

『現代日本語書き言葉均衡コーパス』に対する分類 語彙表番号アノテーションの試行

著者	加藤 祥, 浅原 正幸, 山崎 誠
雑誌名	言語資源活用ワークショップ発表論文集
巻	1
ページ	104-113
発行年	2017
URL	http://doi.org/10.15084/00001463

『現代日本語書き言葉均衡コーパス』に対する 分類語彙表番号アノテーションの試行

加藤 祥 (国立国語研究所コーパス開発センター)[†]
浅原 正幸 (国立国語研究所コーパス開発センター)
山崎 誠 (国立国語研究所研究系言語変化研究領域)

Trial Annotation of ‘Word List by Semantic Principles’ information on ‘Balanced Corpus of Contemporary Written Japanese’

Sachi Kato (National Institute for Japanese Language and Linguistics)
Masayuki Asahara (National Institute for Japanese Language and Linguistics)
Makoto Yamazaki (National Institute for Japanese Language and Linguistics)

要旨

『現代日本語書き言葉均衡コーパス (BCCWJ)』に分類語彙表番号を付与する作業を開始した。『分類語彙表増補改訂版』(2004)の分類語彙表番号を、短単位と長単位のそれぞれにアノテーションする。作業にあたり、人手で UniDic 語彙素 ID に対応させたデータ (近藤・田中, 2017) を用い、該当可能性のある番号を列挙する。作業者は、該当する意味分類が選択可能であれば選択し、選択できない場合や対応のない場合には、新たに適切な番号を付与する。本発表では、番号付与作業基準と作業状況、作業結果を用いた調査例を報告する。

1. はじめに

類語の調査はもちろん、比喩をはじめとする表層的な表現と意味の差を研究する際など、意味的な情報の付与されたコーパスが有用なリソースとなる。また自然言語処理の分野では、語義曖昧性解消のタスクの学習・評価データとして様々な語義タグつきデータが整備されてきた。日本語では、古くは新聞記事を対象とした EDR コーパスや RWCP コーパスなどが国語辞典に基づく語義タグを付与していた。また、代表性を持つコーパスとして、『現代日本語書き言葉均衡コーパス』(Maekawa et al. 2014) (以下 BCCWJ)の一部に対しても、岩波国語辞典の語義が付与され、SemEval-2010 Japanese WSD Task (Okumura et al. 2011) では、日本語の語義曖昧性解消の基礎データとして用いられてきた。また、シソーラスに基づくデータとして、日本語ワードネットに基づく語義タグ付きコーパス(Bond et al. 2012) が整備されている。このコーパスは、英語データを翻訳したものであり、代表性をもつ自然な日本語コーパスに対する、シソーラスに基づく語義タグつきデータは管見の限りない。

国立国語研究所では、BCCWJ コアデータに『分類語彙表増補改訂版』(2004)の分類語彙表番号を悉皆付与する作業に着手した。現在進めているアノテーション基準・作業状況と作業結果を用いた感情表現の分析について報告する。

[†] yasuda-s(α)ninjal.ac.jp

2. アノテーション

2.1 概要

アノテーション作業対象として、コアデータに含まれる新聞サンプル 54 ファイル（部分集合 A : PN(A)）から、アノテーション優先順位に基づき順次作業に着手した。分類語彙表番号を手で UniDic 語彙素 ID (小木曾・中村, 2014) に対応させたデータ (近藤・田中, 2017) により、BCCWJ の言語単位（短単位・長単位）に対応可能性のある分類語彙表番号を列挙したうえで、人手で正しい語義を選択する作業を進めている。本付与作業にあたっては、分類語彙表の 5 桁目までの番号を付与する。（例は表 1。図 1 における「3.1010こそあど」の分類部分が該当する。）

表 1 分類番号の構造（例：この（分類番号：3.1010））

類	部門	中項目	分類項目
相 (3)	関係 (.1)	真偽 (.10)	こそあど (.1010)

アノテーション作業は、短単位と長単位のそれぞれについて行う。列挙された分類語彙表番号の選択肢から、該当する意味分類が選択可能であれば選択し、選択できない場合や、語彙素に対応する分類語彙表番号がない場合には、新たに適切な番号を付与する。以下では、それぞれの単位のアノテーション作業基準について示す。

