

まえがき

本書は、迫田久美子とそのチームが中心となって構築した「多言語母語の日本語学習者横断コーパス」(International Corpus of Japanese as a Second Language: I-JAS)の構築理念・構築過程および収集したデータの概要を紹介し、日本語習得研究・日本語教育へのI-JASの応用可能性について解説を行った書物である。

I-JASには、学習者1,000名、日本語母語話者50名、合計1,050名の参加者を対象とする対面調査で収集した発話と作文、一部の参加者から収集した任意作文、および、全参加者に関する詳細な背景情報のデータが含まれる。

I-JASは、対面調査だけで807.6万語(うち参加者の産出は461.6万語)の産出データを収集しており、名実ともに世界最大の日本語学習者コーパスであるが、その真の価値は、第二言語習得研究の枠組みにおいて、多様な対照研究に利用できるよう綿密な設計がなされている点にある。

まず、対面調査には性質を異にする5種のタスク(ストーリーテリング、対話、ロールプレイ、絵描写、ストーリーライティング)が含まれ、タスク間の比較を行うことができる。さらに、任意作文との比較も可能である。

次に、1,000名の学習者は、海外学習者850名、国内教室環境学習者100名、国内自然環境学習者50名にわけられており、海外学習環境と国内学習環境、教室学習環境と自然学習環境の比較が可能である。

さらに、海外学習者の母語は12種に及び、母語別の比較や、言語系統別の比較もできる。これらの学習者と日本語母語話者の比較も行える。

加えて、すべての学習者は2種の習熟度テストを受けており、習熟度別の比較も可能である。このほか、背景調査のデータを併用することで、性別・年齢・日本語学習歴・日本語学習スタイルなど、幅広い観点で比較研究を行うことが可能である。

これだけの幅広いデータを体系的に集めるのは決して容易なことではなかった。I-JASプロジェクトでは、研修を受けた17名の調査者が、海外17ヵ国20ヵ所、日本国内10ヵ所に赴き、共通のプロトコルで対面調査を

実施し、統制的にデータを収集した。

なお、ここで特筆しておきたいことは、このプロジェクトが研究プロジェクトであるとともに、日本語の学びの輪を世界に広げる国際的な教育プロジェクトでもあったということである。調査者は、タスクという枠組みの中であっても、参加者の話に真摯に耳を傾け、心を通わせ、必要な助言や励ましを行った。また、調査者は、日本の風物が印刷された絵葉書カードを持参し、個々の参加者への感謝と学習助言をカードにしたため、参加者全員に手渡した。参加者の中には、今回のプロジェクトを通して、生まれて初めて、日本語母語話者と長時間話す経験を持った者も少なくなかった。プロジェクトへの参加は、彼ら・彼女らの日本語の学びにとって大きな刺激となった。

I-JAS プロジェクトの完成には、このような調査（前の段落の内容を受けて）に参加してくれた多くの日本語学習者、また同時に多くの機関・個人の助力を得た。巻末資料に関係者および協力者の一覧を掲載し、深く感謝の意を示したい。以下、関係するプロジェクトおよび科学研究費助成金事業を挙げ、本書がその成果の一部であることを記す。

- ・ 国立国語研究所共同研究プロジェクト「多文化共生社会における日本語教育研究」(期間：2009–2015 年度／代表者：迫田久美子)
- ・ 国立国語研究所共同研究プロジェクト「日本語学習者のコミュニケーションの多角的解明」(期間：2016–2021 年度／代表者：石黒圭)
- ・ 科学研究費助成事業（基盤研究 A）「海外連携による日本語学習者コーパスの構築—研究と構築の有機的な繋がりに基づいて—」(期間：平成 24–27 年度／代表者：迫田久美子／課題番号：24251010／共同研究者：岩立志津夫・野田尚史・田中真理・松見法男・金田智子・大関浩美・奥野由紀子・峯布由紀・李在鎬)
- ・ 科学研究費助成事業（基盤研究 A）「海外連携による日本語学習者コーパスの構築および言語習得と教育への応用研究」(期間：平成 28–31 年度／代表者：迫田久美子／課題番号：16H01934／共同研究者：野田尚史・田中真理・李在鎬・砂川有里子・松見法男・野山広・奥野由紀子・望月圭子・宇佐美まゆみ・小柳かおる・石川慎一郎)

