

**語彙的連鎖計算プログラム Lexical Chainers**  
**version 1.50.2 マニュアル**

望月 源  
2002年1月10日  
IS-TM-2002-001

北陸先端科学技術大学院大学情報科学研究科  
Copyright © 2001,2002  
Hajime Mochizuki

# 目次

はじめに	1
1 Lexical Chainers のインストール	2
1.1 配布プログラムと動作環境 . . . . .	2
1.2 インストール . . . . .	3
2 Lexical Chainers の使用方法	5
2.1 chainer_th の使い方 . . . . .	5
2.2 chainer_thcha の使い方 . . . . .	7
2.3 chainer_co の使い方 . . . . .	8
2.4 chainer_cocha の使い方 . . . . .	10
3 シソーラスデータ作成方法	11
3.1 分類語彙表を使用する場合 . . . . .	11
3.2 他のシソーラスを使用する場合 . . . . .	11
4 形態素フィルタルール記述ファイル	12
4.1 形態素フィルタルール記述ファイルとは . . . . .	12
4.2 形態素フィルタルールの説明 . . . . .	12
おわりに	15

# はじめに

本稿は、語彙的連鎖計算プログラム Lexical Chainers version 1.50.2 のインストール方法および使用方法を説明したマニュアルです。

語彙的連鎖 (lexical chain) とは、文書中で語彙的結束性 (lexical cohesion) を持つ語の連続のことを言います。語彙的結束性とは、文と文の表層的な関係による結びつきである結束性 (cohesion)[1][2] の 1 つであり、文書中に出現する語と語の間にある結束性を指します。他の結束性である代名詞、省略などと異なり、関連する 2 つの語が両方とも文書中に存在することから、計算機による計算が比較的容易であるという特徴があります。

Lexical Chainers は、この語彙的結束性を持つ語の連続である語彙的連鎖を自動的に計算します。ただし、ある語とある語の間に語彙的結束性が存在するかどうかを決定するためには、ある基準が必要であり、その基準は 1 つとは限りません。そのため Lexical Chainers は、代表的な基準として、「同一の語の繰り返し」、「シソーラス」、「単語の共起関係」の 3 つを選んで用いることができる複数のプログラムのパッケージとしました<sup>1</sup>。

いずれにしても、文書中には複数の語彙的連鎖が存在し、それぞれの連鎖はある 1 つの話題に関連する語の連続であると捉えることができます。そのため、計算された語彙的連鎖は、その文書の文脈情報として用いることが可能です。なお、使用する基準の違いやパラメータの値を変化させることにより、同じ文書から実際に計算される語彙的連鎖は変化します。そのため、ユーザはその違いを充分考慮して本プログラムを使用して頂きますようお願いします。Lexical Chainers によって計算された、語彙的連鎖の情報を様々な自然言語処理の応用システム等で利用して頂ければ幸いです。

なお、本マニュアルでは語彙的結束性に基づく語彙的連鎖の説明とその計算方法については扱いませんので、他の文献 [8] を参照して下さい。

本システムに関する問い合わせ先

〒 923-1292 石川県能美郡辰口町旭台 1-1

北陸先端科学技術大学院大学 情報科学研究科

望月 源

E-mail: motizuki@jaist.ac.jp

WWW: <http://galaga.jaist.ac.jp:8000/~motizuki/software/chainers/>

---

<sup>1</sup>パッケージ名が Lexical Chainers と複数形になっているのは、この理由によります。

# 1 Lexical Chainers のインストール

ここでは、Lexical Chainers バージョン 1.50.2 のインストール方法を説明する。

## 1.1 配布プログラムと動作環境

### • 動作環境

Lexical Chainers は、UNIX 系 OS 上で動作する。

Lexical Chainers には、4種類の語彙的連鎖計算プログラムが含まれており、語彙的連鎖を計算する基準の違いで、大きく次の2つに分かれる。

- 同一の語の繰り返し、またはシソーラスに基づくプログラム：  
chainer\_th, chainer\_thcha
- 語の共起関係に基づくプログラム：  
chainer\_co, chainer\_cocha