3 相の類

3.1 抽象的關係

3.10 真偽

3.1010 こそあど・他

- 01 この こんな こういう こうした
 かかる こう かく かよう
 こうこう かくかく
 しかしか このまま
 かくのごとく／のごとき このとおり
 02 その そんな そういう そうした さる しかる
 そう さ さよう
 車ほどさように 1. かく

図 1 分類語彙表（部分例）

2.2 短単位に対する分類語彙表番号アノテーション

2.2.1 概要

機能語を除く短単位に分類語彙表番号を付与する。分類語彙表番号の付与される短単位の機能語は助動詞と助詞の一部に限られるためである。分類語彙表番号が付与される機能語の内訳を表 2 に示す。頻度は BCCWJ PN (A) サンプルのものである。

語彙素に対応して列挙された番号（曖昧性：1～11 種類）がある場合、作業者は該当番号を選択する（図 2）。

短単位	品詞	記入欄	分類語彙表番号(選択肢)
研究	名詞-普通名詞-サ変可能		1.3065:体-活動-心-研究・試験・調査・検査など
費	接尾辞-名詞的-一般	1.3721	
を	助詞-格助詞		
受け入れる	動詞-一般		2.3430:用-活動-行 2.3532:用-活動-交 2.3770:用-活

図 2 番号付与作業例

新聞サンプル 54 ファイル (部分集合 A:PN (A)) における短単位数は表 3 の通りである。すなわち、短単位 56,922 のうち、アノテーション対象となり得る自立語は 33,725 語 (59.2%) あり、そのうち UniDic-分類語彙表データと語彙素番号がマッチした 28,696 語 (50.4%) について、選択可能な番号が列挙されている。

表 2 分類語彙表番号が付与される機能語

頻度	語彙素番号	語彙素	品詞
261	40741	れる	助動詞
214	27905	など	助詞-副助詞
87	35891	まで	助詞-副助詞
62	39787	られる	助動詞
49	20355	せる	助動詞
47	21652	たい	助動詞
41	23122	だけ	助詞-副助詞
26	22727	たり	助詞-副助詞
8	10403	くらい	助詞-副助詞
7	34770	ほど	助詞-副助詞
6	30577	ばかり	助詞-副助詞
4	19641	ずつ	助詞-副助詞
2	29213	のみ	助詞-副助詞
2	24320	つ	助詞-副助詞
1	14185	させる	助動詞

表 3 BCCWJ PN(A)集合の短単位内訳

PN(A)短単位	のべ	56922
	機能語	23197
	自立語	33725
UniDic-分類語彙表データにマッチしたもの	全て	29513
	機能語	817
	自立語	28696

また、UniDic-分類語彙表データにマッチした自立語の、選択肢数（分類番号の曖昧性）を表 4 に示す。複数選択肢の列挙された短単位（曖昧性 2 以上）は 12,857 (44.8%) ある。なお、曖昧性が 8 となる短単位数の頻出はサ変動詞「する」の頻度の影響による。短単位の番号付与にあたっては、最小限の文脈に依拠した意味とし、比喩的・慣用的な表現などは語源的な意味とする。内容に即した意味は、長単位で対応する。

「名詞-普通名詞-形状詞可能」「名詞-普通名詞-副詞可能」のような品詞の語については、体（1.で始まる分類語彙表番号）・相（3.で始まる分類語彙表番号）のどちらとも読み取れるが、BCCWJ コアに付与された人手による「名詞」「形状詞」などの用法情報に従う。

表4 分類番号の曖昧性 (BCCWJ PN(A) サンプル)

曖昧性	短単位数	曖昧性	短単位数
1	16656	6	237
2	7479	7	134
3	2621	8	1253
4	826	9	49
5	237	10	21

2.2.2 UniDic-分類語彙表対応のない場合

列挙された選択肢に、文脈上適切な番号がないと判断される場合は、新たな番号を付与する。新たに番号を付与する場合は、『分類語彙表増補改訂版』を参照し、適切な意味分類を検討する。UniDic の語彙素に対応する番号がなく、そもそも選択する番号のない場合も、分類語彙表の意味分類を確認し、適切な番号を付与する。

