『現代日本語書き言葉均衡コーパス』における書籍 サンプルの多様性

著者	柏野 和佳子, 丸山 岳彦, 秋元 祐哉, 稲益 佐知子, 佐野 大樹, 田中 弥生, 山崎 誠				
ページ	1-36				
発行年	2008-03-21				
シリーズ	国立国語研究所内部報告書 ; LR-CCG-07-02				
URL	http://doi.org/10.15084/00002841				

『現代日本語書き言葉均衡コーパス』における 書籍サンプルの多様性

柏野 和佳子・丸山 岳彦・秋元 祐哉・稲益 佐知子・佐野 大樹・田中 弥生・山崎 誠

平成20年3月 大規模汎用日本語データベースの構築とその活用に関する調査研究 ©2008 独立行政法人国立国語研究所 国立国語研究所内部報告書(LR-CCG-07-02)

『現代日本語書き言葉均衡コーパス』 における書籍サンプルの**多様性**

平成20年3月

大規模汎用日本語データベースの構築とその活用に関する調査研究 © 2008 独立行政法人国立国語研究所

目次

はじめに 1			
第 1 章 BCCWJ のサンプル作成の概要			
1.1 BCCWJ の構成			
1.2 サンプルの長さの設計 3			
1.3 紙面におけるサンプリング対象部分の指定 3			
第2章 書籍サンプルの抽出方法の概要			
2.1 生産実態サブコーパスの設計 5			
2.2 流通実態サブコーパスの設計 5			
2.3 NDC の層別によるサンプリング 5			
第3章 書籍サンプルの多様性			
3.1 多様性をとらえる観点 8			
3.2 書籍サンプルの具体例 (
3. 2. 1 NDC 分類と文章の種類が異なる例 9			
3.2.2 形式に特徴のある例 12			
3.2.3 場面設定(時代・場所)に特徴のある例19			
3.2.4 視点, 人称に特徴のある例 20			
3.2.5 論理構成・紙面構成に特徴のある例 23			
3.2.6 文末・調子に特徴のある例 26			
3.2.7 文長に特徴のある例 27			
3.2.8 語彙や表記に特徴のある例 28			
第4章 多様性の分析と文体論研究との接点31			
第5章 おわりに 32			
謝辞 33			
謝辞			

はじめに

国立国語研究所では現在、『現代日本語書き言葉均衡コーパス (Balanced Corpus of Contemporary Written Japanese; 以下 BCCWJ と記す)』の構築を進めている。構築期間は 2006~2010 年度であり、現在、サンプリング・電子化・著作権処理・形態論情報付与など の作業が進められている。本報告書は、このうちのサンプリング作業に関わる研究報告で ある。

BCCWJ のうち、「生産実態(出版)サブコーパス」に含まれる書籍の取得目標サンプル数 は、12,604 である。このサンプル数は、統計的な言語調査を可能にするために、生産実態 サブコーパスの母集団の総文字数推計によって算出したものである(詳細は、丸山・秋元 (2007)を参照)。これにあわせ、「流通実態(図書館)サブコーパス」の取得目標サンプル 数も,12,604 である(詳細は,丸山・秋元(2008)を参照)。5 年計画のうちの 2 年が経過し た現在、両サブコーパスの書籍のサンプリングは、それぞれ目標値の半数を超え、あわせ て約13,000 サンプルが取得できている。

本コーパスの目標の一つは、現代日本語書き言葉の多様な姿をとらえることである。本 報告書では、コーパス構築途中の現段階において、書籍について、実際にどのように多様 なサンプルを取得しつつあるのかを報告する¹。

2007 年度のサンプリング作業は、国立国語研究所研究開発部門言語資源グループのサン プリング班に所属する, 山崎誠, 柏野和佳子, 丸山岳彦, 佐野大樹, 秋元祐哉, 稲益佐知子, 田中弥生が中心となり実施した。また,安部達雄,市原乃奈,遠藤直子,大矢内夢子,久古直, 田口久美子, 立花幸子, 趙恩英, 長門美帆子, 服部紀子, 三浦智子, 保田祥, 吉田奈央らが, こ れを助けた。

¹ 本報告書は,生産実態サブコーパスを中心に報告した柏野ほか(2008a),流通実態サブコーパスもあわせ て報告した柏野ほか(2008b)をもとにして、さらに具体例を追加し、2年間で集積した書籍サンプルの概観 を報告するものである。

第1章 BCCWJのサンプル作成の概要

1.1 BCCWJ の構成

BCCWJ は全体で1億語を超す規模を持ち、図1に示す3つのサブコーパス (SC) から構成される。本報告書でとりあげる書籍サンプルは、このうちの「生産実態(出版) サブコーパス」と「流通実態(図書館) サブコーパス」を構築するためのものである。

生産実態(出版)SC

書籍, 雑誌, 新聞 出版年:2001-2005年 約3,500万語 固定長+可変長 流通実態(図書館)SC

書籍 出版年:1986-2005年 約3,000万語 固定長+可変長

非母集団(特定目的)SC

白書, 国会会議録, ベストセラー, 教科書, 法律, Yahoo!知恵袋・・・

出版·収録年:1976-2005年, 2001-2005年 約3,500万語

可変長(一部, 固定長+可変長)

図 1 BCCWJ の構成

1.2 サンプルの長さの設計

統計的な言語調査にも、幅広いテキスト研究にも利用できるよう、収録するサンプルの長さを2種類設計した。一つは、1サンプルの長さを1,000字とする「固定長サンプル」である。母集団からの抽出比が統計的な意味を持ち、語彙表や漢字表などの作成に適する。もう一つは1サンプルの長さを固定せず、章や節などの文章のまとまりを1サンプルとする「可変長サンプル」である。テキストの論理構造の把握やテキスト内での役割を持った要素の分析などに適する。

1.3 紙面におけるサンプリング対象部分の指定

均質なサンプリングを行うために、紙面におけるサンプリング対象部分を定める作業原則を設けている(詳細は、丸山・秋元 2008)。書籍サンプルに関しての作業原則の概要は次のとおりである。また、サンプル範囲指定例を図 2 に示す。対象外部分には×印をつけている。

(1) 冊としての形態からの選択

- ○文章表現が主となる、序文、本文、あとがきが対象。
- ●とびら,凡例,目次,参考文献,索引,奥付などは対象外。

(2) ページ上の版面からの選択

- ○文章表現が主となる部分が対象。
- ●文章表現が主とならない,図,絵,漫画,写真は対象外。
- ●一次元の文字列にならない表も, 原則対象外。
- ○図表・写真のキャプション部分は原則対象。

