

## 岩波国語辞典を利用した語義タグ付きテキストデータベースの作成

白井 清昭<sup>1</sup>, 柏野 和佳子<sup>2</sup>, 橋本 三奈子<sup>3</sup>, 徳永 健伸<sup>1</sup>, 有田 英一<sup>4</sup>, 井佐原 均<sup>5</sup>,  
荻野 紫穂<sup>6</sup>, 小船 隆一<sup>4</sup>, 高橋 裕信<sup>7</sup>, 長尾 確<sup>6</sup>, 橋田 浩一<sup>8</sup>, 村田 真樹<sup>5</sup>

<sup>1</sup> 東京工業大学 大学院情報理工学研究科 <sup>2</sup> 国立国語研究所 言語体系研究部 <sup>3</sup> 富士通株式会社  
DB サービス部 <sup>4</sup> 新情報処理開発機構 情報ベース機能三菱研究室 <sup>5</sup> 通信総合研究所  
けいはんな情報通信融合研究センター <sup>6</sup> 日本アイ・ビー・エム株式会社 東京基礎研究所  
<sup>7</sup> 新情報処理開発機構 情報ベース機能つくば研究室 <sup>8</sup> 電子技術総合研究所 情報科学部

本論文では、我々が作成した語義タグ付きテキストデータベースの概要について述べる。テキストは毎日新聞の3,000個の記事である。888,000形態素のうち、名詞、動詞、形容詞あわせて149,556形態素を語義タグを付与する対象とした。語義タグは岩波国語辞典によって定義される。すなわち、岩波国語辞典の語釈をそのまま形態素に与える語義タグとする。対象形態素の97.9%は、岩波国語辞典の語釈の中から適切な語義を選ぶことができた。最終的には、今回与えた語義情報と、形態素情報、統語情報、照応・共参照情報をGDA(Global Document Annotation)タグによって統合したテキストデータベースを作成する予定である。

## Text Database with Word Sense Tags Defined by Iwanami Japanese Dictionary

SHIRAI Kyoaki<sup>1</sup>, KASHINO Wakako<sup>2</sup>, HASHIMOTO Minako<sup>3</sup>,  
TOKUNAGA Takenobu<sup>1</sup>, ARITA Eiichi<sup>4</sup>, ISAHARA Hitoshi<sup>5</sup>,  
OGINO Shiho<sup>6</sup>, KOBUNE Ryuichi<sup>4</sup>, TAKAHASHI Hironobu<sup>7</sup>,  
NAGAO Katashi<sup>6</sup>, HASIDA Kōiti<sup>8</sup>, MURATA Masaki<sup>5</sup>

<sup>1</sup>Tokyo Institute of Technology, <sup>2</sup>The National Language Research Institute, <sup>3</sup>Fujitsu

<sup>4</sup>Real World Computing Partnership, Mitsubishi Lab., <sup>5</sup>Communications Research Laboratory,

<sup>6</sup>IBM Japan, <sup>7</sup>Real World Computing Partnership, Tsukuba Lab., <sup>8</sup>Electrotechnical Laboratory,

In this paper, we describe the overview of the word sense tagged text database we currently construct. As target words to which word sense tags would be assigned, we chose 149,556 words, which are nouns, verbs or adjectives, from 888,000 words in the 3,000 newspaper articles excerpted from Mainichi Shinbun. We used word sense description in Iwanami Kokugo Jiten, which is a published Japanese dictionary, as word sense tags. For 97.9% of target words, the appropriate word sense description were found in Iwanami Kokugo Jiten. In addition to these word sense tags, we will annotate the text with morphological, syntactic, anaphoric and coreference information in GDA (Global Document Annotation) tag format in future.

# 1 はじめに

新情報処理開発機構 (RWCP: Real World Computing Partnership) テキスト・サブ・ワーキンググループでは、1994 年度から大規模コーパスの作成に取り組んできた。その活動の一環として、1998 年から 2000 年にかけて、語義タグ付きテキストデータベースを作成した。語義タグの定義は、岩波国語辞典第五版 [4] に従っている。すなわち、テキスト中の形態素に対して、それに対応する語義を岩波国語辞典の語釈の中から選び、語義タグとして付与する作業を行った。語義タグを付与する対象としたテキストは、同ワーキンググループで作成したテキストデータベース RWC-DB-TEXT-95-2 である [1]。このテキストデータベースは、毎日新聞の 1994 年の 3,000 個の記事に対して、機械的に形態素解析を行った後、形態素情報を人手で修正して作成された形態素タグ付きコーパスである。このテキストデータベースに含まれる 888,000 個の形態素のうち、2.1 項で述べる基準を満たす 149,556 形態素に対して、語義タグを付与する作業を行った。