また、それぞれの基準で、プログラムに、ChaSen のライブラリを組込むものと、組込まないものがある。chainer\_thcha, chainer\_cocha が、ライブラリを組込むものである。

プログラム名との対応を表 1. にまとめて示すので各自の目的に合わせてプログラムを選択して欲しい。

表 1: 使用条件とプログラム名の対応表

語彙的連鎖構成基準	形態素解析器	プログラム名	必要なもの
同語の繰り返し シソーラス	juman3.61(*1) ChaSen2.2.x(*2) その他 (*4)	chainer_th	シソーラス (*3)
語の共起	上と同じ	chainer_co	GETA(*5)
同語の繰り返し シソーラス	ChaSen2.2.x	chainer_thcha	ChaSen2.2x シソーラス
語の共起	上と同じ	chainer_cocha	ChaSen2.2x GETA

上記各プログラムの動作に必要な他のアプリケーション等は以下のようになる。

(\*1) juman3.61

JUMAN[6] は、京都大学言語メディア研究室で作成、配布されている。  
(<http://www-nagao.kuee.kyoto-u.ac.jp/nl-resource/juman.html>)

(\*2) ChaSen 2.2.x

ChaSen 「茶筌」 [9] は奈良先端科学技術大学院大学、松本研究室で作成、配布されている。 (<http://chASEN.aist-nara.ac.jp/index.html.ja>)

(\*3) シソーラス

現在のところ、国立国語研究所の分類語彙表の索引を使うのが一番簡単な方法である。なお、後述する指定形式にあわせてファイルを用意することで、別のシソーラスも利用可能である。(詳しくは3節を参照せよ)

(\*4) その他

形態素解析結果の形式を ChaSen や JUMAN と同様にし、フィルタを用意することによって、JUMAN,ChaSen 以外の形態素解析器の処理結果も利用可能である。

(\*5) GETA

GETA は、(株) 日立製作所中央研究所において開発されている、汎用連想検索エンジンである。そのため別途取得、インストールする必要がある。GETA の入手等については、(株) 日立製作所中央研究所の丹羽さん ([yniwa@harl.hitachi.co.jp](mailto:yniwa@harl.hitachi.co.jp)) に直接コンタクトされたし(2002年1月10日現在)。

- 配布プログラムの取得
  - 以下の配布元より Lexical Chainers version 1.50.2 をダウンロードする。  
<http://galaga.jaist.ac.jp:8000/~motizuki/software/chainers/>

## 1.2 インストール

### 1. 準備

- 語の共起に基づく語彙的連鎖を作成したい場合 (chainer\_co または chainer\_cocha) は、GETA をインストールする。
- ChaSen ライブライアリを取り込んだ語彙的連鎖プログラムを使う場合は ChaSen をインストールする。

### 2. インストール先の決定

Lexical Chainers をインストールするディレクトリを決める。以下、\$MOTSROOT と表記する。また、プログラムソースがあるディレクトリを\$MOTSSRC とする。

### 3. \$MOTSSRC/conf/conf を希望に合わせ編集する。

- MOTSROOT

Lexical Chainers のインストール先のディレクトリをフルパスで指定する。指定しなければ、/usr/local がデフォルトとして選択される。(全プログラム共通で使用)

- GETAROOT  
GETA の存在するディレクトリを指定する. GETA を使う場合のみ指定すること. (chainer\_co, chainer\_cocha で使用)
- CHAINC  
chasen.h のある場所を指定する. ChaSen のライブラリを使う場合のみ指定すること.
- CHALIB  
chasen のライブラリ libchasen.a のある場所を指定する. ChaSen のライブラリを使う場合のみ指定すること. (chainer\_thcha, chainer\_cocha で使用)

4. \$MOTSSRC で, configure を--enable-conffile 付きで実行する.

```
% ./configure --enable-conffile
```

なお, conf file を使用しないで, 直接 --prefix を指定することも可能である. その場合, conf 内の各変数を必要に応じて, 環境変数としてセットしてから, 以下を実行すること.

```
% ./configure --prefix=$MOTSROOT
```

5. make を実行する

```
% make
```

chainer\_th, chainer\_thcha, chainer\_co, chainer\_cocha の内, chainer\_th は必ず作成される. 後のものは conf/conf で希望したものだけが作成される.