(3) 文字種による選択

- ○現代日本語の文字が対象。
- ●次のものがブロック単位である場合は対象外。
 - a. 非日本語(英語, フランス語, 中国語等)
 - b. 非現代日本語 (明治元年よりも前 (江戸時代以前) に書かれた日本語)
 - c. 非言語(数式, 化学式等)
- ○以上のものが、タイトルや、対象部分のインラインにある場合は対象。




図2 サンプル範囲指定の例

第2章 書籍サンプルの抽出方法の概要

詳細は,丸山・秋元(2007),丸山・秋元(2008)で述べているため,ここでは簡単に概要を記す。

2.1 生産実態サブコーパスの設計

生産実態サブコーパスは、書き言葉が生産される局面に着目して母集団を定義するものである。対象は、2001~2005年に出版された全ての書籍、雑誌、新聞である。統計的な言語調査を行うために必要なサンプルサイズとして1,000万語を想定し、母集団から1,000万語分の固定長サンプルを抽出することにした。各媒体から取得するサンプル数は、各母集団の総文字数を推計し、その比率を割り当てる。5年間に出版された各媒体の総文字数を推計したところ、書籍が約485億字、雑誌が約105億字、新聞が約64億字という結果を得た(丸山・秋元2007)。ここから、書籍74%、雑誌16%、新聞10%、という構成比率を定めた。固定長サンプル1,000万語(1,700万字と推定)を得るための必要数として、書籍12,604サンプル、雑誌2,730サンプル、新聞1,700サンプルという数を算出した。固定長サンプルと同時に可変長サンプルも抽出するため、生産実態サブコーパス全体の規模は、約3,500万語の見積もりになる。

2.2 流通実態サブコーパスの設計

流通実態サブコーパスは、書き言葉が世の中に流通しているありさまを、図書館における書籍の所蔵状況によって近似的に把握しようとするものである。流通実態サブコーパスの母集団は、生産実態サブコーパスの書籍の母集団である約 485 億字になるべく近似させるために、「都内公立図書館のうち、13 自治体以上で共通して所蔵している書籍」と定義した。そこから、生産実態サブコーパスと同数の12,604 の固定長サンプル、および、可変長サンプルを抽出する。流通実態サブコーパス全体の規模は、約 3,000 万語の見積もりである。

2.3 NDC の層別によるサンプリング

生産実態,流通実態サブコーパスともに,書籍サンプルの多様性を確保するために,国立国会図書館で付与された「日本十進分類法(NDC)」の1次区分の10分類(0. 総記,1. 哲学,2. 歴史,3. 社会科学,4. 自然科学,5. 技術工学,6. 産業,7. 芸術,8. 言語,9. 文学)に,「記録なし」を加えた11分類の層を利用して,サンプリングを実施している。NDCごとに抽出するサンプル数は,生産実態サブコーパス,流通実態サブコーパス,それぞ

れの母集団において 11 分類各層に含まれる推計総文字数の比例割当により算出している。合計 12,604 サンプルを取得する際の NDC 別のサンプル数とその割合を,図3と図4に示す。サブコーパス間で数字に違いはあるが,いずれも,[3. 社会科学]と[9. 文学]とが多い。表 1 には,取得する書籍の例として,生産実態サブコーパスから取得するサンプル例を NDC 別に 2 例ずつ示す。




図3 生産実態サブコーパスにおける取得サンプル数の NDC 別内訳 (サンプル数およびその割合(%))




図 4 流通実態サブコーパスにおける取得サンプル数の NDC 別内訳 (サンプル数およびその割合(%))

表1 NDC 別に取得する書籍の例(生産実態サブコーパスの例)

NDC	著者	出版年	書名	出版社
007	秦森桂 著	2004	文系プログラマー奮戦記 同人ゲーム&ソフトハウスのトンデモ世界	工学社
070	石澤靖治 著	2001	大統領とメディア	文藝春秋
134	ヘーゲル 著;長谷川宏 訳	2003	歴史哲学講義 下	岩波書店
188	梅原猛著	2004	法然の哀しみ 上	小学館
210	岩田明著	2004	消えたシュメール王朝と古代日本の謎	学習研究社
290	内田芳明 著	2001	風景の発見	朝日新聞社
304	櫻井よしこ 著	2001	迷走日本の原点	新潮社
369	全国訪問看護事業協会 編	2004	訪問看護実務相談Q&A	中央法規出版
451	嶋村克, 山内豊太郎 著	2002	天気の不思議がわかる本	廣済堂出版
499	荒川博仁 著; ヘルス・システム研究所 編	2004	薬と病気	ヘルス・システム研究所
547	水澤純一 著	2005	情報通信ネットワーク入門	培風館
537	細川幹夫 著	2002	トヨタ成長のカギ 創業期の人間関係	近代文芸社
610	桝潟俊子, 松村和則編	2002	食・農・からだの社会学	新曜社
673	大久保一彦 著	2002	誰も言わなかった!飲食店成功の秘密	フォレスト出版
720	石本正 著	2001	絵をかくよろこび	新潮社
783	鈴木春祥 著	2003	甲子園に賭ける	新潟日報事業社
816	清水義範 著	2004	大人のための文章教室	講談社
817	遠藤織枝 他著	2004	戦時中の話しことば ラジオドラマ台本から	ひつじ書房
913	司馬遼太郎 著	2004	坂の上の雲 6	文藝春秋
933	ダン・ブラウン 著;越前敏弥 訳	2005	ダ・ヴィンチ・コード	角川書店

NDC は、そもそもは図書館の資料を分類するための指標であり、書籍の主題や内容、形式に基づいて、1次区分で10種、2次区分でさらに10種、3次区分でさらに10種と、階層的で詳細な分類が施されている。さらに、国立国会図書館では分類の統一性を図るために分類基準が明文化されており、書籍を客観的に分類する上で有用な情報である。NDCの層別にサンプリングすることにより、集積される「書籍」の書き言葉の多様性は、これまでにない程度で確保されると言ってよいだろう。

第3章 書籍サンプルの多様性

3.1 多様性をとらえる観点

書籍における書き言葉の多様性をとらえるための観点としては、例えば、表2のようなものが考えられる。

表 2 書き言葉の多様性をとらえるための観点

(1) NDC 分類の 1~3 次区分: (本の内容や主題)