UniDic の語彙素に対応する番号がない例としては、未知語、固有名詞、略語などがある。未知語には「ロック」「カム」「トゥゲザー」のような外来語も多く含まれるが、それぞれ外来語の意味に相当する意味分類を選択し、分類語彙表番号として付与する。

なお、用法によっては、分類語彙表に既存の分類番号がない場合がある。その場合、分類語彙表に存在しない番号を新設して付与することもあり得る。

固有名詞

人名についてはアノテーション対象外とするが、地名や普通名詞を含む「名古屋タワープラザホール」「岡山ホテル」「阪急グランドビル」のような固有名詞については、それぞれ短単位ごとの意味分類が可能と考え、「名古屋タワープラザホール」であれば、「名古屋」「タワー」「プラザ」「ホール」のそれぞれに分類語彙表番号を付与する。

略語・掛詞等

略語についても、元の語形を考慮し、該当する分類語彙表番号を付与する。但し、「厚労」「自民」のように複数語義の組み合わせが一短単位となっている場合もある。このような場合は、「厚労」は「厚生」「労働」,「自民」は「自由」「民主」のそれぞれの短単位に相当する複数の分類語彙表番号を付与する。掛詞やダジャレなど、一短単位について複数の意味が読み取れる場合にも、複数の意味について分類語彙表番号を付与する。

その他

「一個」「一口」のように短単位での登録がある語は、その単位での分類語彙表番号候補がある場合、文脈上「一」「口」や「一」「個」が別の短単位と読むことが適切にも関わらず、「一個」「一口」を一短単位として選択肢(番号の候補)が挙がる。このような場合は、「一」「口」を一短単位と判断し、各々に分類語彙表番号を付与する。また、副詞用法の語であるが分類語彙表番号に体の類しかない場合には、対応する相の番号を新たに付与する。

2.3 長単位アノテーション

短単位と同様に、長単位についても分類語彙表番号を付与する。短単位作業時に、対応した長単位があればマークを表示し、長単位作業のあることを示している。

長単位に対応して列挙された選択可能な番号（1～11種類）がある場合は、該当する番号を選択する。文脈上、適切な番号がないと判断される場合や、語彙素番号に対応する番号がない場合は、同様に適切な意味分類を行い、新たに番号を付与する。

「ていく」「てくる」をはじめ、「にとって」など、助動詞扱いとなるが短単位と異なる意味分類となる場合などは、機能語であっても分類語彙表番号を付与する。また、長単位より大きな単位（慣用句など）として分類語彙表番号がある場合には、メモとして番号を付与する。

3. 作業状況

3.1 現在までの作業概要

作業者と担当サンプルにより、作業ペースに差が生じるが、1時間あたり100語～300語程度のアノテーションが可能である。以下の表5にこれまでの作業における番号付与作業量を示す。

番号付与作業量

表5 番号付与作業量

付与対象	作業内容	作業量
短単位	番号選択（自立語）	全短単位の47%
	新規番号追加（自立語）	全短単位の5%
長単位 （短単位の 15%程度）	番号選択	長単位の14%
	新規番号追加	長単位の76%

短単位へのアノテーション作業の内訳は、全短単位の47%において番号選択、5%で新規番号追加である。両作業をあわせ、52%の短単位に番号付与を行っている。長単位は、短単位の31%が番号付与作業対象となっている。

なお、長単位は全短単位の15%程度に付与作業を行うこととなる。長単位におけるアノテーション作業の内訳は、14%で番号選択、76%で新規番号追加となり、新規番号追加作業の割合が高い。

3.2 作業における問題点等

作業者から質問のある点については、作業者間に揺れが生じることや、作業結果に影響のあることが予想される。現在までの作業では、作業者とQAを共有しており、作業者の記入した質問に、発表者が回答している。ここでは、作業者とのQAに見られる傾向から、作業において問題となる可能性のある点について報告する。

複数の読みが可能な場合

文脈上、複数の読みが可能な場合、付与する1つの番号をいずれと定めるのかを作業者

個人の判断にゆだねるため、作業者によって同様の文脈でも揺れの生じる可能性が考えられる。

長単位の文法的分類

助動詞扱いになっている場合をはじめ、どの部分が主となる複合語であるのかの判断にあたり、長単位を、体・用・相のいずれに分類するのかが問題となりがちである。意味の番号は等しい場合でも、作業者によって文法的な分類が異なってくる可能性がある。また、UniDic-分類語彙表対応データの部分的な不備や不足などの影響による作業者の迷いや揺れも散見される。これらは作業の進行により、付与作業済みデータを用いた UniDic-分類語彙表対応データの補填や拡充が可能となることが期待され、今後解消され得る。