6. make install を実行する

```
% make install
```

これにより, \$MOTSROOT/bin にプログラムがインストールされる.

以上で, インストール終了.

## 2 Lexical Chainers の使用方法

ここでは、Lexical Chainers の使用方法をプログラム別に説明する。

### 2.1 chainer\_th の使い方

#### 1. シソーラスの準備

このプログラムは、シソーラスデータがないと動かないので作成する。分類語彙表などのシソーラスがない場合は、とりあえず dummy を使ってデータを作成する。

```
% cd $MOTSROOT/data  
% $MOTSROOT/sbin/mkidx.sh dummy dummy
```

正式なシソーラスデータの作成方法は、3節「シソーラスデータ作成方法」を参照せよ。

#### 2. 使用方法

プログラムは以下のように使用する。

```
% ./chainer_th [options] < 形態素解析結果ファイル  
(例: chasen -e TEXTFILE | ./chainer_th [options])  
(例: juman -e TEXTFILE | ./chainer_th -jum [options])
```

オプションの説明：

- 入力タイプ

使用する形態素解析器の出力形式に対応するタイプを指定する。使用できる形式は、-knp, -cha, -jum のどれかであり、デフォルトは -cha である。

**-knp** : KNP[5] の -tab 形式出力を使用

**-cha** : ChaSen 2.2.x の -e 形式出力を使用 (default)

**-jum** : Juman3.61 の -e 形式出力を使用

- フィルタールール記述ファイルの指定

**-rule <filename>** :

使用する形態素解析器の出力形式に対応した除外単語リストなどを記述したファイルをフルパスで指定する。

指定がない時は、上の「入力タイプ」と連動して、

デフォルト (-cha) では\$MOTSROOT/rule/mrule0 を読み込む。

-knp, -jum の時は、\$MOTSROOT/rule/mrule1 を読み込む。

- 連鎖を作る候補語に関するオプション

**-F <0-6>** : デフォルト値=0

連鎖を作る候補語となる品詞を指定する。組み合わせは以下のとおり

- 0. 名詞 動詞 形容詞
- 1. 名詞 — 形容詞
- 2. 名詞 — —
- 3. 名詞 動詞 —
- 4. — 動詞 —
- 5. — 動詞 形容詞
- 6. — — 形容詞

- 概念階層のレベル設定

階層は使用するシソーラスに依存し、最大5階層まで扱うことができる<sup>2</sup>。

**-i <0-5>** : デフォルト値=2

シソーラスの概念階層の何レベルまで使用するかを指定する。

0の場合は、シソーラスを使用しないで、同じ語の繰り返しのみになる。

**-j <0-5>** : デフォルト値=0

シソーラスの概念階層の何レベルを使用するか指定する。

(-iとは異なり、指定したレベルのみを使う)。

0の場合は、このオプションを無効にする。

- シソーラスの設定に関するオプション

**-D <index>** :

使用的するシソーラスを指定する。

ただし事前に\$MOTSROOT/data/の下に、シソーラスを加工したファイルを作成しておく必要がある。詳しくは、3節「シソーラスデータ作成方法」を参照せよ。

- 出力に関するオプション

**-t <INT>** : デフォルト値=1

何語以上連なったら有効な語彙的連鎖として出力するかを指定する。

**-1** : 多義性が完全に解消できない場合に、最初の1語義だけを表示する。

**-V** : 処理中にメッセージを出す。

**-W** : 連鎖の候補となる単語以外も単語数にカウントする。

**-h** : help を表示する。

### 3. 出力形式

出力の1行目は、{ 総文数 総候補語数 総形態素数 }を表わす。

2行目以降は、1レコードが1単語の情報を表し、複数レコードによって1種類の語彙的連鎖を表わしている。1つの語彙的連鎖は空行の次のレコードから空行までである。1レコードの形式は以下のようになる。