本論文では、語義タグ付きテキストデータベースの作成作業ならびに概要を報告する。2 節では、語義タグを付与する対象となる形態素の選択基準やタグ付け作業の指針など、語義タグ付きテキストデータベースの作成過程について述べる。3 節では、一形態素に付与された語義タグ数の分布や、付与された語義タグの種類の内訳など、作成された語義タグ付きテキストデータベースの概要について述べる。最後に 4 節では、同ワーキンググループの今後の活動予定について述べる。

## 2 語義タグ付きテキストデータベースの作成

### 2.1 語義タグ付与対象形態素の選択

形態素情報が付与された 3,000 個の新聞記事の中から、以下の条件を満たす形態素を抽出し、語義タグ付与対象形態素とした。

#### 【対象形態素選択基準】

1. 品詞が名詞、動詞、形容詞のいずれかである。  
但し、名詞については固有名詞、代名詞、数を、動詞および形容詞については文語であるものを対象から除いた。
2. 形態素と一致する見出しが岩波国語辞典に記載されている。

表 1: 語義タグ付与対象形態素数一覧

品詞	(a)	(b)	(c)	(d)
名詞	377,464 38,445	224,325 21,432	205,271 15,836	78,453 5,071
動詞	81,015 3,303	80,942 3,275	73,736 2,658	66,168 1,614
形容詞	7,230 429	7,180 425	6,214 337	4,409 175
その他	422,291 1,285	—	—	—
合計	888,000 43,462	312,447 25,131	285,221 18,831	149,030 6,860

(上段がのべ数、下段が基本形の異り数)

テキストデータベースに付与されている形態素情報には、読みの情報が含まれている。形態素の読み(活用語の場合には基本形の読み)と一致する見出しが岩波国語辞典に存在することが条件となる。

#### 3. 語釈が一意に決まらない。

岩波国語辞典において、品詞、読み、表記が一致する見出しがひとつしかなく、かつその見出しの語釈がひとつしかない場合、その形態素は作業対象から除いた。

【対象形態素選択基準】を満たす形態素は 149,030 個あり、これらを語義タグを付与する対象とした。その品詞別の内訳を表 1 に示す。表 1 において、(a) は 3,000 記事全体の形態素数、(b) は【対象形態素選択基準】の条件 1 を満たす形態素数、(c) は条件 1,2 を満たす形態素数、(d) は条件 1,2,3 を満たす形態素数をそれぞれ示している。語義タグ付与対象形態素の数は (d) に示されている。

さらに、複数の形態素を連結して得られる複合語が語義タグを付与する対象となる場合がある。例えば、新聞記事中に「分かれ」「道」という形態素の並びがあるとする。この場合、[わかれみち(分かれ道)] という見出しが岩波国語辞典にあるので、「分かれ」と「道」のそれぞれに語義タグを付与する他に、「分かれ道」にも語義タグを付与した方が望ましい。そこで、連続する 2 個または 3 個の形態素を連結した複合語について、【対象形態素選択基準】の条件 2,3 を満たすものを取り出し、語義タグ付与対象形態素に加えた。また、連続する最後の形態素が活用語の場合、表記と基本形の 2 通りの可能性について、条件を満たすか否かを調べた。例えば、「組み」「合わせ」という形態素の並びがある場合、「組み合わせ」と「組み合わせる」の 2 通りの複合語について、【対象形態

表 2: 複数の形態素を連結して得られた対象単語

連結形態素数	1	2	3
対象単語数(のべ)	149,030	508	18
対象単語数(異り)	6,860	139	7

素選択基準】の条件 2,3 を満たすか否かを調べた。このような複合語も含めた語義タグ付与対象形態素の数を表 2 にまとめる。表 2 において、連結形態素数 1 の欄は表 1 (d) の再掲である。また、条件 2,3 を満たしても、語義タグ付与作業の過程で、語義を付与する単位としてふさわしくないと判断された複合語は除かれている。

複合語の場合、【対象形態素選択基準】の条件 1 は考慮しない。なぜなら、複合語の品詞は、それを構成する形態素の品詞からは必ずしも特定できないからである。例えば、「同時」と「に」を連結した「どうじに(同時に)」という見出しが岩波国語辞典に存在するが、「同時」の品詞は名詞、「に」の品詞は助詞であるのに対し、「同時に」の品詞は副詞である。