なお、本書の関連資料の提供の場として、専用のサイト (www.9640.jp/ijas/) を用意した。サイトでは、誤植・誤記の修正情報のほか、書籍に載せられなかったデータや資料を公開する予定である。あわせて活用していただきたい。

最後に、本書の意義を認め、出版を快諾くださったくろしお出版、とくに、本書の編集を担当された池上達昭氏に感謝を申し上げたい。

今後、本書を手ほどきとして、I-JAS が第二言語としての日本語の習得研究や日本語教育の分野で幅広く使用され、世界の日本語研究および日本語教育の一層の発展に資することを願っている。

2019年12月
編著者

目 次

まえがき	iii
------------	-----

第 I 部 I-JAS の設計と構築

第 1 章 I-JAS 誕生の経緯	2
1.1 はじめに	2
1.2 誤用分析から学んだこと	3
1.3 コーパスデータの重要性	4
1.3.1 アンケート調査法の問題点	4
1.3.2 コーパス調査法：縦断データの問題点	5
1.3.3 コーパス調査法：横断データの問題点	6
1.4 I-JAS の誕生に向けて	8
1.4.1 失敗から学んだこと	8
1.4.2 I-JAS のデータ収集の基本方針	9
1.4.3 I-JAS の 10 大特徴	10
1.5 まとめ	13
第 2 章 参加者の決定	14
2.1 はじめに	14
2.2 調査対象とする参加者	14
2.3 参加者のタイプ	16
2.3.1 海外の教室環境学習者	16
2.3.2 国内の教室環境学習者	17
2.3.3 国内の自然環境学習者	18
2.3.4 日本語母語話者	18
2.4 まとめ	19
第 3 章 調査の設計と実施	20
3.1 はじめに	20
3.2 データ収集の基本方針	20

3.3	I-JAS 調査の全体像	21
3.4	事前調査	22
	3.4.1 背景調査	22 / 3.4.2 任意作文調査 27 / 3.4.3 事前調査の実施方法 29
3.5	本調査(対面調査)	31
	3.5.1 対面調査の準備	31 / 3.5.2 対面調査の流れ 33
3.6	事後調査(習熟度調査)	42
	3.6.1 J-CAT	43 / 3.6.2 SPOT 44 / 3.6.3 事後調査の実施方法 46
3.7	まとめ	47
第4章	音声データのテキスト化.....	48
4.1	はじめに	48
4.2	テキスト化作業の流れ	49
4.3	書き起こし	50
	4.3.1 書き起こしの基本方針	50 / 4.3.2 表記法 51 /
	4.3.3 発話の区切り表示	51 / 4.3.4 その他, 特殊な記法 51 / 4.3.5 作業者の研修 52
4.4	形態素解析	53
	4.4.1 自動形態素解析の制約	53 / 4.4.2 I-JAS タグセットの開発 55 / 4.4.3 形態素解析の実施 60
4.5	まとめ	61
第5章	データの公開.....	62
5.1	はじめに	62
5.2	2種類のデータ	62
	5.2.1 テキストデータ	63 / 5.2.2 付属データ 65
5.3	公開データの種別	65
	5.3.1 公開データの一覧	65 / 5.3.2 産出データの公開 66 / 5.3.3 関連データの公開 68