---

<sup>2</sup>プログラムは5階層に対応しているが、シソーラスデータ作成プログラムが4階層までしか対応していないため、現在は実質4階層までしか扱えない

- 同じ語の繰り返しに基づく場合 (-i 0 で chainer\_th を使用)
 

{ 文番号 語番号 通し番号 見出し語 見出し語 付属する助詞 助詞 }

例 :

5 9 63 要求 要求 kaku を  
 19 11 249 要求 要求 kaku が  
 (空行)
- シソーラスに基づく場合
 

{ 文番号 語番号 通し番号 概念番号 見出し語 付属する助詞 助詞 }

例 :

3 7 45 165 難しい yougen no  
 19 13 251 165 困難 yougen no  
 (空行)

「通し番号」は -W オプションの有無に依存する.

- W なし : 文書の先頭から現在までに出現した候補語の通し番号を表す.  
 -W 付き : 文書の先頭から現在までに出現した形態素の通し番号を表す.

「付属する助詞の分類」は、その単語が名詞である場合は直後の助詞の種類を示し、動詞か形容詞である場合には yougen(用言) と記述されている.

助詞の分類と意味の対応は、\$MOTSROOT/rule/mrule0 や mrule1 あるいは自分で指定したフィルタルール記述ファイルの助詞の項目に記述されているとおりに出力される<sup>3</sup>.

## 2.2 chainer\_thcha の使い方

### 1. シソーラスの準備

このプログラムは、シソーラスデータがないと動かないので作成する. 分類語彙表などのシソーラスがない場合は、とりあえず dummy を使ってデータを作成する.

```
% cd $MOTSROOT/data
% $MOTSROOT/sbin/mkidx.sh dummy dummy
```

正式なシソーラスデータの作成方法は、3節「シソーラスデータ作成方法」を参照せよ.

### 2. 使用方法

プログラムは以下のように使用する.

---

<sup>3</sup>形態素解析器により助詞の分類が異なるので、統一することはせず、フィルタルール記述ファイルを設けて対応することにした.

```
% ./chainer_thcha [options] < TEXTFILE
```

オプションの説明：

- 入力タイプ  
ChaSen ライブラリを使用するので、入力タイプは -cha のみになる。
  - それ以外のオプションは、 chainer\_th と同じ。
3. 出力フォーマット  
出力フォーマットは、 chainer\_th と同じ。

### 2.3 chainer\_co の使い方

#### 1. 使用方法

プログラムは以下のように使用する。

```
% ./chainer_co handle [options] < 形態素解析結果のファイル
```

(例: chasen -e TEXTFILE | ./chainer\_co mai94)

(例: juman -e TEXTFILE | ./chainer\_co mai94 -jum )

ここで handle とは、 GETA の handle を意味する。

オプションの説明：

- 入力タイプ  
使用する形態素解析器の出力形式に対応するタイプを指定する。使用できる形式は、 -knp, -cha, -jum のどれかであり、 デフォルトは -cha である。
  - knp : KNP の -tab 形式出力を使用
  - cha : ChaSen 2.2.x の -e 形式出力を使用 (default)
  - jum : Juman3.61 の -e 形式出力を使用
- フィルタルール記述ファイルの指定
  - rule <filename> :  
使用する形態素解析器の出力形式に対応した除外単語リストなどを記述したファイルをフルパスで指定する。  
指定がない時は、上の「入力タイプ」と連動して、  
デフォルト (-cha) では\$MOTSROOT/rule/mrule0 を読み込む。  
-knp, -jum の時は、 \$MOTSROOT/rule/mrule1 を読み込む。
- 連鎖を作る候補語に関するオプション

**-F <0-6>** : デフォルト値=0

連鎖を作る候補語となる品詞を指定する. 組み合せは以下のとおり

- 0. 名詞 動詞 形容詞
- 1. 名詞 — 形容詞
- 2. 名詞 — —
- 3. 名詞 動詞 —
- 4. — 動詞 —
- 5. — 動詞 形容詞
- 6. — — 形容詞

- 共起計算に関するオプション

**-handle <str>** :

GETA で使用するコーパスの handle name を指定する.

**-calc\_mode <num>** :

共起スコアの計算式を指定する.