## 2.2 語義タグの定義

1 節で述べたように、語義タグは岩波国語辞典の語義立てに従う。[いちばん] という岩波国語辞典の語釈と語義タグの対応を図 1 に示す。

語義タグは、以下のように 5 つの数字から構成されている。

〈見出し ID〉-〈複合語 ID〉-〈大分類 ID〉-〈中分類 ID〉-〈小分類 ID〉

〈見出し ID〉は、岩波国語辞典における見出しを特定するための番号である。例えば、「2329-0-1-1-0」という語義タグの 2329 は、[いちばん] という見出しを表わす。〈複合語 ID〉は、見出し中の複合語を特定するための番号である。岩波国語辞典では、例えば「一番」という見出しひには、「一番」の語釈に統いて、「一番鶏」「一番乗り」「一番槍」という複合語の語釈が記述されている。この場合、一番、一番鶏、一番乗り、一番槍の〈複合語 ID〉はそれぞれ 0,1,2,3 となる。〈大分類 ID〉、〈中分類 ID〉、〈小分類 ID〉は、見出しにおける語釈を特定するための番号である。岩波国語辞典では、語釈を識別するための番号として、意味分類の粒度に応じて大分類、中分類、小分類の 3 つの種類の番号が用いられている。大分類の語釈番号は(一)、(二)、(三)<sup>1</sup>、中分類の語釈番号は①、②、③、小

<sup>1</sup> 実際に市販されている岩波国語辞典では、これらは漢数字を

分類の語釈番号は⑦、①、⑦によって記述されている。(大分類 ID)、(中分類 ID)、(小分類 ID)はこれらの語釈番号に対応している。また、見出し中に使われてない分類の語釈番号があるとき、その分類に対応する ID の値は 0 とした。さらに、1 つの見出しに 1 つの語釈しか存在しないときなど、語釈文の前に何も番号が付記されていない場合があるが、そのような語釈の(大分類 ID)、(中分類 ID)、(小分類 ID)は全て 0 にした。(ex. 図 1 の“2329-1-0-0-0”など)

語義タグ付与対象形態素に与える語義情報としては、以上のように定義された語義タグの他に、作業者が自由に作成する語釈や、“該当なし”，慣用表現の説明文などがある。これらの詳細は次項で述べる。以降、便宜上、これらの語義情報も語義タグと呼ぶ。

## 2.3 作業手順

2.1 項で述べた語義タグ付与対象形態素に対して、該当する語義タグを付与する作業を行った。その作業手順は以下の通りである。

### A. 岩波国語辞典の語釈を付与する場合

岩波国語辞典の語釈の中から該当するものを選択し、それに対応した語義タグにマークを付ける。マークは\*(該当する)と?(該当すると思われるが断定しにくい)の 2 種類がある。また、1 つの単語に対して複数の語義タグを選んでもよい。

### B. 語釈を作成する場合

岩波国語辞典の語釈に適当なものが存在しない場合には、作業者が語釈を作成し、形態素に与える語義タグとする。語釈を作成する場合には、基本的には広辞苑を参考にし、広辞苑の語釈を流用するか、自由に作文する。

### C. “該当なし”の場合

対象形態素が語義情報を与える単位としてふさわしくないと判断された場合には、“該当なし”という語義タグを与える。例えば、「けいざいショット」というコラムのタイトルがある場合、「ショット」の語義タグは“該当なし”となる。

### D. 慣用表現の場合

語義タグ付与対象形態素が慣用表現の一部の場合、語構成としての意味に該当する岩波国語辞典の語釈を選択し、さらに慣用表現全体とその意味を語義タグとして付与する。例えば、「会場に足を運ぶ」という文の「運ぶ」が語義タグ付与対象形態素である場合、「運ぶ」の意味に該当する語釈を選択した後，“慣用#「足を一」(行

四角で囲った記号で表わされる。

(語義タグ)		(岩波国語辞典における語釈文)
2329-0-1-0-0	↔	いちばん【一番】 ①((名)) ①第一の番。
2329-0-1-1-0	↔	⑦順番が最初であること。
2329-0-1-1-1	↔	⑦同種のものの中で最もすぐれたもの。最上。
2329-0-1-1-2	↔	②一回・一曲など、番で数えるもの一つ。「一勝負」
2329-0-1-2-0	↔	①最も。「一始め」
2329-0-2-0-0	↔	②こころみに。ひとまず。「承知するかしないか一当たってみよう」
2329-0-2-1-0	↔	いちばん／【一番】／—どり【△鶏】 朝、一番始めに鳴くニワトリ。
2329-0-2-2-0	↔	いちばん／【一番】／—のり【一乗り】 最初に敵陣に馬を乗り入れること。またその人。転じて、ある場所に最初に乗りこむこと。
2329-1-0-0-0	↔	いちばん／【一番】／—やり【一×槍】 最初に敵陣に槍をつきいれること。またその人。転じて、最初に功名を立てること。
2329-2-0-0-0	↔	いちばん／【一番】／—やる【一×槍】 最初に敵陣に槍をつきいれること。またその人。転じて、最初に功名を立てること。
2329-3-0-0-0	↔	

