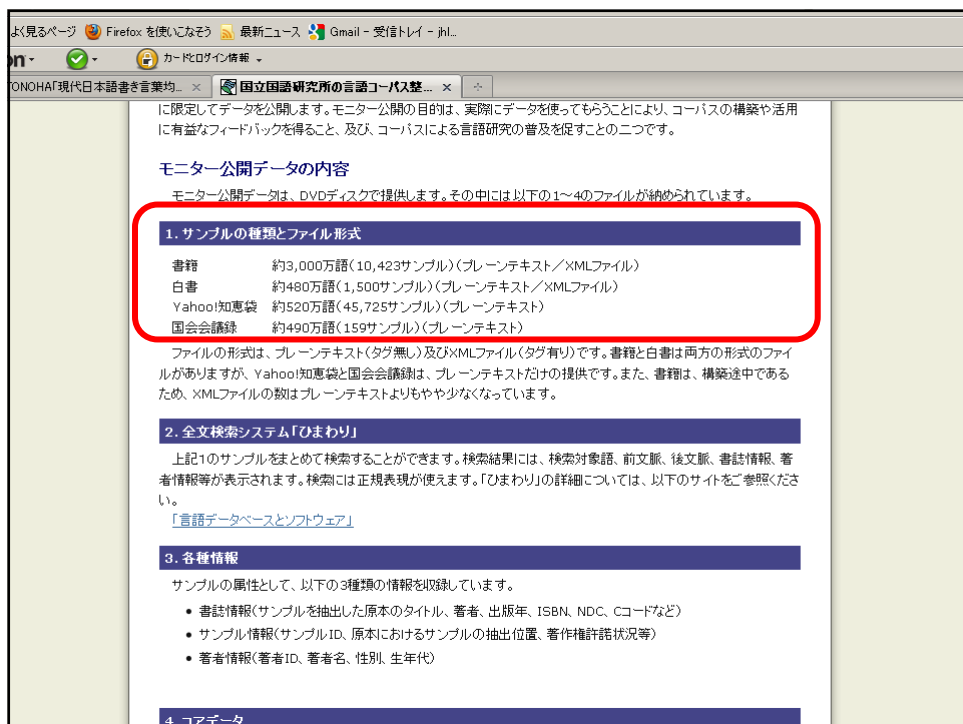
- オリジナルの各作品の著作権は、それぞれの作品の著作権に従います。
- その他のものについては [GNU Free Documentation License](#) あるいは [クリエイティブ・コモンズ・ライセンス](#)、[アトリビュション/ノンコマーシャル 1.0](#)、[\(著作権\)者表示-非営利目的利用](#) のどちらかに従い、それらの著作権は情報通信研究機構自然言語グループが保持します。なお、オリジナルの作品が二次配布を禁止している場合には、そこからの派生物(対訳データなど)も二次配布することを禁止します。また、オリジナルの作品が営利目的の利用を禁止している場合には、派生物の営利目的の利用も禁止します。
- データ配布についての我々の解釈: 対訳文対応を付けるときには、元データ(orgの中のファイル)に対して、内容に関りない部分での加工をする必要がある。それだけでなく、加工の際に誤りが生じる可能性もある。そのため、加工

コーパスの紹介

1. 書き言葉 (3) その他のデータベース

- テキスト検索専用のデータベース
 1. 国会会議録検索システム
 2. 判例検索システム
 3. 日本語書き言葉均衡コーパスモニター公開
(BCCWJ)

<http://www30.atwiki.jp/corpus-ling/>



コーパスの紹介

2. 話しことば

	日本語話し言葉コーパス	多言語話し言葉コーパス	日本語会話データベース
内容	国立国語研究所・情報通信研究機構・東京工業大学が共同開発した話し言葉データベース	日本語母語話者同士の会話と、日本語母語話者と日本語学習者の会話の文字化資料(CD-ROM)	日本語母国語話者と非母国語話者の発話パターンの比較分析と日本語教育向けの基礎資料となる言語データベース
入手	利用申込後、DVD18枚	利用申込書による申請。無料	ウェブからダウンロード
コーパス化	ツール付き	エクセル形式	*.raによる音声データとHTMLのテキストデータ