4. 進捗

これまで（2016年10月号付与済みデータ（2016年10月～12月）月～12月）に付与作業の完了したデータは以下（表6）である。

表6 番号付与済みデータ（2016年10月～12月）

集合	短単位	付与数	選択	追加等
PN	50837	25524	24005	3074
その他	13656	6823	6505	318
総計	64493	32347	30510	3392

作業者によって追加等作業数に差があるため、現在はPNとその他に違いが見られるが、今後作業者間の揺れなどの確認を進め、整理と統一を行う予定である。

PNに付与された分類語彙表番号の類は、体の類(1)が71%、用の類(2)が20%、相の類(3)が8%、その他(4)が1%の割合となっている(図3)。なお、PNの他の集合でも類の割合は概ね等しい結果となる。




図3 これまでに付与した分類語彙表番号の類 (PN)

次に、PNに付与された上位頻度(1.0%以上)の番号を以下の表7に示す。アノテーションしたサンプルが新聞であることから、数記号が1割に及ぶ。また、地名や人間や団体の

活動や存在に関する分類番号が多い。

表7 上位頻度付与番号 (PN, 1.0%以上)

番号	頻度		例
1.1960	2665	10.4%	数記号
2.3430	1108	4.3%	行為・活動 (する)
1.2590	838	3.3%	固有地名
2.1200	616	2.4%	存在 (ある)
1.2000	422	1.7%	人間
1.1962	360	1.4%	助数接辞
1.1000	346	1.4%	事柄
1.2760	263	1.0%	同盟・団体
3.1010	251	1.0%	こそあど・他
付与済み PN	25510	100.0%	

5. 作業結果の利活用：新聞に見られる感情表現

これまでに付与作業の完了したデータを用いた調査例を示す。調査には、2016年10月から12月に分類語彙表番号を付与したPNの一部のデータを用いた (表6)。以下では、意味分類のグループを検索した調査結果例として、新聞に見られる感情表現 (体・用・相) の分布について報告する。

一般に客観的な記述が多いと考えられる新聞には、感情に関する表現は少ないことが予想される。それでは、新聞において感情に関する言及は、どのような場合にどのようなされるのであろうか。また、どのような感情が言及されるのか。ここでは、感情表現の出現する文脈 (新聞の面情報) を見るとともに、記述された感情がポジティブ・ネガティブのどちらに多いのかを調べることで、感情に関する体・用・相の類の使い分けを見てみたい。

分類語彙表番号付与済みデータ (PNの一部; 表6参照) を用い、感情に関する分類の付与された短単位を調査した。「.30」は「心」の中項目であり、「.301」に分類される項目は、感情に関連している。また、体 (1.301)・用 (2.301)・相 (3.301) のそれぞれの項目がある。以下、調査結果を類別の頻度で示す (表8)。

新聞においては、体の類が用いられやすく相の類は用いられにくい¹ことが予測されるが、相の類の頻度が最も高い結果となっている。それでは、新聞に用いられる感情表現はどのようなものか、ネガティブ・ポジティブの観点と出現文脈を見るため、以下で類別に用例を確認する。

¹ PNの品詞比率 (token) を見ると、名詞が46.5% (BCCWJ全体は35.0%, 以下同様に示す)、形容詞が1.0% (1.5%), 副詞が0.8% (1.5%) などであり、新聞は体の類にあたる名詞の比率が高く、相の類にあたる形容詞や副詞の比率が低い傾向にある。

表 8 感情に関する表現

分類項目		1. 体の類	2. 用の類	3. 相の類	計
*. 3011	活動-心-快・喜び	2	13	17	32
*. 3012	活動-心-恐れ・怒り・悔しさ	5	2	5	12
*. 3013	活動-心-安心・焦燥・満足	16	4	12	32
*. 3014	活動-心-苦悩・悲哀	4	4	4	12
計		27	23	38	88