5.4 コードセット 69

5.5 まとめ 70

第2部 I-JASの量的外観

第6章 参加者の属性.....72

6.1 はじめに 72

6.2 母語別参加者数 73

6.3 職業・性別・年齢 74

6.4 言語環境 76

6.5 日本語学習環境 78

6.6 まとめ 80

第7章 参加者の習熟度.....82

7.1 はじめに 82

7.2 J-CATとSPOTの全般的得点分布 82

7.3 J-CATに見る母語別・学習環境別の習熟度分布 86

7.4 SPOTに見る母語別・学習環境別の習熟度分布 88

7.5 まとめ 89

第8章 参加者の産出語数.....91

8.1 はじめに 91

8.2 タスク別産出語数 91

8.3 母語別・学習環境別の産出語数 94

8.4 まとめ 100

第3部 I-JASの使用法

第9章 「中納言」の基本検索.....102

9.1 はじめに 102

9.2 事前登録 102

9.3 文字列検索と短単位検索 103

9.4	文字列検索：中国語母語話者が対話で使用した「それから」を探す	105
9.4.1	検索対象の指定	105 / 9.4.2 タスクの指定 106 /
9.4.3	母語の指定	107 / 9.4.4 検索結果の読み方 108
9.5	まとめ	111
第10章	「中納言」の応用検索	112
10.1	はじめに	112
10.2	活用形一括検索：「行く」の活用形を一括検索する	113
10.3	品詞指定検索：接続助詞の「が」を検索する	115
10.4	共起検索：「～している」形を検索する	116
10.5	詳細設定	118
10.5.1	データ範囲の詳細設定	118 / 10.5.2 結果表示方法の詳細設定 119
10.6	検索結果の保存	120
10.7	短単位検索時の注意点	121
10.8	まとめ	122
第11章	計量研究の方法	123
11.1	はじめに	123
11.2	必要標本数の確認	123
11.2.1	必要標本数とはなにか	123 / 11.2.2 実例の検討 124
11.3	差の有意性の検定	126
11.3.1	有意性検定とはなにか	126 / 11.3.2 比較する対象 126 / 11.3.3 有意性検定のロジック 126 / 11.3.4 使用する統計量 127 / 11.3.5 実例の検討 128
11.4	多変量解析	131
11.4.1	多変量解析とはなにか	131 / 11.4.2 クラスター分析 133 / 11.4.3 対応分析 135
11.5	計量的コーパス研究の今後	137

11.5.1 どの統計量を使うべきか? 138 / 11.5.2 危険率を見る
だけでよいのか? 138 / 11.5.3 検定を反復してよいのか? 139
/ 11.5.4 そもそも検定はいるのか? 140

11.6 まとめ 141

第4部 I-JASの分析

第12章 作文における産出量と語彙特徴..... 144

12.1 はじめに 144

12.2 データと方法 145

12.2.1 言語テストによる能力集団の作成 145 / 12.2.2 解析
テキストデータの作成 148 / 12.2.3 解析方法 148

12.3 結果 149

12.3.1 延べ語数と異なり語数 149 / 12.3.2 文字や語彙の使
用率 151 / 12.3.3 内容語の使用率 154 / 12.3.4 平均文長
155

12.4 まとめ 156

第13章 作文における語彙レベルとリーダビリティ 157

13.1 はじめに 157

13.2 データと方法 157

13.2.1 「日本語教育語彙表」 157 / 13.2.2 jReadability 158

13.3 結果 159

13.3.1 語彙レベルの分布 159 / 13.3.2 リーダビリティ
162

13.4 まとめ 166

第14章 発話における副詞の使用..... 167

14.1 はじめに 167

14.2 学習者による副詞の使用 167

14.3 調査の枠組み 168

14.3.1	目的と RQ	168	/	14.3.2	データ	169	/	14.3.3	分 析手順	170
14.4	結果と考察	178								
14.4.1	RQ1：副詞使用量	178	/	14.4.2	RQ2：高頻度副詞	179	/	14.4.3	RQ3：特徴副詞	181
14.5	まとめ	183								
第 15 章	発話における丁寧体否定文の使用									185
15.1	はじめに	185								
15.2	学習者による丁寧体否定文の使用	185								
15.3	調査の枠組み	188								
15.3.1	目的と RQ	188	/	15.3.2	データ	188	/	15.3.3	分 析手順	190
15.4	結果と考察	194								
15.4.1	RQ1：母語話者のナイデス率	194	/	15.4.2	RQ2： 学習者のナイデス率	196	/	15.4.3	RQ3：共起要素	199
15.5	まとめ	203								
第 16 章	総括と展望									205
16.1	はじめに	205								
16.2	日本語教育・第二言語習得研究の観点から	206								
16.2.1	第二言語習得研究の深化と拡大	206	/	16.2.2	日本語 教育の実践への応用	207	/	16.2.3	I-JAS への期待	208
16.3	縦断研究の観点から	208								
16.3.1	B-JAS とはなにか？	208	/	16.3.2	B-JAS の特徴：こ れまでの発話コーパスの抱えた課題を踏まえて	209	/	16.3.3	I-JAS への期待	210
16.4	計量言語研究の観点から	211								
16.4.1	計量言語学とはなにか？	211	/	16.4.2	計量言語学と 日本語教育	211	/	16.4.3	I-JAS への期待	212