(2) **種類**: 小説 (物語), 手紙, 日記, 論説文, 紀行文, ルポルタージュ, 韻文, 翻訳, 戯曲 (シナリオ), マニュアル, ガイドブック, 辞書, 事典

(3) **形式**: 座談,対談,インタビュー,パネル討論,講演,会話形式,往復書簡形式,リレー執筆形式,Q&A 形式,投稿形式,辞書・事典形式,見本・用例形式

(4) **場面設定**: 時代(現代,江戸時代,平安時代,未来),場所(日本国内,国外,仮想世界)

(5) **著者の属性**²: 年代, 性別, 出身地 (6) **対象読者の属性**: 年代, 性別, 好み

(7) 視点: 人称, 人間以外

(8) 硬軟: 難解, 堅い, 平易, くだけている

(9) **論理構成・紙面構成**: 章節, キャプション, 注記, コラム, 引用, ブロック割り構成, 図説, カタログ的構成

(10) 文体: 口語文, 文語文, 候文, 和漢混淆文, 条文

(11) **文末・調子**: デスマス調, デアル調, ゴザイマス調, 体言止め, 語りかけ口 調, 演説調

(12) 文長: 長短

(13) **修辞・比喩**: 種類, 使い方 (14) **オノマトペ**: 種類, 使い方

(15) **語彙**: 語彙の選択,特に位相の異なる語彙の選択(古語,俗語,幼児語,方言など),語種の選択

(16) **表記**: 文字種の選択(漢字,カタカナ,ひらがな),表外漢字の使用,仮名遣い(現代仮名遣い,歴史的仮名遣い),ローマ字や外国語の使用

(17) 記号類: 句読点,記号類の使い方

(18) **ルビ・注記**: 使用量(多少),使用目的(読み,原語,別の言い換え語,注釈, 参考文献)

² サンプルからは判断できないことが多く、簡単にはわからないものであるが、観点の一つに成り得るものであろう。(6)も同様。

表 2 に示したこれらの観点は、サンプリングの過程で経験的に得られたものであり、 用語の吟味、体系的な整理が必要であることは言うまでもない。たとえば、「フィクション」「ノンフィクション」で区別される観点もあれば、そうでないものもある。多様性をとらえる観点・指標を総合的に体系化する作業は、コーパスを有効に利用するために必要不可欠なものであり、今後の大きな課題の一つである。

3.2 書籍サンプルの具体例


以下,表2に示した観点を順に用いながら,書籍サンプルの具体例を示し,多様性のあり方を示す。1サンプルに複数の観点をもつものは当然多くあるが,注目する観点ごとに例を示す。「硬軟」「文体」などの多様性は,特に独立した節をたてて示さないが,以下に示すサンプル全般にその多様性も十分観察される。例は,書籍名および,そのサンプルの一部分のテキストとサンプル紙面とで示す(適宜,一方の省略もあり)。書籍名につけた()内は,書籍に付与されたNDC(3桁)とその分類名である。

3.2.1 NDC 分類と文章の種類が異なる例

基本的には、文章の主題や内容の分類にはNDC分類が使えるが、NDC分類は書籍をトップダウン的に一意に分類するものであるため、注意が必要になる。たとえば、文章の種類でいえば、例1は戯曲、例2はルポルタージュ、例3は日記の例である。

例1:梅原猛『梅原猛著作集 19』小学館 (081:叢書,全集,選集の日本語)

(照手姫, 男衆や召使いを呼んで指図する。しばらくして, 国府の役人登場。) 国府の役人 頼もう, 頼もう。国守様が介殿とともにおいでじゃ。 小糸 よくおいで下さいました。



例 2: 桝田武宗『「社会の窓」から何が見えるのか』 桜桃書房 (049: 一般論文集. 一般講演集の雑著)

それで…、本題の〈カフェ・パタゴニア〉なんだけど。本物のパタゴニアに較べると随分格が下がるんですね。カフェというくらいだから、サ店ですよ。サ店には違いないけれども二十四時間営業だし、トースト食べ放題だし、終電が出たあとから始発が出るまでの間は、眠っていても文句を言われないっていう…。こんな程度じゃ太刀打ちできない…ですよね。

確かに、〈カフェ・パタゴニア〉なんて章題をつけて気を惹こうとした僕は、「ミミッコイ」って言われても仕方ないと思います。「セコイ」でも仕方ありません。しかし、多少弁解をさせて頂きますと、これから書こうとしている〈カフェ・パタゴニア〉ての、実言うと並のサ店だなんて思ったら大間違いなんですよ。なんちゃっテへへ。とか言いつつなんとか気を惹こうなんて、姑息だね。アー。ヤダヤダァダナ姿の洗髪って、よく分かんないでしょうけど、深く考えないで下さい。別に意味はないんです。

時間営業だし、トースト食べ放題だし、終電が出たあとから始発が出るまでの間は、眠っていて を開始するタイプの人間なんです。 下さい。別に意味はないんです。 姑息だね。アー。ヤダヤダアダナ姿の洗髪って、 て思ったら大間違いなんですよ。なんちゃっテへへへ。とか言いつつなんとか気を惹こうなんて、 頂きますと、これから書こうとしている〈カフェ・パタゴニア〉ての、実言うと並のサ店だなん も文句を言われないっていう……。こんな程度じゃ太刀打ちできない……ですよね。 が下がるんですね。カフェというくらいだから、サ店ですよ。サ店には違いないけれども二十四 間にか、その間三〇年弱の時間が経っているんですから「いつの間にか」っていう表現は適切じ と同じように(と言っても、果てしなく格下ですけど)、昼間は活動しないで深夜になると活動 て言われても仕方ないと思います。「セコイ」でも仕方ありません。しかし、多少弁解をさせて ゃないかもしれないけど、他に思いつかないからこのまま先を急ぎますが、ポップ・アート調の インテリアに変わっていてMTVなんかも放送されてるような店になってたんです。 確かに、ヘカフェ・パタゴニアンなんて章題をつけて気を惹こうとした僕は、「ミミッコイ」っ ある夜、多分午前三時頃だったと記憶してますが、ふと、「羅王」っていうサ店に入ったんで 僕は、エドガー・アラン・ポーだとかメルヴィルだとかローレン・アイズリーだとかいう方々 僕が高校生だった頃は名曲喫茶店みたいな造りの内装だったんですけれど、いつの 本題の〈カフェ・パタゴニア〉なんだけど。本物のパタゴニアに較べると随分格 よく分かんないでしょうけど、深く考えないで SOCIAL WINDOW