日本語会話データベース

<http://www.env.kitakyu-u.ac.jp/corpus/>

コーパス・サンプル


MENU



音声データ再生は左の画像アイコンをクリック

1: 牧野です。初めまして、どうぞよろしく。
2: 初めまして、吉原と申します。
1: 吉原さんですね。
2: はい、こんにちは。
1: えーと、まあ、全然、私は吉原さんのことを知らないんで、(2:(はい)まあ、最初に、簡単に、いー、略歴っていうか、えー、自分史っていうか、(2:(はい))簡単にちょっと1、2分でいいですから、話してみてください。
2: わかりました。えーと、私は、今22歳なんですけれども、えーと、長野市で生まれまして、えーと、両親の転勤が10回ほど、(1:ああ、ああ)あの、生まれてからあったもんですから、えーと、京都と東京、地方を行き来しまして、あと、(ほか)にも日本とアメリカの行き来も何度かありまして、えーと、引っ越しが

多言語話し言葉コーパス



多言語話し言葉コーパス

Microsoft Excel - 2_M03-M04.xls				
ファイル(F) 編集(E) 表示(V) 挿入(I) 書式(O) ツール(T) データ(D) ウィンドウ(W) ヘルプ(H) Adobe PDF(B) KH Coder(X)				
ファイル分割(N)				
F1				
A	B	C	D	E
ライン番号	発話文番号	発話文終了	話者	発話内容
1	1	*	M03	<2人で笑い>何なんだ、これは<2人で大笑い>。
2	2	*	M03	おれら暇人だよなく笑いながら>。[この間、M04は笑っている]
3	3	*	M03	こんな、勉強しなきゃいけないのに。[この間、M04は笑っている]
4	4	*	M04	おれ、レジュメ打たなきゃいけないのに<笑いながら>。
5	5	*	M03	くだんねー<2人で笑い>。[テーブルを叩きながら]
6	6	*	M04	くだんねー、って録音されてる>[<笑いながら>。
7	7	*	M03	<はい、はい>[、はい。[この間、M04は笑っている]
8	8	*	M03	失礼。[この間、M04は笑っている]
9	9	*	M03	でも、まあ、それなりになんかを話さなきゃいけないからー、フランクとはいえ、じゃ、
10	10	*	M04	「人名1」の話でもしてください。
11	11	*	M03	うん。
12	12	*	M03	そうのでもいいけど。
13	13	*	M04	そうのなー。
14	14	*	M04	「人名1」はね、これねー、「人名2」ちゃんから絶対口外すんなって言われたけど口外するよ<笑いながら><笑い>。
15	15	*	M03	それ、録音、録音されてんだけどさ<笑いながら><2人で笑い>。
16	16	*	M03	はい、何ですか<笑いながら>。
17	17	*	M04	なまて言ったはな

コーパスの紹介

3. 習得コーパス

	KYコーパス (第二言語としての日本語学習者の話し言葉)	日本語学習会話データ
内容	90人分のOPIテープを文字化した言語資料である	390名分のOPIデータ
入手	利用申込後、FDが返送。無料	ウェブページからダウンロード
コーパス化	プレーンテキストデータ	プレーンテキストデータ
その他		一部音声データもあり。

D:\corpus\WORK\Database\corpus\KYコリス\KY-corpus-original\韓国\KNH02.t

ファイル(F) 編集(E) 表示(V) 検索(S) ウィンドウ(W) マクロ(M) その他(O)