図 1: 語義タグと語釈文の対応

く。通う)”のような記述を語義タグとして付与する。慣用表現の記述は、岩波国語辞典にふさわしい記述があれば、それをそのまま用いる。

#### E. 複合語の見出しの語義タグを付与する場合

語義タグ付与対象形態素とそれに後続する形態素を連結した単語が、複合語の見出しとして岩波国語辞典に記載されている場合がある。例えば、「一番乗りは太郎君だ」という文の「一番」が語義タグ付与対象形態素であるとする。このとき、図 1 の例にあるように、「一番」とその後の「乗り」をつなげた「一番乗り」という見出しが見出し [いちばん(一番)] の複合語として岩波国語辞典に記載されている。

このような場合には、まず語構成としての意味に該当する岩波国語辞典の語釈を選択し、\*マークをつける。先の例では、「一番」の語義タグとして“2329-0-1-1-1”を選び、\*マークをつける。さらに、語義タグ付与対象形態素が同じ見出し内にある複合語の一部である場合には、該当する複合語の語釈を選択し、?マークを付ける。先の例では、「一番」が「一番乗り」の一部であることを示すため、“2329-2-0-0-0”の語義タグを選び、?マークを付ける。

#### F. 別見出しの語釈を参照する語釈を選択する場合

該当する語釈が別の見出しの語釈を参照している場合がある。例えば、[おきる(起きる)] の語釈文のひとつに

②↓おこる(起)アウ

がある。この語釈は、[おこる] という別見出し

の⑦,⑧のいずれかの語釈と同じであることを表わしている。

このように、他の語義を参照している語釈が対象形態素の意味を表わすものとして適切である場合、その参照先の語釈にもマークをつける。先の例では、[おきる] の②を適切な語釈として選んだ場合には、[おこる] の⑦,⑧のいずれかのうち、適切な語釈にもマークをつける。

上記の作業を行うために、Mule 上で動作するタグ付けツールを開発した。このツールを用いて、3人の作業者が語義タグを付与する作業を行った。作業者は、言語学や辞書編纂の知識をある程度持っている人である。IPAL 辞書 [7] の作成に関与した人も含まれる。作業に要した時間は、試行期間や見直し作業も含めて、約 2 年間である。

### 3 語義タグ付きテキストデータベースの概要

本節では、作成された語義タグ付きテキストデータベースの概要について述べる。なお、付与された語義タグの具体例については、付録 A を参照していただきたい。

#### 3.1 一形態素に付与された語義タグ数

語義タグ付与対象形態素 1 つにつき、付与された語義タグ数の分布を表 3 に示す。表 3 から、ほとんど(99.2%) の形態素の語義が一意に定まることがわかる。

表 3: 一形態素に付与された語義タグ数の分布

語義タグ数	1	2	3
形態素数	148,359	1162	35

表 4: 付与された語義タグの種類

A. 岩波国語辞典の語釈	*	147,348
	?	51
B. 作成された語釈		2,724
C. 該当なし		453
D. 慣用表現		212
E. 複合語の見出し		871
F. 別見出しの語釈		330

### 3.2 語義タグの種類の内訳

表 4 は、付与された語義タグの種類とその頻度をまとめたものである。表 4 において、A.～F. は 2.3 項に示した作業手順に対応している。B. および C. が、岩波国語辞典の語釈によって意味を特定することができなかった形態素の数を表わしている。その全体に占める割合は 2.1%である。

### 3.3 語義タグの頻度分布

語義タグ付与対象形態素を表記、読み、品詞で分類し、一種類の対象形態素に付与される語義タグの異り数について調査した。但し、ここで報告するのは、岩波国語辞典の語義タグ(表 4 の A.)の頻度分布であり、他の種類の語義タグ(表 4 の B.～F.)は考慮していない。また、出現頻度の低い形態素について語義タグの頻度分布を調べることはあまり意味がないと考え、出現頻度 10 以上の対象形態素のみについて調べた。ちなみに、語義タグ付与対象形態素全体に対する出現頻度 10 以上の対象形態素のべ数の割合は 90.8%である。