1. TF.IDF :  $df(x, y) \times \log(N/(df(x) \times df(y)))$

2. 相互情報量 :  $df(x, y) \times N/(df(x) \times df(y))$

10. コサイン距離 :  $\sum(xi \times yi) / \sqrt{x_i^2} \times \sqrt{y_i^2}$

**-threshold <num>** :

クラスタ (連鎖) 作成時の共起スコアの閾値を指定する.

**-N <INT>** :

共起スコア計算に使用するコーパスの総文書数.

- 出力に関するオプション

**-compth** : chainer\_th と compatible な出力にする.

**-W** : 連鎖の候補となる単語以外も単語数にカウントする.

**-h** : help を表示する.

## 2. 出力形式

-compth オプション付きで実行した場合は, chainer\_th と同じ.

それ以外の場合は次のようにになる.

出力の 1 行目はテキストの, { 総文数 総候補語数 総形態素数 } を表わす.

2 行目以降は, 1 レコードが 1 単語の情報を表し, 複数レコードによって 1 種類の語彙的連鎖を表わしている. 1 つの語彙的連鎖は空行の次のレコードから空行までである.

1 レコードの形式は以下のようになる.

{ 文番号 語番号 通し番号 見出し語 付属する助詞の分類 助詞 }

例 :

1 10 10 携帯 no no

1 12 12 電話 no no  
(空行)

- 「通し番号」は -W オプションの有無に依存する。  
-W なし：文書の先頭から現在までに出現した候補語の通し番号を表す。  
-W 付き：文書の先頭から現在までに出現した形態素の通し番号を表す。

「付属する助詞の分類」は、その単語が名詞である場合は直後の助詞の種類を示し、動詞か形容詞である場合には yougen(用言) と記述されている。

助詞の分類と意味の対応は、\$MOTSROOT/rule/mrule0 や mrule1 あるいは自分で指定したフィルタルール記述ファイルの助詞の項目に記述されているとおりに出力される<sup>4</sup>。

## 2.4 chainer\_cocha の使い方

### 1. 使用方法

プログラムは以下のように使用する。

```
% ./chainer_cocha handle [options] < TEXTFILE
```

ここで handle とは、GETA の handle を意味する。

オプションの説明：

ChaSen ライブラリを使用するので、入力タイプは-cha のみになる。  
それ以外のオプションは、chainer\_co と同じ。

### 2. 出力形式

-compat オプション付きで実行した場合は、chainer\_th と同じ。  
そうでなければ、chainer\_co と同じ。

---

<sup>4</sup>形態素解析器により助詞の分類が異なるので、統一することはせず、フィルタルール記述ファイルを設けて対応することにした。

### 3 シソーラスデータ作成方法

ここでは、chainer\_th と chainer\_thcha で参照するシソーラスデータの作り方を説明する。なお、\$MOTSROOT は、Lexical Chainers をインストールしたルートディレクトリを意味する。また、シソーラスのための作業ディレクトリは \$MOTSROOT/data である。

#### 3.1 分類語彙表を使用する場合

分類語彙表の場合は、索引データである ‘sakuin’ ファイルを用いる。なお、sakuin が \$BGH にあるものとして説明する。

1. 作業ディレクトリに移動する。

```
% cd $MOTSROOT/data
```

2. nkfなどを用いて分類語彙表の索引 (sakuin) を EUC に変換する。

```
% nkf -s -e < $BGH/sakuin > sakuin.euc
```

3. シソーラスデータを作成する。

シソーラスデータは、スクリプト \$MOTSROOT/sbin/mkidx.sh を使って作成する。

```
% $MOTSROOT/sbin/mkidx.sh bgh sakuin.euc
```

4. データの確認をする

ここまで作業により、\$MOTSROOT/data には、bgh.dat, bgh.wan, bgh.idx の 3 つのファイルが作成される。

これにより、chainer\_th, chainer\_thcha にオプションとして -D bgh を付けることで、分類語彙表がシソーラスデータとして使用できるようになる。