例3:中野翠『へなへな日記』毎日新聞社(049:一般論文集.一般講演集の雑著)

茫然と一週間が過ぎた。

先週引き込んだ風邪がなかなか治らない。たいした熱も出ていないのに何をするのも億劫。もうひとつ力がこもらない。

「余は大儀じゃ」

という言葉がポワーッと浮かんでくる。大儀なんて言葉、何年ぶりだろう。こういう半死語のようなもの、私は妙に好きだなあ。自分の中から急に飛び出してくると、「おっ」と思う。

この『サンデー毎日』が店頭に並ぶ頃には貴乃花はどうなっているのだろう(今日はまだ大相撲初場所五日目)。

早くも三敗を喫していて、その取り口を見ていると「大儀」という言葉がぴったりだ。相撲を取っている間、すでにもう疲れている感じである。もしかすると 貴乃花は私たちが思っている以上にどこか体が悪いのかもしれない。



戯曲, ルポルタージュ, 日記はいずれも NDC9 番台の 3 次区分にある分類名であるが, 以上の 3 例は, いずれもそこに分類されていない。本が全集である点や, 講演集の類で あるという面が優先された NDC が付与されている。このように, 時には NDC 分類とは別に「種類」という観点が必要になるサンプルがある。

3.2.2 形式に特徴のある例

続いて、形式に特徴のある例を示す。表 2 にあげたうちから、対談、会話形式、往復書簡形式、Q&A 形式、投稿形式、辞書・事典形式、見本・用例形式の例を順に示す。例 4 は、対談の例である。例 5 は会話形式の例である。例 5 は、実際の対話ではなく、発話ごとに著者が異なるわけではない。

例 4:鶴見俊輔『未来におきたいものは 鶴見俊輔対談集』晶文社 (304:社会科学の 論文集. 評論集. 講演集)

大江 おもしろいですね。僕は以前柳田国男から、昔話の語りはじめの「とんとある話。あったか無かったかは知らねども、昔のことなれば無かったこともあったにして聴かねばならぬ。」といって、聞き手が「うん!」といって始まる、というのを小説に取り入れたことがあります。『M/Tと森のフシギの物語』(岩波書店)というのですが。

鶴見 耄碌した人たちの話や何かを補正しながら聞いていく。これが悪く政治的 に使われると、玉虫色ってことになる。ひじょうに悪辣な仕方で使われるんだけ れども、しかし、いろいろな古老の話や何かを聞いていく、子供の話や何かは、 揺すぶりながら、意味の幅を変えながら聞いていく。それが明治以前の習慣とし てあったというわけです




例 5:野々村花衣『感性ちゃんと頭脳君の対話』文芸社 (304:社会科学の論文集.評 論集.講演集)

感性 そういうことか。分かったわ。つまり、「肌の表面に何を塗っても、その物質がバリアゾーンを通過して有棘細胞層や基底細胞層にまで到達するわけがない」ってことなのね?

頭脳 そうだよ。そんなことは不可能なんだよ。もしもそれが可能だとしたら, 肌の防衛網が機能していないことるから, おそらくそういう人は生きていけない だろうね。

感性 物質のサイズを小さく, 細かくしてもダメなの?

頭脳 ダメだよ。無理だね。バリアゾーンが健全な場合には,水の分子一個です ら通さないんだ。



次の例 6 は、小説であるが、その形式を「往復書簡」にしているものである。引用が 少し長くなるが、一往復分を以下に例示する。

例 6: 恩田陸『象と耳鳴り』祥伝社 (913:日本文学の小説. 物語)

謹啓

風薫る季節となりましたが、お元気でいらっしゃいますでしょうか。 私はとても元気です。ようやく生活にリズムが出来てきて身辺が落ち着きました。 東京生まれで東京育ちの私(しかも、高校時代まで山手線以外乗ったことがなく、天然ボケという点では友人の間でもピカーと言われていたこの私が!)が、よりによって新聞記者などという職業につき、初めて家を離れ、しかも最初の赴任先が遠い北国ということで、親も友人も心配していましたし、何より本人が面くらっていましたが、ようやく慣れてきて周囲を見る余裕が出来てきました。こちらの支局はこぢんまりとしていて、とっても家庭的です。支局全体が一つの家族みたい。先輩方の配慮で、思ったよりも早くすんなり現場に溶け込むことができました。そこで、今マイブームとして、いつも切手を貼った封筒と便箋と万年筆を持ち歩き、待ち時間や空き時間が出来ると、お世話になった方々や、連絡する暇のなかった友人たちに手紙を書きまくっているのです。告白いたしますと、実は伯父様も、その犠牲者の一人となったわけです。今は、駅の喫茶店の中です。次の約束までの時間が少し空いてしまったので、風に揺れるケヤキの葉っぱを見ながらペンを走らせています。

それはさておき、こんなにご挨拶が遅くなってしまって申し訳ないのですが、 就職の時には伯父様にはたいへんお世話になりました。改めて深くお礼を申し上 げます。伯父様って本当にお顔が広いのですね。どこでも伯父様のお知り合いの 方が、よくして下さいます。それにすっかり甘えてしまっている自分が情けない のですが、右も左も分からず、迷惑ばかり掛けている今の状況を思うと、せいぜ い出世払いでいつかお返しできることを祈るばかりです。

それにしても、社会人で面白いですね。何をしても、どこに行っても、誰と話をしても今は面白いです。こうしてみると、学生ってなんて狭い世界で見栄ばかり張り合って、単調なつまらない世界だったんだろうと思います。自分では、今までずっと人見知りをする内向的な性格だと思っていたのですが、このような仕事について、自分の意外な一面を見たような(そしてこちらが本分だったような)気がしています。

いろいろご報告したいこと、気が付いたことがあるのですが、そろそろ移動時間なのでまたお手紙差し上げます。桃代伯母様によろしくお伝え下さい。ついでに、桃代伯母様からうちの母にあんまり心配しないように伝えていただけるともっと嬉しいです。

ではまた。

敬白

五月十一日 孝子

拝啓

お手紙拝見いたしました。潑剌とお仕事されているご様子、安心いたしました。 日々素直に感ずるままに吸収、成長していかれることをお祈りいたします。やが て失敗したり壁にぶつかったりすることもありましょうが、後悔することはあり ません。それが若さというものなのですから。また、今は手探りしつつ全力疾走 をしているのでしょうが、時には立ち止まって休息を取ることも大事です。老婆 心ながら、心の隅に留め置かれますよう。 この歳になると、貴方のような若い女性から手紙をいただくことなど皆無に近いゆえ、久しぶりに華やいだものを感じました。かえってこちらより御礼を申し上げたいほどです。