1 KNH02

T : こんにちは↓
S : こんにちは↓
T : わたくしはTです、えーとあなたは↓
S : わたくしは Sと申します↓
T : はじめまして、どちらからいらっしゃいます
S : 韓国から来ました↓
T : あーそうですか、韓国のどこですか↓
S : 韓国のデクです↓
T : あーそうですか、それは、あの韓国の北の
S : ああ、ちょっと、真ん中です、〈あーそう
く〉真ん中です↓
T : なるほど、そこは日本より寒いですが↓
S : ええ、だいたいぶつと 〈え〉 同じ↓
T : そこには、今、ご家族も住んでいらっしゃる
S : はい、そうですね、みんながデクに住んでいます
T : 日本にいらっしゃるのは、あなただけで
S : いいえ、妹と一緒に、妹と一緒にいらっし
↓
T : 妹さんも京都に住んでいらっしゃいますか
S : いいえ、わたしは、〈ええ〉 いっしょに大
T : ああ今も大阪に住んでいらっしゃいますか
S : はい↓
T : あーそうじゃあ京都までどのくらいかかりますか↓
S : 1時間30分ぐらいかかりました、〈ああそうですか〉 学校まで↓
T : あーそう、じゃあずいぶん朝の乗り物でいらっしゃるの混むでしょう↓
S : ええ↓
T : じゃあ、どういふうにして、学校までいらっしゃいますか↓
S : あのー、自転車、いえいえ、電車とか、〈え〉 電車で京都まで行って、あの一大宮駅
まで行って、〈え〉 バスで、学校まで行っています↓
T : あーそうですか、じゃああの、えーと京阪ですか阪急ですか↓
S : 阪急です↓

A1	B1	C1	D1	E1	F1	G1	H1	I1
1	こんにちは	コンニチ	こんにちわ	感動詞		O		
2	EOS							
3	わたし	ワタシ	わたし	名詞・代名詞一般		O		
4	は	ハ	は	助詞・係助詞		O		
5	S	エス	S	個人情報		O		
6	と	ト	と	助詞・格助詞一般		O		
7	申し	モウシ	申す	動詞・自立五段・サリ連用形		O		用・活動・言・語
8	ます	マス	ます	助動詞 特殊・マ基本形		O		
9	EOS							
10	韓国	カンコク	韓国	名詞・固有名称・地域・国		O		B-LOCATI(体・主体・公私固)
11	から	カラ	から	助詞・格助詞一般		O		
12	また	マイリ	また	助詞・自立五段・ラリ連用形		O		
13	まし	マシ	ます	助動詞 特殊・マ連用形		O		
14	た	タ	た	助動詞 特殊・タ基本形		O		
15	EOS							
16	韓国	カンコク	韓国	名詞・固有名称・地域・国		O		B-LOCATI(体・主体・公私固)
17	の	ノ	の	助詞・連体詞		O		
18	デク	テク	テク	名詞・固有名称・地域一般		O		
19	です	デス	です	助動詞 特殊・デ基本形		O		
20	EOS							
21	ああ	アア	ああ	感動詞		O		
22				ボーズ		O		
23	ちょっと	チョット	ちょっと	副詞・助詞類接続		O		
24				ボーズ		O		
25	真ん中	マンナカ	真ん中	名詞一般		O		体・関係・空間中
26	です	デス	です	助動詞 特殊・デ基本形		O		
27				ボーズ		O		

コマンド

ファイル(F)編集(E)表示(V)履歴(S)ブックマーク(B)ツール(T)ヘルプ(H)

http://dbms.kokken.go.jp/kaiwa/お礼

【楽天市場】価格.com - 賢者の買物...最新ニュースヤフオク・モノバケ・アマゾン...ジョルダン株式会社Gmail - 受信トレイ - jhl...Yahoo!メールYahoo! JAPAN

McAfee SiteAdvisor

検索 | 日本語学習者会話データ

日本語学習者会話データ

閉じる

検索

「mp3 (データ番号107, 169, 267)」は音声のサンプルデータです。
項目のうち、「日本語学習期間」と「日本語の能力試験」は参考データです。
「データ概要」を参照してください。
「CTRL」キーを押しながら項目をクリックすると、複数の項目での絞り込みができます。

OPIレベル	性別	年齢	出身国	母語
初級-下 初級-中 初級-上 中級-下	男 女	15(参考データ) 17(参考データ) 18 19	アイルランド アメリカ アメリカ? アメリカ(ハワイ)	韓国語 ロシア語 中国語(台湾語) 中国語

職業等	日本語在籍期間	日本語学習期間	日本語能力試験	
日本語学校生 大学・大学院生 専門学校生 会社員	～3ヶ月未満 ～6ヶ月未満 ～1年未満 ～2年未満	～3ヶ月未満 ～6ヶ月未満 ～1年未満 ～1年6ヶ月未満	1級 2級 3級 4級	検索 検索条件クリア