16.5	世界の学習者コーパス研究の観点から	212
16.5.1	主要な英語学習者コーパスの開発小史	213 / 16.5.2
	主要な日本語学習者コーパスの開発小史	214 / 16.5.3
	への期待	214
16.6	まとめ	215
主要参考資料.....		217
巻末資料 収集データサンプル		222
索引.....		249
関係者および協力者一覧.....		253

I-JAS の設計と構築

I-JAS は、従来にないユニークな特徴を持った学習者コーパスである。I-JAS はどのような背景で構想され、どのようにして作られたのであろうか？

I-JAS の開発にあたっては、(1) 参加者の決定、(2) 調査の設計と実施、(3) 音声データのテキスト化、(4) データの公開、という4つのステップで作業を進めた。

第1部では、まず、第1章において、I-JAS プロジェクト誕生の経緯や、既存のコーパスとの関係性、また、「I-JAS の10大特徴」について簡単にまとめた後、第2～5章で上記の4つのステップについて順に説明する。

第2章では、I-JAS の調査に参加した学習者のタイプやその背景を示す。

第3章では、対面調査を中心とする参加調査の全体をどのように設計・実施したかを示す。

第4章では、対面調査で集めた音声データをどのように書き起こし、言語分析用に形態素解析したかを示す。

最後に、第5章では、公開されるデータの全体像を示し、ファイルのコードやデータの読み方について説明する。

第1章

I-JAS 誕生の経緯

1.1 はじめに

本章では、なぜ、I-JAS という多様な母語の日本語学習者のコーパスが誕生したのかについて、これまでの研究を振り返りながら、I-JAS の背景および経緯を述べる。

第二言語(外国語を含む)学習者は、目標言語を習得する過程で様々な学習者特有の言語表現を産出する。正用も誤用も含んだ第二言語学習者特有の言語は「中間言語」と呼ばれ、1970年代から研究が盛んに進められるようになった。

日本語を第二言語とする学習者にも、(1)～(3)のような様々な誤用が観察されている。(→)で正用を示し、国名は学習者の国籍を示す。

- (1) 田中さんが(→は)どこですか (韓国 市川, 2010, p.59)
- (2) さむくて(→寒いから)、ヒーターをつけよう
(インドネシア 同上, p.389)
- (3) 私たちは三年前にけっこうしていますが(→しましたが)、こどもがまだありません。
(アメリカ 同上, p.414)

国内における日本語教育が盛んになり始めた1970年代は、上記のような誤用は学習者の母語と日本語の違いが起因して起きると考える研究者が多く、日本語と学習者の母語との対照研究が盛んに行われた。しかし、日本語教育の現場にいる日本語教師は、母語の異なる学習者から同種の誤用が産出される実態を見て、学習者の母語の影響、つまり母語の言語転移だけでは片

第2章

参加者の決定

2.1 はじめに

学習者コーパスを作るのは膨大な時間と労力を要する作業である。I-JAS のプロジェクトでは、大まかに4段階の検討および作業のステップを経て最終的なコーパスの完成にこぎつけた。2～5章ではそれぞれのステップについて実際の作業の内容を紹介していく。

- [1] 参加者の決定(どのような学習者を対象とするか?)
- [2] 調査の設計と実施(どのような調査を行うか?)
- [3] 音声データのテキスト化(音声データをどう処理するか?)
- [4] データの公開(集めたデータをどういう形で公開するか?)