それにしても、我が妻桃代を始めとして、下条の家の女性陣の血が脈々と受け継がれていること、貴方の就職の話を聞いた時にまざまざと実感いたしました。だいたい下条の女性陣はみな一見箱入りで世間知らずと見えますが(失礼)、その本質的な部分での聡明さ、大胆さ、人間というものの本質を見抜く直感力は、長年人間の虚実を相手に仕事をしている私ですら敬服させられるものがあります。貴方を採用した会社の方もその辺りのところを感じられたのでありましょう。益々のご活躍をお祈りいたしております。

3

敬具

渋谷孝子様

五月十九日 関根多佳雄



続けて 4 例を示す。例 7 は Q&A 形式の例である。このような Q&A 形式は,解説書の類においてよく見られる。例 8 は投稿形式の例である。そして,例 9 は,辞書・事典形式,例 10 は見本・用例形式の例である。

例 7:中央青山監査法人,中央青山 PwC サステナビリティ研究所編『環境経営なるほど Q&A 環境先進企業へのヒント』経済社 (336:経済の経営管理)


Q3-7 マネジメントのための環境会計

マネジメントのための環境会計にはどんなものがありますか? それぞれの特徴を教えて下さい。

Α

■内部環境会計の意義

環境会計は、その目的により、外部報告目的の環境会計と内部管理目的の環境会計とに分類されています。わが国では環境省のガイドラインも推進力となって、多数の企業が環境会計を外部に公表するようになってきた一方、企業の意思決定に役立つ内部管理目的の環境会計の研究も進められています。



例 8: 久郷晴彦『よく効くアロエベラ 26 人の感動の体験』コスモトゥーワン (498: 医学の衛生学. 公衆衛生. 予防医学)

(2) あれほどひどかった頭痛と便秘がすっかり解消 山梨県・山川としえ(四九歳)

若いころからひどい頭痛と頑固な便秘で悩まされてきました。首から肩にかけてのあたりが、いつももやもやしていて、貧血症もありました。心臓もいつも、どきどきしたような感じで、立っているのがやっとでした。ですから、頭痛薬と便秘薬は毎日欠かせず、外出するときはカバンの中に薬を入れて持ち歩いていました。




例 9:日比野光敏『すしの事典』東京堂出版 (383:風俗習慣.民俗学.民族学の衣食住の習俗)

アガリ…お茶のこと。本来は、食べ始めに出す茶をデバナ(出花または出端?)、 食べ終わりの締めくくりに出す茶をアガリ(上がり)と呼び分けていたようだが、 今ではどれもアガリと呼ばれることが多い。

アニキ…古いすしダネやすし飯のこと。「ネタがアニィになる」などと使う。 アブ…マグロの腹部の脂身のこと。

イカダ…細巻きずしの盛り方のひとつ。切り分けた二切れを並行に置き、切り口側から他の二切れを揃えて立てかけるもの。以降は、その立てかけたものに順次立てかけてゆく。

イッチョウヅケ…コハダなどの小魚を、一尾まるごとすしダネにすること。




例 10: 伊宮伶『手紙の書き出し実例集』新典社 (816: 日本語の文章. 文体. 作文)

十月上旬

拝啓 十月の声を聞きますと、さすがに九月の陽気とは打って変わって秋らしく、上着が恋しくなって参ります。

拝啓 雨の多い九月でしたが、十月に入ると打って変わって晴天続き、ほっと しているところでございます。



3.2.3 場面設定(時代・場所)に特徴のある例

生産実態サブコーパスは 2001 年以降, 流通実態サブコーパスは 1986 年以降に出版された書籍が対象である。出版年で選定しているため, 原著の時代は古典まで遡る。しかしながら, 本コーパスでは, 明治元年以降に書かれたものを現代語としてサンプリング対象にしている。それより前の時代の文は現代語ではないとし, 原則, サンプリング対象にはしていない。ただし, 古典の現代語訳や注釈は対象にする。よって, 源氏物語の現代語訳や古今和歌集の注釈部分などは実際にサンプリングしている。

また,時代小説などに代表されるような,内容の時代設定が明治時代より前であっても,記された時代が明治元年以降であれば,当然サンプリングの対象である。さらに,訳文が現代日本語であればサンプリング対象となるところから,原著が外国のものもサンプリング対象にしている。

それらに SF 小説のようなものまで含め、時代や場面設定に特徴のあるものは、語彙や用法にその特徴が現れ、多種多様になる。先に示した例 1 は、時代設定が江戸時代のものであった。以下では、時代設定が平安時代である例と、外国の古典の訳例を示す。

例 11: 谷恒生『陰陽師阿倍晴明 3(終の章)』祥伝社 (913: 日本文学の小説,物語)

泥ノ法師は瓢をひきよせると、ぐびりと酒をふくんだ。

「それにしても、師輔邸のものものしさはいかぬわい。検非違使と源氏武者が一 戦交じえでもすれば、師輔卿は叛逆罪に問われかねぬわ」

熊野房魁深がにが虫を嚙みつぶしたような顔をつくった。




例 12:上村勝彦訳『マハーバーラタ 原典訳 3』筑摩書房 (929:中国文学のその他の東洋文学)

太陽は日の出と日没の間に、山の王、黄金の山である大山メールを右まわりにまわって敬意を表していた。(二) それを見て、ヴィンディヤ山は太陽に言った。「太陽よ、あなたがいつもメール山をまわるように、私に対しても右まわりの礼をして欲しい。(三)」

そう言われると、太陽は山の王に答えた。

「私は自分の意志であの山を右まわりにまわるのではない。この世界の創造者が、 私がそのようなコースをとるように指定したのだ。(四)」

それを聞くと、山は激しく怒って増大し、太陽と月の道を妨害しようとした。(五)



3.2.4 視点. 人称に特徴のある例

文章の多くは、三人称、もしくは一人称で書かれている。ここでは三人称以外の例をあげる。はじめに、一人称の例を2例示す。例13は「オイラは~」という文体である。同じ一人称の文章でも、例14のように、自分を愛称で呼びながら書き進めるものもある。「ほんじょは~」という、その「ほんじょ」が、著者「本上まなみ」の自称であることがわからないと、人称判断に迷いそうである。