#### 3.2 他のシソーラスを使用する場合

基本的に、分類語彙表の索引データと同様のフォーマットになるように使用するシソーラスを加工することで、利用できるようになる。

1. ファイルの準備

以下のフォーマットでファイルを作成する。文字コードは EUC で作成すること。

見出し語, よみ, ID1, ID2, ID3, ID4

例： dummy ファイルの中身

だ, だ, 0.0000, 0, 0, 0

み, み, 0.1000, 0, 0, 0

い, い, 0.2000, 0, 0, 0

```
ファ, フア,0.1000,0,0,0  
イ, イ,0.0000,0,0,0  
ル, ル,0.0000,0,0,0
```

2. 上記のファイルからシソーラスデータを作成する.

```
% $MOTSROOT/sbin/mkidx.sh sample dummy
```

3. データの確認をする.

ここまで の作業により, \$MOTSROOT/data には, sample.dat sample.wan sample.idx が作成される.

これにより, chainer\_th, chainer\_thcha にオプションとして -D sample を付けることでこのファイル(シソーラス)が利用できるようになる.

## 4 形態素フィルタールール記述ファイル

ここでは、フィルタールール記述ファイルとその記述方法について説明する.

### 4.1 形態素フィルタールール記述ファイルとは

「形態素フィルタールール記述ファイル」とは, \$MOTSROOT/rules/mrule\* ファイルのことであり、以下の働きをする.

- 語彙的連鎖を作成する際に、形態素解析結果の中で有効な単語を決定する。(除外する単語の指定)
- 助詞の分類とその意味の対応を決める.

Lexical Chainers のデフォルトとして用意してあるフィルタールール記述ファイルは、以下の 2 つである.

- ChaSen 2.2.x 用 : \$MOTSROOT/rules/mrule0
- juman3.61, knp 用 : \$MOTSROOT/rules/mrule1

Lexical Chainers では、-rule オプションにより、ユーザ独自の形態素フィルタールール記述ファイルをプログラムに渡すことができるので、フィルタを自作することも可能である.

### 4.2 形態素フィルタールールの説明

例として、ChaSen 2.2.x 用のフィルタである\$MOTSROOT/rules/mrule0 をあげ説明する(図 1).

```

# action\t filed1\t 表記 1(\t filed2\t 表記 2...)\n
#
#
;名詞
6      3 名詞
;形容詞
3      3 形容詞
;動詞
2      3 動詞
-1     2 する
-1     2 ある
-1     2 なる
-1     2 できる
-1     2 よる
-1     2 とする
-1     0 よって
-1     0 より
-1     0 つれて
-1     0 ついて
-1     0 という
-1     0 した
;助詞
9      3 助詞
kaku   4 格助詞
shu    4 終助詞
setsuzoku 4 接続助詞
kakari 4 係助詞
tokushu 4 特殊
fukushika 4 副詞化
fuku   4 副助詞
heiritsu 4 並立助詞
rentaika 4 連体化
;未定義語
6      1 未知語
=====

```

図 1: フィルタルール記述ファイルの例

- 先頭が「#」で始まる行は無視される。
- 先頭が「;」で始まる行はプログラム内部で区別する品詞についての情報の記述開始を意味する。

この例では、「名詞」、「形容詞」、「動詞」、「助詞」、「未定義語」という 5 つの品詞を内部的な品詞として用いる。

- 「; 品詞」の直後の行は形態素解析における表記との対応を示す。

この行の形式は { コード \t フィールド番号 \t 表記 } である。

ここで、「コード」はプログラム内部で扱う品詞(直前の行で指定しているもの)に割りあてるコードを意味する。「フィールド番号」と「表記」は形態素解析の結果における何番目の「フィールド」がどのような「表記」になっている場合が対応するかを示している。

例：

; 名詞

6 3 名詞

この 2 行の解釈は、形態素解析の結果の 3 フィールド目が「名詞」と表記された場合、内部的に「名詞」であり「6」というコードを割りあてる、と解釈される。また、「形容詞」=3、「動詞」=2、「助詞」=9 である。なお、「未定義語」は 6 であり、これは名詞と同じように扱うことの意味する。