まず、2章では「参加者の決定」に関して述べる。コーパスを作る上で重要なことは、誰を対象としてデータを集めるのかを明確に決めることである。これによって集められるデータの特徴が異なってくる。本章では、I-JAS のデータがどのような参加者から取られたものなのかを具体的に紹介する。

2.2 調査対象とする参加者

日本語学習者コーパスを作ろうとする場合、その対象が日本語学習者であることは自明である。しかし、一口に日本語学習者と言っても、日本語を習い始めたばかりで、日本語をまったく書いたり話したりできないとすれば、データの収集は困難になるだろう。そこで、I-JAS では、対象とする日本語学習者について以下の3つの基礎要件を定めた。

第3章

調査の設計と実施

3.1 はじめに

2.1 節で述べたように、学習者コーパスの構築は、(1) 参加者の決定、(2) 調査の設計と実施、(3) 音声データのテキスト化、(4) データの公開という4つの段階で進められる。3章では、このうち、「調査の設計と実施」に関して述べる。

I-JAS のデータの中核部は、調査者（インタビュワー役を担当した教員）と参加者（学習者および日本語母語話者）の間で行われた対面調査で収集された。多様な母語背景を持つ学習者が調査に参加していること、そうした学習者が性質を異にする多様なタスクに取り組んでいること、また、すべての参加者に同条件で調査を実施したことは、I-JAS の特筆すべき特徴であるが、I-JAS の対面調査とはどのようなものであったのだろうか。

本章では、I-JAS 構築のために行った調査の全体像を紹介する。I-JAS を正しく利用するには、I-JAS の調査がそもそもどのようなもので、「何をどう調査したのか」を正確に理解しておくことが不可欠であると言える。

3.2 データ収集の基本方針

学習者の日本語の習得状況を観察するには、日本語学習者の話し言葉や書き言葉のデータが不可欠である。では、具体的にどのようなタスクを与え、どのようなデータを集めればよいのであろうか。

学習者コーパスの開発に際して、収集すべきデータは一義的に決まるものではない。というのも、研究目的に応じて必要なデータは異なるからである。逆に言えば、データ収集に先立ち、「何を目的としてデータを集めるの

第4章

音声データのテキスト化

4.1 はじめに

2章および3章で示したように、I-JAS プロジェクトでは、初めに対象とする調査参加者を決定し、次いで、対面調査を中核とする I-JAS 調査の全体的な枠組みを決めて調査を実施してきた。

世界各国で行った調査によって膨大な量の音声データが得られたわけであるが、収集した音声データをテキストデータとして整備するためには、書き起こし (transcription) と形態素解析 (morphological analysis) という2つのデータ加工のプロセスが必要となる。4章ではこれらの詳細について述べる。

書き起こしとは、音声を聞き、それを文字として書き出していく作業のことで、「文字化」や「文字起こし」と呼ばれることもある。また、形態素解析とは、書き起こしたテキストを形態素 (テキストを構成する最小単位。いわゆる「語」に準じる) に分割し、個々の語について、読みや品詞、また、活用のタイプや終止形などの情報を加える作業のことである (小木曾, 2014)。

そもそも、書き起こしや形態素解析はなぜ必要なのであろうか。ここで、以下の例を見てみることにしよう。(1) は録音された音声を、(2) は書き起こしされたテキストを、(3) は形態素解析されたテキストを示す (縦線は形態素の切れ目を示す)。なお、この例は、中国語母語話者 (CCS40) の対話タスクにおける実際の発話から取ったものである。

- (1) ハハハアレワケッコーマエノニジュウネングライマエノエイガーデスケド…
- (2) {笑} あれは結構前の二十年ぐらい前の映画一ですけど…

第5章

データの公開

5.1 はじめに

2～4章で述べたように、I-JAS プロジェクトでは、(1)参加者の決定、(2)調査の設計と実施、(3)音声データのテキスト化という作業をそれぞれ綿密な計画のもとに実施してきた。コーパス構築のための作業の最後に来るのは(4)データの公開である。5章ではこの点について述べたい。

コーパスの公開にあたって、かつては、コーパス全体をダウンロードさせる方式が一般的であった。利用者は、ダウンロードしたデータを各自のコンピュータ上で処理して必要な検索や分析を行った。こうした公開方法は、コーパスの処理技術に精通した利用者には有益なものであるが、幅広い利用者の便宜に叶うものとは言いがたい。

このため、近年では、ダウンロード版よりもオンライン版でのコーパス公開が一般的になりつつある。オンライン版では、通例、検索システムが同時に提供されるため、データ処理の技術を持たない幅広い利用者がコーパスを活用し、自身の教育や研究に役立てることができる。こうした動きをふまえ、I-JASでも、発話書き起こしや作文といった産出テキストについては、オンライン版とダウンロード版の2つの形でデータを提供することとした。