5.1 体の類

体の類は、「エンジョイ」「不快」「怒り」「安心」などが含まれる。

ポジティブ・ネガティブどちらも含む 1.3013 が最も多く、この内訳は、「不安（7件）」、「満足（3件）」、「心配（2件）」、「安心」、「楽」などであり、「不安」や「心配」というネガティブな意味の語彙が含まれている。用例は、(1) が総合面、(2) が国際面、(3) がスポーツ面の記事であるが、ニュース記事に用いられる傾向が見て取れる。新聞に現れる感情語は、ネガティブな意味の語彙である場合、漢語であることが多く、ニュース記事に体の類として現れる傾向があるといえる。

(1) 開票まで不安は去らなかつた。結果は、2位を八千票以上引き離し、2万票弱を獲得する圧勝。(サンプル ID : PN1b_00005, 毎日新聞・総合, 下線は著者による。以下同様。)

(2) 失業者の増加などが原因とみられ、徴収が困難になれば保険財政の悪化につながる恐れがある。(サンプル ID : PN3g_00001, 西日本新聞・総合国際)

(3) 「中国の人口十三億人はいいいけど、市場としては未知数。スポンサーには期待と同じくらい不安があるんだ」(サンプル ID : PN1a_00008, 朝日新聞・スポーツ)

5.2 用の類

用の類は、「すっきりする」「恐れる」「ほっとする」「くよくよする」などが含まれる。具体的には、2.3011 が半数以上を占めている。内訳としても、「楽しむ（11件）」が大半であり、このほかに「喜ぶ」などがある。以下に例示した(4)は経済面の記事だが、商品紹介部分であった。(5)は生活面の記事である。用の類は、ニュース記事ではない面において、ポジティブな感情を表す際に用いられる傾向がある。

(4) 今春、摘んだ茶葉を使用し、熟成したお茶本来のコクが楽しめるという。五百ミリ・リットルペットボトル入り。(サンプル ID : PN1c_00004, 読売新聞・経済)

(5) 前向きな気持ちで1人のお正月を楽しめば、きっと運も向いてくるのでは？ 楽しいプランのあれこれを提案したい。(サンプル ID : PN3b_00004, 毎日新聞・生活)

5.3 相の類

形容詞や副詞を含む相の類は、「うれしい」「悲しい」「ドキドキ」「しみり」などが含まれる。相の類に分類された表現は体・用の類よりも使用頻度が高く（表 8）、新聞においても感情に関する表現として最も使われやすいといえる。

具体的には、3.3011（快・喜び）が最も多い。また、ポジティブ・ネガティブのどちらをも含む 3.3013（安心・焦燥・満足）の内訳は、「冷静（3件）」、「気楽（2件）」のほか、「ホッと」、「楽」、「気軽」、「伸びやか」など、概ねポジティブな意味の語彙であった。新聞で用いられる相の類は、ポジティブな感情に関する表現の現れる割合が高い傾向があると考えられる。

用例の（6）は演劇の紹介文、（7）は社説、（8）は家庭面の記事であり、用の類同様に、感情に関する表現は、ニュース記事ではない面に現れている傾向が見られた。

（6）もともとの時代劇ファンには、少し癖のある芝居が鼻につくかもしれない。だが、そういう点を割り引いても、この作品は面白い。（サンプル ID：PN5c_00002，読売新聞・エンターテインメント）

（7）入賞した作文や絵を見ていると、ロケットに乗って宇宙旅行をしたり、宇宙人と対話する近未来の夢が語られ、楽しい気分になってくる。（サンプル ID：PN2g_00004，西日本新聞・オピニオン（社説））

（8）結局、家庭訪問は受けた。内容は「元気です。おもしろい子ですね」程度。だが、学校での子どもの様子はわからないから、それだけでうれしい。（サンプル ID：PN1a_00002，朝日新聞・家庭）

5.4 新聞に見る感情表現のまとめ

新聞に見られる感情表現は、相・体・用の類の順で用いられており、一般に新聞の特徴として考えられる名詞の多さや漢語の多さに反し、相の類の使用頻度が高いという特徴がある。用例を見ると、相と用、体の類で、感情表現の出現文脈が異なる傾向にあることがわかる。相と用の類は紹介文や生活関連記事で用いられており、体の類はニュース記事に用いられているという傾向があった。