一覧

データ番号	OPIレベル	年齢	性別	出身国	母語	職業等	日本語在籍期間	日本語学習期間(参考)	日本語能力試験(参考)	TEXT
16	中級-中/中級-上/上級-下	22	女	韓国	韓国語	日本語学校生	1年	1年		表示DL
26	中級-下/中級-中	27	女	韓国	韓国語	日本語学校生	5ヶ月	18ヶ月		表示DL
31	上級-上	29	男	韓国	韓国語	フリーター	2年	2年	1級	表示DL

完了

http://dbms.kokken.go.jp/kaiwa/kaiwa/0016.txtお礼

【楽天市場】価格.com - 賢者の買物...最新ニュースヤフオク・モノバケ・アマゾン...ジョルダン株式会社Gmail - 受信トレイ - jhl...Yahoo!メールYahoo! JAPAN

McAfee SiteAdvisor

日本語学習者会話データhttp://dbms.kok...kaiwa/0016.txt

T : はい、こんにちは【姓A】です
I : こんにちは【姓B】と申します
T : はい、えー【姓B】さんは《はい》、お国はどちらですか
I : お国は韓国のプサンです
T : あ、プサンですか《えー、はい》、はい、えー日本に来てどれぐらいになりますか
I : あー3か月ぐらいになりました
T : 3か月、あ《はい》、まだ3か月ですか、そうですね
I : こん、あ、今回、が、あ、今回までが3か月ぐらいです、先生《ん》、ん《はい》、らい、あー、らいしゅ、あ、ん、去年12月、
T : で、まあちょうど3か月で《はい、はい》、で、あとどれぐらいいる予定ですか
I : まあ私が、あー、い、ワーキングホリデーのビザで来て《はい》、まあ1年間ぐらいはだいじぶですけど《えー》、このあとは
T : あ《あ》、つづ、続けてかよって《えー》、はい
I : かよったつもりですから《あ、そう》、ずっといる、いたいんですけど《えー》、でもビザが問題ですから
T : はい、えっと今ワーキングホリデーっておっしゃったんですけど《はい》、ワーキングホリデーって、ちょっとこう、教えてくれ
I : ワーキングホリデーは《はい》、意味は【笑】《んーんー》、英語ですけど《はい》、働き、働く、働きて《はい》、働くて《ん
T : いいですね《えー》、で
I : 日本語もあるけど《はい》、こう、ホジュとか
T : ん、ほじゅ
I : ホジュ、あー、***あ、アメリカの
T : ほじゅ《ホジュ》、ほじゅってなんですか
I : はーホジュは、どうしよう【笑】《んーんーんー》、ホジュはアメリカの、いる、国ですけど、今私が発音がちょっと、日本
T : はい、アメリカの、中の
I : 中のいる、ホジュが【ため息】《ふん》、動物の中で《ん》、このみたくの《はい》、このお腹の中で《はい》赤ちゃんを、フ
T : あー《【笑】こ、ここ*》、どこの国に多いですか《はい》、どこの国に多い
I : ホ、ホ、ホジュの国で《は》、多いの、有名な動物です《あー》、この国の有名な動物
T : あ、お腹に赤ちゃんが《ん》いて《いて》、それはカンガルーですね
I : あ、そう【手をたたく】、カンガルーの《はいはい》、同じ、同じですか【笑】【手をたたく】
T : はいはい、あ、カンガルーが
I : 有名な《な》、国です
T : あ、ホジュってのは国の名前ですね《えー、えー》、んー、となると《はい》、たぶん
完了

E-KWIC

[illegible]

コーパスの紹介

4. 特殊なコーパス

	戦時中のことば	女性のことば・職場編	男性のことば・職場編
内 容	戦時中の1936年から戦後の1955年の間に、日本放送協会からラジオで放送された78冊のラジオ台本を文字化し、Unicodeテキストファイル(タブ区切り)としたもの。	1993年9月～11月に首都圏で収録された音声資料を文字化したもの。対象は有識の20代から50代の女性。19名の協力者に職場でのインフォーマルな場面とフォーマルな場面での自然会話を録音している。	1999年10月～2000年12月に首都圏で収録された音声資料を文字化したもの。対象は有識の20代から50代の男性で、各世代5名で異なる職種・職場からなる19名の協力者に職場でのインフォーマルな場面とフォーマルな場面での自然会話を録音している。
入 手	書籍として購入(¥3,990)。テキストデータCD-ROMが付いてくる	書籍として購入(¥3,675)書籍にフロッピーディスク付。CVS(コンマ区切り)ファイルをLHAで、圧縮した資料を付属する。	書籍として購入(¥2,940)書籍にCD-ROM付。CVS(コンマ区切り) ファイルをLHAで、圧縮した資料を付属する。
規 模	約4万行の発話	約1万行の発話	約1万行の発話
コーパス化	整形化の必要あり	整形化の必要あり	整形化の必要あり