論集. 講演集)

オイラ、実は腹の中じゃ何十万も買ったらタダじゃおかねえと思ってたんだけ ど、娘はじいっと考えて何万止まりだった。ただ、自分のを買った後に、

「お母さんにも、これ」

って、カミさんのベルトまで買いやんの。そんなもの、ついでにオイラにたかるんじやねえ。カミさんの方がオイラより財産持ってんだって。


そもそも、オイラたちが子供の時代は、メロンなんて幻で、バナナや饅頭でさえ病気するとかオヤジが死ぬとか、近所で葬式があったとか、特別なときしか食べられなかった。特別なものが当たり前にあるようになって、ガキがつけ上がりだしたんだな。当たり前のこともわからなくなってしまったんだ。



例 14:本上まなみ『ほんじょの虫干。』新潮社 (770:演劇)

サントリーニは小さい島で、まわりは全部あおい海。だから毎日ほんじょは、海をながめながらそこで捕れたタコエビイカサカナをぱくぱく食べて過ごしていたよ。三度のごはんを何より大事にしてるから、命をかけてお店をまわったけどどこも感激のおいしさ。例えば、何かを炭火で焼いてオリーブオイルと塩とレモンをさっとふっただけのシンプルな料理とか。でもそこからは、うまみがじわじわーっと出てくるの。ああ、おいしいってことは幸せってことだ。

あちこち食べた中で一番ほんじょが好きになったのは〈RED BEACH〉と呼ばれるところにあった洞窟レストラン。



数は多くはないが、中には二人称で書かれるものもある。たとえば、小説の二人称とは、野村(2005)によると、「日本語では、地の文において「あなた、君、お前」などによって主人公が指し示される人称空間を基調とするテクスト(小説・物語)がこれに相当することになる。ただし、書簡体小説はここから除外される。」と説明されている。たとえば、次の例15は、主人公が「おまえ」と呼ばれて、物語が展開している。

例 15: 重松清『疾走』角川書店 (913: 日本文学の小説. 物語)

警察に電話を入れるタイミングも難しい。早すぎると、おまえとみゆきが部屋を出る前に警官が駆けつける。遅すぎると、三島が踏み込んでくる。

七時二十分に警察に電話をする、とアカネは言った。そのあとすぐにフロント に電話をかける。ロビーにいるはずの三島をフロントのカウンターに呼びだして、 三島が電話に出る、その隙に、おまえとみゆきはロビーを抜けてホテルの外に出 る。

小説のほか、いわゆるゲーム本にも「あなたは~」の文体が見られる。例 16 はそのような例である。

例 16: 麗川真央『悪魔のいたずら心理ゲーム』学習研究社 (記録なし)

楽しくミステリーワールドで遊んだあなた。記念の動物スタンプを押してもらって、帰ることにしました。さて、あなたが押してもらったのは、何の動物のスタンプ?

次の例 17 は、擬人化の例である。家の中のだれかが捨てたハナクソによって作られ

る「ハナクソ太郎」の視点で文章が語られている。

例17: 舟崎克彦『ハナクソ太郎のぼうけん』学習研究社 (記録なし)


こんなありふれた家の中にも、てきはウョウョしているんだ。 ごしゅじんさまたちは、今夜ものんきにゆめを見ているけど、そんなあいだに、 てきはしのびよってきて、じんるいをほろぼそうとねらっているのさ。 そんなやつらからまもってあげているのが、ぼく―ハナクソ太郎なんだ。

3.2.5 論理構成・紙面構成に特徴のある例

論理構成に特徴のある例として、引用に特徴がある例を2例示す。また、紙面構成に 特徴のある例を2例示す。いずれも、紙面のみ例示する。


例 18 は、講義のあまった時間に学生に書かせたものを集めたものであるらしい。段落ごとに実際の著者が異なるため、著者が交代で執筆する「リレー執筆形式」のようにも見えるが、著者明記がないためそうは言い難い。編者による引用が連続する例であると考える。

例 18: 吉村英夫,シネカブ撰『ほろっと本音キラッと青春 紙上チャット こんな大学 生しています』アールズ出版 (377: 教育の大学・高等・専門教育.学術行政)



例 19 は、節ごとに他から文章を引用し、それに対する意見を述べるという構成になっている。


例 19:渡部昇一『努力しだいで知性は磨かれる』PHP 研究所 (159:倫理学. 道徳の 人生訓. 教訓)




次に、紙面構成に特徴のある例として、例 20、例 21を示す。これらのように視覚的な工夫がされているものを仮に「ブロック割り構成」と呼ぶこととする。ガイドブックや PC 関連のマニュアル、図説・図解の必要なものなど、なかば必然的に視覚的工夫を

とるものもあるが、ここではそれら以外にも工夫のあるものの例として、ビジネス書の 例を示す。

例 20:山田真哉監修『トヨタだけがなぜ儲かるのか!?財務を「カイゼン」する 12 のルール』 宝島社 (記録なし)



例 21:藤村正宏『「モノ」を売るな!「体験」を売れ! 2 時間でわかる! 』オーエス 出版 (673:商業の商業経営. 商店)




3.2.6 文末・調子に特徴のある例

ここまで例示してきたうちに、すでに「デスマス調、デアル調、ゴザイマス調、体言止め、語りかけ口調、演説調」といったものの大部分のサンプルをあげているが、ここで、語りかけ口調と、ゴザイマス調の例とを示す。

例 22:中島梓『小説道場』光風社出版 (914:日本文学の評論. エッセイ. 随筆)

ご質問の「視点」の件ですが、三回といわず、ずいぶん乱れてたよ。ためしにこんど、一人称で同じストーリーをどう書くかやってみてごらん。勉強になると思う。たとえば、本人が死んじゃってからってことになると、要はそのシーンが書きようがなくなるから、ストーリーもかわって来ちゃうわけよ。本当はそのくらいデカい問題なんだよ。質問一の答えは「そのとおり」です。「それ以外の方法は許されない」のです。それがイヤならはじめから「神の視点」をとっとくのだよ。この話の場合、奥川の視点にするイミはあんまりないので、本当は「神の視点」をやった方が正しかった、と先生は思います。そうすればどの心理も書けたもの。何もかもいっそうグチャグチャに乱す、というのもひとつの方法だと思いなさい。お勉強お勉強。



例 23: 井上祐美子『柳絮』徳間書店 (913:日本文学の小説. 物語)