- 3 行目以降(が存在する場合)は、以下の形式で記述される。

{action\ t フィールド番号 1\ t 表記 1(\ t フィールド番号 2\ t 表記 2\ t...)}

ここで「フィールド番号」と「表記」は、形態素解析結果の何番目のフィールドがどのような表記である場合に「action」で表わされる性質と一致するかを意味する。

「action」の意味は内部で扱う品詞の種類により次のように異なる。

- 名詞、形容詞、動詞、未定義語では除外する語を指定する。action=-1
- 助詞の場合は、助詞の分類とその意味の対応を決める。action=分類名

例：

; 助詞

2 3 動詞  
-1 2 する  
-1 2 ある  
-1 2 なる

これは、動詞の 3 行目以降、形態素解析の結果の第 2 フィールドが「する」「ある」「なる」… の場合は action -1 と解釈する(この場合除外を意味する)ことを表わしている。

また、タブで区切って「フィールド番号 \t 表記」の組を続ければ、条件を厳しくすることができる。

例：条件を厳しくした場合

;名詞

6 3 名詞

-1 4 接尾 2 的

このようにすると、名詞-接尾の中で「的」という語だけを削除することになる。

助詞の場合は次のようになる。

例：助詞の場合

;助詞

9 3 助詞

kaku 4 格助詞

shu 4 終助詞

...

ここで kaku や shu という表記が最終的な語彙的連鎖の出力にも表われることになる。また、タブで区切って「フィールド番号\t 表記」の組を続ければ、分類を細かくすることができる。

例：助詞の条件を細分化した場合

;助詞

9 3 助詞

gakaku 4 格助詞 2 が

wokaku 4 格助詞 2 を

## おわりに

Lexical Chainers によって計算され出力される語彙的連鎖データそのものは、単語のグループですので、何かに直接利用できるというものではありません。しかし、メッセージ検索[3]、自動要約[7]<sup>5</sup>、談話構造解析などの自然言語処理の応用分野において、基礎的なデータとして広く利用されています。

なお語の共起関係に基づく語彙的連鎖を計算するプログラムでは、コーパス中の語の出現頻度の取得に、(株) 日立製作所中央研究所において開発された汎用連想検索エンジン GETA(Generic Engine for Transposable Association)[4] を使用しています。GETA は大規模なコーパス解析、検索などに特に力を発揮する非常に強力なツールであり、Lexical Chainers とは関係なく様々な利用が可能ですので、あわせて利用されることをお勧めします。

---

<sup>5</sup><http://galaga.jaist.ac.jp:8000/motizuki/software/posumcl/>

## 参考文献

- [1] H.A.K. Halliday and R. Hasan. *Cohesion in English*. Longman, 1976.
- [2] M. Okumura and T. Honda. Word sense disambiguation and text segmentation based on lexical cohesion. In *Proc. of the 15th International Conference on Computational Linguistics*, pp. 755–761, 1994.
- [3] 望月源, 岩山真, 奥村学. 語彙的連鎖に基づくメッセージ検索. 自然言語処理, Vol. 6, No. 3, pp. 101–126, 1999.
- [4] 高野明彦, 丹羽芳樹, 西岡真吾, 岩山真, 久光徹, 今一修, 櫻井博文, 徳永健伸, 奥村学, 野本忠司. 汎用連想計算エンジンの開発と大規模文書分析への応用. IPA 独創的情報技術育成事業研究成果報告書, 1999.
- [5] 黒橋禎夫. 日本語構文解析システム KNP version 2.0 b6 使用説明書, 1998.
- [6] 黒橋禎夫, 長尾真. 日本語形態素解析システム JUMAN version 3.61, 1999.
- [7] 望月源. テキスト簡易要約器 Posum version 1.50.2 マニュアル. JAIST Technical Memorandum, IS-TM-2002-002, 2002.
- [8] 望月源, 岩山真, 奥村学. 語彙的結束性に基づく語彙的連鎖の計算. JAIST Technical Memorandum, IS-TM-2000-002, 2000.
- [9] 松本裕治, 北内啓, 山下達雄, 平野善隆, 松田寛, 高岡一馬, 湯原正幸. 形態素解析システム『茶筌』version 2.2.7 使用説明書, 2001.