「戦時中のことば」のデータサンプル

レコード番号	台本番号	台本名	放送年月日	台本内レコード番号	発話	話者	話者性	話者年代	相手	相手性	相手年代	発話場所	関係
22	1	三四郎 (一)	1936.08.3	1	22 ハハハハ、然しこれからは、日本もだんだん発展するでしょう。	三四郎	男	20代	広田	男		汽車の中	乗客同士
23	1	三四郎 (一)	1936.08.3	2	23 きアアー 日露戦争に勝って、一等国になったからって字清天になっても開は、まず駄目でしょうな。	広田	男		三四郎	男	20代	汽車の中	乗客同士
24	1	三四郎 (一)	1936.08.3	3	24 貴方は随分悪い事を伺いますね。	三四郎	男	20代	広田	男		汽車の中	乗客同士
25	1	三四郎 (一)	1936.08.3	4	25 駄本でそんな事をいったら殺られてしまいます。	三四郎	男	20代	広田	男		汽車の中	乗客同士
26	1	三四郎 (一)	1936.08.3	5	26 ハハハ 駄本より東京は広い。	広田	男		三四郎	男	20代	汽車の中	乗客同士
27	1	三四郎 (一)	1936.08.3	6	27 東京より日本は広い。	広田	男		三四郎	男	20代	汽車の中	乗客同士
28	1	三四郎 (一)	1936.08.3	7	28 日本よりー。	広田	男		三四郎	男	20代	汽車の中	乗客同士
29	1	三四郎 (一)	1936.08.3	8	29 日本より隣の国の方が広いでしょう。	三四郎	男	20代	広田	男		汽車の中	乗客同士
30	1	三四郎 (一)	1936.08.3	9	30 囚われちゃ駄目だ。	広田	男		三四郎	男	20代	汽車の中	乗客同士
31	1	三四郎 (一)	1936.08.3	10	31 幾ら日本の為を思っても 島嶼の引越になるばかりだ。	広田	男		三四郎	男	20代	汽車の中	乗客同士
32	1	三四郎 (一)	1936.08.3	11	32 そりゃそうですけども、僕は駄本で育ちました。	三四郎	男	20代	広田	男		汽車の中	乗客同士
33	1	三四郎 (一)	1936.08.3	12	33 そうですか。	広田	男		三四郎	男	20代	汽車の中	乗客同士
34	1	三四郎 (一)	1936.08.3	13	34 ジャ日本の悪口はやめて、富士山の話に切りましょう。	広田	男		三四郎	男	20代	汽車の中	乗客同士
35	1	三四郎 (一)	1936.08.3	14	35 あなたは富士山を眺めてみた事がありますか。	広田	男		三四郎	男	20代	汽車の中	乗客同士
36	1	三四郎 (一)	1936.08.3	15	36 戦時中という	三四郎	男	20代	広田	男		汽車の中	乗客同士