国が滅びるとは、こういうことなのだと一人の命運を思いもよらぬ方向へ変えて しまうものなのだという、一例でございましょう。

ただ、この劉氏の趙は長続きせず、遭の武将でした石勒という者がやがて、独立 して別の国を建てます。

この石勒の国も結果としては三十年ほどで滅び、北から慕容氏が燕という国号を 名乗りまして、南下してまいりました。謝万叔父上が戦って、無残な敗北を喫し たのは、この鮮卑族の燕相手でございます。

その燕に対して、北西から力を伸ばしてまいったのが、秦の符堅というわけでご ざいます。

実のところ、わたくしもこの北の国々の移り変わりは、よく把握できておりません。国といったところで、はっきりとした線がひいてあるわけでなし、その版図も常に変化しております。

3.2.7 文長に特徴のある例

文の長短の傾向は、電子テキスト化された後の統計的な調査をもって明らかにできることではあるが、サンプリング過程においても、長め、短め、という印象は視覚的に目につくものである。そのような中から、例を示す。例 26 が短め、例 27 が長めの例である。例 28 は、句読点なしで文が連なっているものである。ゆえに、一文が長い、というだけのものではないが、あわせてここに例示する。

例 26: 花井愛子『純愛 1994』講談社 (913:日本文学の小説. 物語)

のれんくぐって。

ガラリ、なーんて、昔ながらの、すりガラスに格子のの戸を開けると。

グレーの、集団!!

すなわち。

オジサンだらけっつつつ。

うちの父親より年上に違いないオトーサン連中の、巣・・・・・。

だったりして。

お店の中は、カウンターだけ。

はっきり言って、狭い。

オジサン、10人ぐらい、いたんだろうか。

それでも、ぎっしり満員に、あたしには、見えてたのに。

例 27:松浦寿輝『花腐し』講談社 (913:日本文学の小説.物語)

批難がましくなじるというよりもむしろ呆れたようにそう呟いて栩谷の衣類をハンガーに掛け、自分もそそくさと着替えはじめたりする女の外出着の方はたしかにわずかな飛沫に湿っている程度で、二人並んでそれぞれ傘をさして帰ってきて、しかも栩谷のは大きな男物の傘だったのに、栩谷の背広だけが背中いちめん色が変わるほど濡れそぼっているのは奇妙といえば奇妙なことだった。女はそんな言葉ほどに気持が尖っているわけではなく、またわざとらしく顔をそむけてみせたりはするものの雨水に栩谷の汗が混ざり合ったにおいを決して嫌っているわけでもなくて、いやそれどころかそんなとき肩に手を掛けて引き寄せると頰を紅潮させてわざわざ栩谷の腋の下に顔を埋めてくる。

栩谷は配管が剝き出しになった安普請のホテルの半地下の駐車場の軒下で雨 宿りしていたが、鉛色の梅雨空をふと見上げた拍子に、その祥子という女が畳の 上に広げた栩谷の背広にタオルを当てて水気を取っていた癇性な手つきがいき なり蘇ってきた。

例 28:ジェイムズ・ジョイス[著]丸谷才一,永川玲二,高松雄訳『ユリシーズ』講談 社 (933:英米文学の小説.物語)

Yesだって先にはぜったいしなかったことよ朝の食じを卵を2つつけてベッドの中で食べたいと言うなんてシティアームズホテルを引きはらってからはずうっとあのころあの人は亭しゅ関ぱくでいつも病人みたいな声を出して病きで引きこもってるみたいなふりをしていっしょけんめいあのしわくちゃなミセスリオーダンの気を引こうとして自ぶんではずいぶん取り入ってるつもりだったのにあのばばあと来たらみんな自ぶんと自ぶんのたましいのめいふくを祈るミサのため寄ふしてあたしたちにはなんにも残さないなんてあんなひどいけちんぼあるかしらメチルをまぜたアルコールに4ペンスつかうのだってびくびくものでいつも自ぶんの持病の話ばかりあれやこれやそれから政じの話やら地しんのことやらこの世の終りのことやらうんざりするおしゃべりばかりまずすこしはたのしみましょうよ世の中の女がみんなああいうふうになったらどうしますか水着やデコルテのわる口を言ってたけれどもちろん誰だってあのばあさんにそんなもの着てくれなんてたのみますかあの女が信じんぶかかったのは男が誰ひとりはなもひっかけなかったからあんなふうにはなりたくないものですね顔までかくせと言わないのが不しぎなくらい


3.2.8 語彙や表記に特徴のある例

最後に、例 29 と例 30 に、語彙や表記に特徴のある論説文 2 例を示す。例 29 は、漢字に関する論説文である。表外漢字(一部、テキスト引用に二文字を用いる)が数多く出現し、非常に難解に見える。例 30 は、言葉遣いは平易であるが、歴史的仮名遣いで

あるため、この仮名遣いに馴染みがないとやはり難解に見える。

例 29:白川静『白川静著作集 別巻 3』平凡社 (222:アジア史. 東洋史の中国)

「柱也、从木盈聲」とあり、「春秋傳曰、丹桓宮楹」と春秋傳の文を引くが、文は莊廿三年の經文である。釋名釋宮室に、「楹、亭也、亭亭然孤立、旁無所依也」とあり、段注にその文を引いて、「按禮言東楹西楹、非孤立也、自其一言之耳」というも、字義に關しない。盈は盈滿の義であるから、柱というもおそらく太みのある圓柱の意であろう。段注にまた、「考工記、蓋杠謂之=、=即楹、如欒盈、史記晉世家作欒逞、其比也」という。詩の商頌殷武に「旅楹有閑」とみえ、また考工記輪人「爲蓋、達常圍三寸、=圍倍之」、注「=、蓋杠也」とあり、これによると達常より含らみのあるものを=・楹と稱するのである。おそらくエンタシスのある圓柱の稱であろう。盈滿の義を以て、盈の聲符をとる字であろうと思われる。前條に「柱、楹也」と互訓するも、柱楹の別はエンタシスの有無に存していよう。以下柱・小柱の義をもつ諸字を列しており、古代中國における宮殿建築の發達の狀を思わせるものがある。



例 30:柳田国男『柳田國男全集 第 30 巻』筑摩書房 (380:風俗習慣,民俗学,民族学)