表 5 は、一種類の対象形態素に付与された語義タグの異り数の分布を表わしている。平均すると、一種類の対象形態素につき 1.59 種類の語義タグが付与されることになる。また、90%以上の対象形態素は 4 種類以下の語義タグしか付与されていない。図 2 (a) は、一種類の対象形態素に対して、最も多く付与された語義タグの相対頻度の分布を表わしている。横軸は語義タグの最大相対頻度(小数点 2 位以下切り捨て)，縦軸はそれに該当する対象形態素の異り数を表わしている。一方、図 2 (b) は、一種類の対象形

表 5: 付与された語義タグの異り数の分布

語義タグの異り数	1	2	3	4	5 以上
形態素数	636	606	262	123	169

態素に対する語義タグのエントロピー(小数点 2 位以下切り上げ)の分布を表わしている。エントロピーは式(1)によって定義され、語義タグの偏りの度合を表わす。

$$H = \sum_{x \in X} -p(x) \log_2 p(x) \quad (1)$$

式(1)において、 $X$  は一種類の対象形態素に付与された語義タグの集合を、 $p(x)$  は語義タグ  $x$  の出現確率(相対頻度)を表わしている。エントロピーの値が小さければ小さいほど、付与された語義タグに偏りがあることになる。

図 2 (a),(b) から、特定の語義タグが集中的に現われる傾向が読み取れる。また、品詞別にみると、特定の語義タグが集中的に現われる傾向は、動詞や形容詞と比べて名詞の方が強いことがわかる。

### 3.4 One Sense per Discourse

Yarowskey は、語義の分布は one sense per discourse という性質を持つと主張している [5]。one sense per discourse とは、同じ文書の中にある単語の語義は全て等しくなる傾向があることを指す。そこで、作成された語義タグ付きデータベースにおいて、同じ記事に現われる形態素の語義タグがどの程度一致しているかを調べた。表 6 の“一記事”的行は、同一記事に 2 回以上出現する対象形態素があったとき、それらに付与された語義タグが全て一致する割合を示している。動詞と比べて、名詞や形容詞の一一致率が高いことがわかる。また、これと比較するために、同一記事に同じ対象形態素が  $n$  回( $n >= 2$ ) 出現したとき、それと同じ表記、読み、品詞を持つ対象形態素をテキストデータベース全体の中からランダムに  $n$  個取り出し、それらの語義タグが一致する割合を調べた。表 6 の“ランダム”的行は、この試行を 10 回繰り返したときの一一致率の平均を示している。表 6 の“一記事”と“ランダム”的の一一致率を比べると、同じ記事に現われる形態素の語義は等しくなる傾向が強いといえよう。また、同一記事内に現われているのにも関わらず、複数の語義タグが付与された対象形態素を調べてみたところ、「する」「いる」「ある」などの補助動詞にもなりうる動

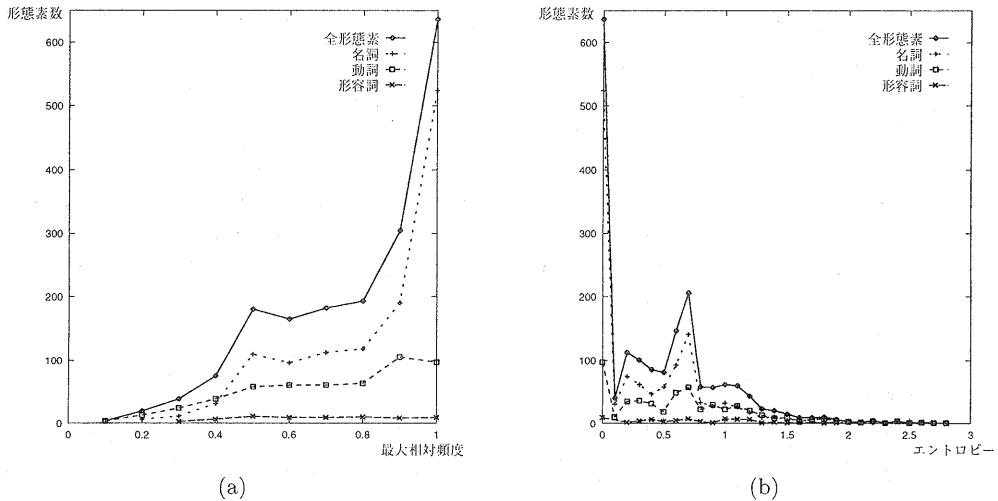


図 2: 語義タグの相対頻度とエントロピー

表 6: 語義タグの一一致率

	全品詞	名詞	動詞	形容詞
一記事	75.9%	88.0%	60.9%	84.8%
ランダム	61.0%	71.2%	48.8%	67.3%

詞や、「こと」「ため」「もの」などの形式名詞が多いことがわかった。

#### 4 今後の活動予定

最後に RWCP テキスト・サブ・ワーキンググループの今後の活動予定について述べる。

我々は、作成された語義タグ付きデータベースについて、頻度分布などの統計的な調査しか行っていないが、今後は定性的な分析を行う予定である。例えば、「取る」「見る」などの基本的な動詞の語義タグの分布や、「手」「頭」などの身体語彙の語義タグの分布、あるいは「午前」と「午後」などの反意語の語義タグの分布の関係などを調べたい。