「職場のことば」のデータサンプル

通番	発話	協力者コード	場面1	場面2	発話者コード	性別	年齢
1	1 はい、お電話代わりました。	協力者01	1993年10月 朝	電話 室内	01A	女	28
2	2 はい、お電話になっております。	協力者01	1993年10月 朝	電話 室内	01A	女	28
3	3 はい。	協力者01	1993年10月 朝	電話 室内	01A	女	28
4	4 はい。	協力者01	1993年10月 朝	電話 室内	01A	女	28
5	5 はい、お待ちしております。	協力者01	1993年10月 朝	電話 室内	01A	女	28
6	6 はい。	協力者01	1993年10月 朝	電話 室内	01A	女	28
7	7 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
8	8 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
9	9 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
10	10 はい。	協力者01	1993年10月 朝	電話 室内	01A	女	28
11	11 はい。	協力者01	1993年10月 朝	電話 室内	01A	女	28
12	12 わかりました。	協力者01	1993年10月 朝	電話 室内	01A	女	28
13	13 じゃ、これーお受けします。	協力者01	1993年10月 朝	電話 室内	01A	女	28
14	14 でですね、しめ、連絡切りの件なんですけれども、これ、あの、[名字]とど	協力者01	1993年10月 朝	電話 室内	01A	女	28
15	15 < 笑い > あ、そうですか。	協力者01	1993年10月 朝	電話 室内	01A	女	28
16	16 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
17	17 ええ、あの、特にー、あの、まだ聞いてませんので。	協力者01	1993年10月 朝	電話 室内	01A	女	28
18	18 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
19	19 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
20	20 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
21	21 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
22	22 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
23	23 じゃ、あのー、これで断切りということにしましょうか。	協力者01	1993年10月 朝	電話 室内	01A	女	28
24	24 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
25	25 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
26	26 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
27	27 あー、なるほど。	協力者01	1993年10月 朝	電話 室内	01A	女	28
28	28 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
29	29 ええ。	協力者01	1993年10月 朝	電話 室内	01A	女	28
30	30 じゃあ、あの、そちらのほうは断ったばかりか、ということなんです、あのー	協力者01	1993年10月 朝	電話 室内	01A	女	28

コーパスの紹介

5. 辞書・シソーラス

区分	日本語語彙大系	日本語動詞の結合価	分類語彙表
内容と規模	30万語の収録語は3000種の意味分類を用いて定義されている、大規模の日本語シソーラス。3000種の意味分類を用いて日本語の文型を定義している。	15万文規模の日本語文集合をもとに、「動詞がとりうる格と、その格を担う体言」について整備した、大規模な言語データ集。	延べ約9万6千語の日本語の単語を意味的に分類したもの
入手	有料（無料化予定あり）	有料	有料
検索ソフト	パッケージとして同梱	パッケージとして同梱	ない(PDFの索引のみ)
元の電子データを直接閲覧	基本的には不可能	基本的には不可能	可能(PDFファイル)
製作元	日本電信電話株式会社 NTTコミュニケーション科学基礎研究所	日本システムアプリケーション 荻野孝野・小林正博・井佐原均 編著	国立国語研究所

日本語動詞の結合価

• GUI

結合価データ検索システム

検索指示

●用言を指定しての検索

走る 検索

出力候補リスト

走る[イシル](100d8a:走る)
 走る[イシル](103ac1:ものが速く進む)
 走る[イシル](103ac4:速く流れる)
 走る[イシル](103ac7:表情や心の中に、怒りや悲しみ
 走る[イシル](103ac8:急にこある傾向を強くもつ)
 走る[イシル](1f117c:急いで行く)
 走る[イシル](3d040b:川や道などがある方向に通じ
 走る[イシル](3d0714:人や動物が走ること)

●体言を指定しての検索

検索



表示指定

前ページ 次ページ

環境

結合価データファイル: D:\corpus\WORK\Data ...

1画面の表示文数: 100 例文



研究紹介

1. 李 在鎬・井佐原 均 (2006) 「第二言語獲得における助詞「に」の習得過程の定量的分析」、『計量国語学』第二十五巻四号、pp.163-180.
2. 李 在鎬・鈴木 幸平・永田 由香・黒田 航・井佐原 均(2007) 「動詞「流れる」の語形と意味の問題をめぐって」『計量国語学』第26巻2号, pp.64-74
3. 李 在鎬(2008) 「移動動詞に対する実験的分析」, 『言葉と認知のメカニズム』 pp.87-101, ひつじ書房.
4. 黒田 航・李 在鎬 (2008) 「WWWを丸ごとデータにすると何がわかるか」、『日本語学(2008年2月号)』 27-2:pp. 22-37, 明治書院
5. 李 在鎬(2009) 「助数詞と多変量解析」, 『日本語学(2009年6月号)』 28-7:pp.44-57, 明治書院.
6. 李 在鎬(2009) 「タグ付き日本語学習者コーパスの開発」 『計量国語学』 27-2, pp.60-72.

<http://www30.atwiki.jp/corpus-ling/pages/52.html>