それから又同じ穀物でも、砕けやかけらや粃などのやうに、粒のまゝでは用ゐ られぬものが多い。さういふのは粉に挽いて食べるの他は無い。蕎麦も小麦も粉 にするのが元の食べ方であつて、或はそれを飯や粥の上にふりかけて食ふことも あるが、多くはその粉だけを食べる算段をして居た。此類の穀粉も、農家の常食 とするのが唯一の用途であった。今日の所謂麵類は、一つの改良した方法であっ て、味も見た目もよく興味も刺戟するが、是は手が掛るので働く日にはこしらへ て居られない。以前はもう少し簡単な食べ方をしたのである。その一つは、炒つ てはたいて乾いた粉のまゝで食ふもの、上品な言葉ではオチラシ、村ではハッタ イといふ人が多い。ハッタイは即ち「はたきもの」の略語である。或は乾いた粉 を水で捏ね、又は始めからねばし挽きにして、之を摘んで汁の中に落しても食べ る。是が即ちツミイレであるが、今では魚の肉などゝ合せて、町では御馳走の一 つになつて伝はるのみである。或は又その水で捏ねたものを、ぶつ//に切つて 煮ることもあり、それを全国に亘つてホウトウともハツトウとも謂つて居たが、 ハツトウも亦恐らくは、はたいて粉にしたからの名であらう。或はこのこね方を やゝゆるくして、その粉に芋類を搗き合せて煮るものもあつた。関東の多くの山 村では是をネリゲ、即ち練粥と謂つて居る。薩摩芋の栽培が普及してから、その ネリゲが幾分か甘くなつて来て、少しは食べにくさが減じたと謂つて居る。



第4章 多様性の分析と文体論研究との接点

本稿の最後に、コーパスに格納された文章 (サンプル) の多様性を分析するとはどういう作業であるか、という点について考えてみたい。

たとえば、従来の文章・談話・テクスト研究の中では、文章の多様性は、「文体」や「スタイル」、あるいは「位相」としてとらえられてきた。このうちの「文体」について、林(1991)は、以下のように述べている (p. 32)。

文体論:文体に関する理論,理論的追及。文章は,その表出の目的(内容),時代的制約による記載様式・語彙・語法などの違い,および書き手の個性,個性に基づく言語表現に関する美的理想の違い等から,多様な形態を示し,読み手に違った印象を与える。この違いを類型的に,あるいは個別的にとらえたものを文体とし,これについて論ずる分野を文体論という。

現実に存在している書き言葉の実態を反映するようにサンプルを抽出し、その言語的な特徴や類型を多角的な視点から明らかにしていく作業は、上記の文体論の方法論に近い。NDCを基準として設計された現代日本語書き言葉のコーパスが、どのような多様性を有するかを検討することは、そのまま、現代日本語の書き言葉全体を対象とした文体論的な分析になり得ると考える。

第5章 おわりに

生産実態,流通実態のサブコーパスに収録されるサンプルを概観し,多様性をとらえるための観点について検討した。そして,それらの観点を用いて,現在集積の進む「書籍」サンプルの多様性を報告した。今後,サンプルが電子化され,構造を表すタグや形態論情報が付与されてくれば,多様性のより具体的な分析が可能になる。

文章に関する研究が言語学的に、あるいは心理学的に進められている一方、図書館や 書店においては、図書分類というものが、NDC 以外にも様々に工夫、検討されている。 それら従来の議論と、今まさに実現しつつある大規模コーパスの分析とをあわせ、文章 の多様性について、さらなる分析、議論を進めていきたい。

謝辞

本研究は、文部科学省科学研究費補助金特定領域研究「代表性を有する大規模日本語書き言葉コーパスの構築:21世紀の日本語研究の基盤整備」(平成18~22年度、領域代表者:前川喜久雄)による補助を得ています。また、「生産実態(出版)サブコーパス」「流通実態(図書館)サブコーパス」の構築に当たっては、著者、出版社をはじめ、国立国会図書館、東京都立図書館、立川市中央図書館、一橋大学附属図書館、(社)日本図書館協会、(社)日本文藝家協会、(社)日本推理作家協会、(社)日本児童文学者協会、(社)日本児童文芸家協会、(社)日本ペンクラブ、各位よりデータ提供等の御協力をいただいています。記して深く感謝の意を表します。

参考文献

- 柏野和佳子・丸山岳彦・秋元祐哉・稲益佐知子・佐野大樹・田中弥生・山崎誠(2008a). 「書籍の生産実態を反映するサンプリング —NDC ごとに取得したサンプルの多様性の分析—」『言語処理学会第14回年次大会発表論文集』,言語処理学会.
- 柏野和佳子・丸山岳彦・秋元祐哉・稲益佐知子・佐野大樹・田中弥生・山崎誠(2008b). 「書籍サンプルの多様性」特定領域研究「日本語コーパス」平成19年度ワークショップ予稿集.
- 野村眞木夫(2005).「日本語の二人称小説における人称空間と表現の特性」『上越教育大学国語研究』19, pp. 1-19.
- 林巨樹(1991).「文体論の領域」『文体論の世界』,三省堂.
- 丸山岳彦・秋元祐哉(2007).『『現代日本語書き言葉均衡コーパス』におけるサンプル構成比の算出法-現代日本語書き言葉の文字数調査-』,特定領域研究「日本語コーパス」 平成 18 年度研究成果報告書(JC-D-06-02).
- 丸山岳彦・秋元祐哉(2008).『『現代日本語書き言葉均衡コーパス』におけるサンプル構成比の算出法(2) ―コーパスの設計とサンプルの無作為抽出法―』,特定領域研究「日本語コーパス」平成19年度研究成果報告書(JC-D-07-01).

研究開発部門言語資源グループ (サンプリングサブグループ)

(研究開発部門グループ長(副)) 山崎誠

柏野和佳子 (研究開発部門研究員) 丸山岳彦 (研究開発部門研究員)

田中弥生

佐野大樹 (研究開発部門特別奨励研究員) 秋元祐哉 (研究開発部門研究補佐員) 稲益佐知子 (研究開発部門研究補佐員) (研究開発部門研究補佐員)

国立国語研究所内部報告書(LR-CCG-07-02)

『現代日本語書き言葉均衡コーパス』における書籍サンプルの多様性

平成20年3月21日

執筆者 柏野和佳子・丸山岳彦・秋元祐哉・稲益佐知子・佐野大樹・ 田中弥生・山崎誠

発行者 独立行政法人国立国語研究所 〒190-8561 東京都立川市緑町10 番地の2 電話042 (540) 4300 (代表)

c2008 独立行政法人国立国語研究所

(平19-10)