また、我々は、岩波国語辞典の語釈文に対して形態素情報を付与したテキストデータベース (RWC-DB-TEXT-96-2) を作成し、既に公開している。今回は毎日新聞の記事に含まれる形態素を対象としたが、岩波国語辞典の語釈文に含まれる形態素に対して、該当する岩波国語辞典の語釈を与える作業をすすめている。

岩波国語辞典の語釈文中の形態素に語義タグを付

与する作業を始める際、毎日新聞の語義タグ付きテキストデータベース作成の際に問題となった点を見直し、作業指針の変更やタグ付けツールの改良を行った。特に、岩波国語辞典の語釈の定義の見直しを行った。例えば、[あお(青)] に以下のような語釈がある。

- ① 黒い毛色の馬。「いななけ、一よ」△俗に、毛色が何であれ、馬をさすこともある。

現段階では、上記の語釈は 1 つの語義を表わすとみなされ、1 つの語義タグ ("184-0-0-2-2") で表現される。しかしながら、「△俗に、…」以降の記述は、別の語義を表わしていると考える方が妥当である。岩波国語辞典では、特に「△」という記号の後に現われる記述は、別の語釈として独立させた方がよい場合がある。そこで、語釈文中的「△」という記号の後にある記述を人手でチェックし、別の語釈として独立させた方がよい場合には、そのように辞書の語義立てを変更した。

また、毎日新聞 3000 記事のテキストデータベース (RWC-DB-TEXT-95-2) と岩波国語辞典そのもののテキストデータベース (RWC-DB-TEXT-96-2) に対して、GDA タグ [6] によって統語構造や照応・共参照の構造を付与する作業も行っている。最終的には、GDA タグの枠組において、形態素情報、統語情報、照応・共参照情報、語義情報を統合したテキストデータベースを作成する予定である。なお、岩波国語辞典のテキストデータベースは、岩波国語辞典自身の意味的検索（「これこれしかじかの意味を一言で言う

にはどう言えば良いか?」というような検索)に加えて、一般的な日本語文書に関する意味的検索にも使えるものと期待されるので、これらに関する研究も行なう予定である。また、岩波国語辞典については、共参照のタグ付けを拡張する形で項構造に関するタグ付けも行なうべく準備を進めている[3]。

2001年に、語義曖昧性解消のコンテストSENSEVAL2[2]が行われる。参加者による評価は2001年の4月から5月にかけて行われ、7月にはワークショップが開催される予定である。SENSEVAL2には2つの日本語タスクがある。ひとつは日本語から英語への訳語選択を行うタスク、もうひとつは岩波国語辞典の語釈の中から適切な語釈を選ぶタスクである。作成された語義タグ付きテキストデータベースは、後者のタスクの訓練データとして使用される予定である。

なお、本論文で紹介したテキストデータベースの入手方法については、以下のURLを参照していただきたい。

[http://www.rwcp.or.jp/wswg/rwcdb/  
text/index.html](http://www.rwcp.or.jp/wswg/rwcdb/text/index.html)

## 謝辞

約15万語という大量の形態素に語義タグを付与する作業をして下さった方々、並びにタグ付けツール開発に携わっていただいた方々に深く感謝いたします。

## 参考文献

- [1] Koiti Hasida, Hitoshi Ishihara, Takenobu Tokunaga, Minako Hashimoto, Shihoko Ogino, Wakako Kashino, Jun Toyoura, and Hironobu Takahashi. The RWC text databases. In *Proceedings of the first International Conference on Language Resources and Evaluation*, pp. 457-462, 1998.
- [2] Adam Kilgarriff and Martha Palmer (Guest Ed.). Special issue on SENSEVAL. *Computers and The Humanities*, 2000.
- [3] 村田真樹、内山将夫、井佐原均. 辞書定義文を用いた複合語分割 — 語構成情報の抽出と考察 —. 言語処理学会第6回年次大会発表論文集, pp. 411-414, 2000.
- [4] 西尾実、岩淵悦太郎、水谷静夫. 岩波国語辞典 第五版. 岩波書店, 1994.
- [5] David Yarowsky. Unsupervised word sense disambiguation rivaling supervised methods. In *Proceedings of the Annual Meeting of the Association for Computational Linguistics*, pp. 189-196, 1995.
- [6] 橋田浩一. GDA 日本語タギングマニュアル.  
<http://www.etl.go.jp/etl/nl/gda/tagman.html>, 2000.
- [7] 情報処理振興事業協会. 計算機用日本語基本動詞辞書 IPAL(Basic Verbs), 1987.