よって、新聞に用いられる感情表現は、相と用の類が主にポジティブな感情に関してどちらかというやわらかい語彙の多い文脈で用いられ、体の類がネガティブな感情に関してどちらかという硬い語彙の多い文脈で用いられていると考えられる。

6. まとめ

本稿では、『現代日本語書き言葉均衡コーパス（BCCWJ）』に分類語彙表番号を付与する作業について、アノテーション基準と現在までの作業状況を報告した。現在まで、月に 2 万単位（短単位）ほどのアノテーションが進行中である。

これらのデータ整備によって、BCCWJ が意味的な情報によって検索可能となり、従来用例の収集が困難であった意味上のグループに応じた分類を要する研究における新たな可能性が期待される。本稿では、品詞や特定の語彙ではなく、感情という意味上のグループを

用いて、新聞で感情に関する表現がどのように用いられているのかという調査を試みた。

この他にも、たとえば比喩研究では、隠喩のように明示された比喩指標のない用例を収集するために、結合する要素のずれを判定する必要がある。文脈と意味分類を対照することで、このような比喩の用例は格段に収集しやすくなるはずである。また、本作業によって、未知語をはじめとする分類語彙表にない語への番号付与が進んでいるほか、UniDic-分類語彙表対応データの補完となり得る番号付与はもちろん、分類語彙表にない番号の新設が要される場合もあり、既存のデータの拡充も可能となる。

今後、本データを利用した語義の曖昧性解消を自然言語処理研究者により進められることを望む。また、分類語彙表代表義データ（山崎・柏野 2017）、UniDic 語彙素番号-分類語彙表番号対応表（近藤・田中 2017）、『国語研日本語ウェブコーパス』に基づく word2vec モデル（浅原・岡 2017）、『日本語歴史コーパス』に対する分類語彙表番号アノテーションの他、『日本語歴史コーパス』平安時代編の相の類についての分類語彙表番号アノテーション（池上 2017）や、L1 学習者作文コーパスに対する分類語彙表番号アノテーションが進められている。これらのデータに基づく、通時適応モデルの開発や作文支援システムの構築も期待される。

謝 辞

本研究の一部は国立国語研究所コーパス開発センター共同研究プロジェクト「コーパスアノテーションの拡張・統合・自動化に関する基礎研究」・言語変化研究領域共同研究プロジェクト「通時コーパスの構築と日本語史研究の新展開」によるものである。

文 献

- F. Bond, T. Baldwin, R. Fothergill, and K. Uchimoto. 2012. "Japanese SemCor: A Sense-tagged Corpus of Japanese" in The 6th International Conference of the Global WordNet Association (GWC-2012)
- K. Maekawa, M. Yamazaki, T. Ogiso, T. Maruyama, H. Ogura, W. Kashino, H. Koiso, M. Yamaguchi, M. Tanaka and Y. Den, 2014. "Balanced corpus of contemporary written Japanese", Language Resources and Evaluation, 48:2, 345-371.
- M. Okumura, K. Shirai, K. Komiya and H. Yokono. 2011. "On SemEval-2010 Japanese WSD Task", 『自然言語処理』 18(3), 293-307.
- 浅原正幸・岡照晃. 2017. 「NWJC2vec: 『国語研日本語ウェブコーパス』に基づく単語の分散表現データ」, 言語処理学会第 23 回年次大会発表論文集.
- 池上尚. 2017. 「『日本語歴史コーパス 平安時代編』出現形容詞に対する古典分類語彙表番号アノテーション」, 言語処理学会第 23 回年次大会発表論文集.
- 小木曾智信・中村壮範. 2014. 「『現代日本語書き言葉均衡コーパス』形態論情報アノテーション支援システム的设计・実装・運用」, 『自然言語処理』 21(2), 301-332.
- 近藤明日子・田中牧郎. 2017. 「分類語彙表・UniDic 見出し対応表の構築 —コーパスへの網羅的・系統的な語義情報付与を目指して—」, 言語処理学会第 23 回年次大会発表論文集.
- 山崎誠・柏野和佳子. 2017. 「『分類語彙表』の多義語に対する代表義情報のアノテーション」, 言語処理学会第 23 回年次大会発表論文集.
- 国立国語研究所(編). 2004. 『分類語彙表増補改訂版データベース』
http://pj.ninjal.ac.jp/corpus_center/archive.html#bunruiddb