## A 付与された語義タグの例

例として、実際に付与された語義タグとその頻度を示す。書式は以下の通りである。

◎(表記)(読み)(品詞)(出現頻度)

(語義タグ)(マーク)(付与頻度)(相対付与頻度)  
(岩波国語辞典の語釈文)

...

### 【名詞】

◎問題 モンダイ 名詞 824

51669-0-0-1-0 \* 0 0.000

①答を求めて他が出しました自分で設けた、問い合わせ。

51669-0-0-1-1 \* 9 0.011

⑦実力をためしたり練習したりするための問い合わせ。  
〔算数の問題〕

51669-0-0-1-2 \* 801 0.972

①研究・議論により、または策を講じて、解決すべき事柄。「問題提起」「この計画にはまだ解決すべき問題(点)が多い」「死活の問題」「問題にならない」(取り上げる価値がない)「時間の問題」(↓じかん(時間))▽難点の意にも使う。「いささか問題がある」

51669-0-0-2-0 \* 0 0.000

②問題①に似たあり方のもの。

51669-0-0-2-1 \* 11 0.013

⑦扱いが面倒な事件。「また女の事で問題を起こした」

51669-0-0-2-2 \* 3 0.004

①人の注目を集めている、また集めてしまるべきこと。「これが問題の人物です」「最近の問題作」

◎関係 カンケイ 名詞 447

9667-0-0-1-0 \* 249 0.557

①一つまたは一組のものが他に対してもつ何らかのつながり。「本社は彼と何の関係もない」「火と水(と)の関係」(対立関係のたとえ)「人間関係」「関数関係」▽日常語では、例えば男女間の情交など、特定の関係を暗示的に指す場合がある。論理的には、甲の乙に対する関係と、その逆関係すなわち乙の甲に対する関係とを区別する。

9667-0-0-1-0 \* 175 0.391

②それに直接(強く)かかること。そういうかかり。「彼が関係した事件」「所持金の関係で買うのをやめる」「関係者」

9667-0-0-1-0 \* 23 0.051

③《接尾語的に》その方面(の仕事)。「営業関係をやっています」▽職業・担当業務をややほかして言う。

### 【動詞】

◎受ける ウケル 動詞 408

3481-0-1-0-0 \* 0 0.000

(一)【受ける・△承ける・請ける】[下ー他] 他から来る物や加わる作用を身に引き取る。

3481-0-1-1-0 \* 0 0.000

①来るものを持って支える(ようにする)。▽一般には「受」を使う。

- 3481-0-1-1-1 \* 8 0.0196  
 ⑦ うけとめる。「ボールをミットで受ける」「たれる油を皿に受ける」
- 3481-0-1-1-2 \* 16 0.0392  
 ① 授かる。「学位を受ける」「国民栄誉賞を受ける」「母の血を受けて詩才がある」。天から授かる。「生を人の世に受ける」△天授の場合は「享」とも書く。
- 3481-0-1-1-3 \* 10 0.025  
 ⑦ あとを引き継ぐ。【承】「父のあとを承けて家業に励む」
- 3481-0-1-2-0 \* 1 0.002  
 ② それに応ずる気持で受け取る。
- 3481-0-1-2-1 \* 154 0.377  
 ⑦ うけいれる。うけいれて応ずる。【受】「敬礼を受ける」「試験を受ける」「受けて立つ」(仕掛けられた攻撃に応じて立ち向かう。すもうの立ち合いから出た言い方)
- 3481-0-1-2-2 \* 8 0.020  
 ① 要求・提案に応ずる。【承・請】「お受けします」
- 3481-0-1-2-3 \* 0 0.000  
 ⑦ 注文をひきうける。【請】「得意先の仕事を請ける」
- 3481-0-1-2-4 \* 0 0.000  
 ⑦ 代金を払って引き取る。【請】「質草(しちぐさ)を請け出す」
- 3481-0-1-3-0 \* 205 0.502  
 ③ 作用などに身をさらす。【受】「四面に敵を受ける」「ボールを頭に受ける」「命令を受ける」「注意を受ける」「傷を受ける」「あなどりを受ける」「南を受けて(=南向きに)建てられた家」
- 3481-0-2-0-0 \* 6 0.015  
 (二)【受ける】[下自] 芝居などで、客の気に入り、かっさいを得る。転じて広く、好評を得る。「大衆に受ける」△(-)③の転。

#### ◎ 持つ モツ 動詞 322

- 51332-0-1-0-0 \* 0 0.000  
 (-) [五他]
- 51332-0-1-1-0 \* 65 0.202  
 ① 手に取る。「荷物を持つ」「持ちつ持たれつ」(おたがいに助け合うさま)「持ちも提(さ)げもならぬ」(どうにも処置する方法がない)「肩をもつ」(支持し、声援する)
- 51332-0-1-2-0 \* 10 0.031  
 ② 自分のものにする。
- 51332-0-1-2-1 \* 114 0.354  
 ⑦ 所持する。身につける。所有する。「大金を持ち歩く」「選挙権をもつ」「家を持つ」△(-)③。
- 51332-0-1-2-2 \* 69 0.214  
 ① 心にいだく。「関心を持つ」「恨みを持つ」「その事を根に持て恨む」
- 51332-0-1-2-3 \* 41 0.127  
 ⑦ 身にそなえる。「持って生まれた性質」「手に職を持つ」
- 51332-0-1-2-4 \* 2 0.006  
 ⑦ 担任する。受け持つ。「新入生の組をもつ」
- 51332-0-1-2-5 \* 2 0.006  
 ⑦ 負担する。「学資は国でもつ」「責任を持つ」
- 51332-0-1-3-0 \* 16 0.050  
 ③ 成り立たせる。有する。保つ。「関係を持つ」「その国とは国交をもっていない」「会議を持つ」「交渉を持つ」△第二次大戦後の言い方。

- 51332-0-2-0-0 \* 3 0.009  
 (二) [五自] 状態・品質・働きが長い間変わらないで保たれる。「この服はずいぶん長く保った」「体が保たない」(健康な状態が続かない)「天気がもつ」

#### 【形容詞】

- ◎ 高い タカイ 形容詞 210
- 31166-0-0-1-0 \* 1 0.005  
 ① 規準とする面から上への距離が大きい。△低い。
- 31166-0-0-1-0 \* 3 0.014  
 ⑦ (ずっと) 上方の位置にある。「高く飛ぶ」
- 31166-0-0-1-0 \* 6 0.029  
 ① 上端までの隔たりが大きい。「背が高い」「鼻が高い」(自慢するさまにも言う)△↓ふかい①。
- 31166-0-0-1-0 \* 0 0.000  
 ② 他より著しい。
- 31166-0-0-1-0 \* 13 0.062  
 ⑦ 地位・格式・能力等がすぐれている。△低い。  
 「格調が高い」「目が高い」(物事の本質・価値を見抜く力がすぐれている)
- 31166-0-0-1-0 \* 143 0.681  
 ① 程度がはなはだしい。△低い。「評判が高い」「気位が高い」「緯度が高い」
- 31166-0-0-1-0 \* 40 0.190  
 ⑦ 買うのに多くの金がいる値段だ。△安い。
- 31166-0-0-1-0 \* 4 0.019  
 ⑦ 声・音の振動数が多い。「ソプラノの高い声」。俗に、声・音が大きい。「声が高くてやかましいよ」。△低い。<派生> 高さ★ 高み★
- ◎ 大きい オオキイ 形容詞 198
- 5167-0-0-1-0 \* 0 0.000  
 ① 物の形・量・事柄の度合が、同類の(平均的な)ものを越えてうわまわっている。△小さい。
- 5167-0-0-1-0 \* 32 0.162  
 ⑦ 体積・面積などが、たくさんの場所を占める。「大きい部屋」「大きいつらをする」(えらぶって、横柄な態度をする)「大きい体」
- 5167-0-0-1-0 \* 135 0.682  
 ① 数・量・程度・作用などがはなはだしい。「五は三より大きい」「大きい音」「損害が大きい」「人格形成に大きく影響する」
- 5167-0-0-1-0 \* 3 0.015  
 ⑦ 年齢が上である。大人だ。「大きくなったら」「ぼくより大きい子」
- 5167-0-0-1-0 \* 27 0.136  
 ⑦ 規模がまさっている。範囲が広い。「大きい計画」。包容力がある。「人物が大きい」
- 5167-0-0-1-0 \* 0 0.000  
 ② 事実や身分・能力に比べ、大げさだ。「大きい事を言う」
- 5167-0-0-1-0 \* 1 0.005  
 ③ 《「大きく」の形で》えらぶって。かさにかかる。「頭から大きく出る」「大きく構える」△文語形容詞「多し」の連体形から出た「おほきなり」の「おほき」に形容詞語尾の付いたもの。<派生> 大きさ★