5.2 2種類のデータ

I-JASのデータは、参加者による発話の書き起こしや作文といった産出テキストデータと、付属データ(音声+フェイスシート+関連情報)に大別することができる。このうち、前者についてはオンライン版とダウンロード版という2種類の使用形態がある。



第2部

I-JAS の量的外観

第1部では、(1)参加者の決定、(2)調査の設計と実施、(3)音声データのテキスト化、(4)データの公開、という4つのステップでI-JASの構築が進められたことを示した。この過程で、1,050名の発話者から、800万語を超える大量のデータが収集された。

第2部では、こうして集められたデータを計量的観点から概観する。

まず、第6章では、I-JASの参加者の人数や基本的な属性情報を整理して示す。

第7章では、参加者のうち、学習者の日本語習熟度の概況について詳しく述べる。参加者は、すべて2種類の日本語習熟度テストを受験しており、テストのスコア情報を活用することで、学習者を習熟度別に分けて分析することが可能になる。

第8章では、参加者の産出語数に注目し、タスク別・母語別の語数について紹介する。

第6章

参加者の属性

6.1 はじめに

第1部では、I-JASの構築過程と集められたデータの概要について説明した。すでに述べたように、I-JASの最大の特徴は1,000名の学習者と50名の日本語母語話者から、800万語を超える大量の産出データを集めたことである。

I-JASを用いて研究を行う際には、参加者の産出データ(作文・発話)を調べるだけでなく、その属性情報や習熟度情報を加味して分析を行うことが重要である。また、異なるタスク間で頻度を比較する際には、タスクごとに産出の総語数を調べ、得られた頻度を標準化しておく必要がある。この目的に沿い、以下、第2部の6～8章では、参加者の属性・習熟度・産出語数の3点について計量的な概観を行うこととしたい。なお、6～8章の分析のもとになっているのは、I-JASの関連情報の1つである「フェイスシート調査(背景調査)結果」と「語数表」の情報である。

さて、6章においては、参加者の一般的な属性情報に注目する。フェイスシートからわかる情報は多岐にわたるが、以下では、(1)母語別・学習環境別の参加者数、(2)職業・性別・年齢、(3)言語環境(複言語使用状況)、(4)日本語学習環境(教育機関・学習のきっかけ・日本語使用活動)の4観点を取り上げ、状況を概観したい。

第7章

参加者の習熟度

7.1 はじめに

I-JASは大規模な日本語学習者コーパスであるが、特筆すべきは、学習者の日本語習熟度データとして、3.6.1節と3.6.2節で述べた「J-CAT」と「SPOT」のスコアが付属していることである。この情報を活用することで、学習者の産出分析を精緻化し、考察をさらに深めることができる。

本章では、J-CATとSPOTの得点分布を中心に報告する。得点分布についての理解は、I-JASの性質を捉える上でもっとも基礎的かつ重要な情報である。なお、以下の節では、得点の度数分布表をもとにしたヒストグラムと母語別の得点情報を示す。

7.2 J-CATとSPOTの全般的得点分布

I-JASに収録されている全データをもとに、J-CATの合計得点(400点満点)とSPOTの得点(90点満点)を調査したところ、以下のような得点分布が確認された。なお、J-CATの平均点は201.95、標準偏差は58.89、SPOTの平均点は66.23、標準偏差は12.06である。

ヒストグラムは、横軸がテストの得点、縦軸が度数(人数)である。ヒストグラムを通して得点の全体分布を確認することができる。図を見る際のポイントとして、中央(中程度の能力の集団)が盛り上がり、両端に伸びる分布、すなわち正規分布になっているかどうかを確認する。

図1のJ-CATであれば、200点台がもっとも盛り上がり、左端の100点台(能力が低い集団)と右端の300点台(能力が高い集団)が少なくなっていることが確認できる。図2に関しても分布のパターンとしては概ね図1

第 8 章

参加者の産出語数

8.1 はじめに

コーパス分析では、個別の頻度を議論するにあたり、全体のサイズ情報を参照して正規化を行う。たとえば、20 万語中の 20 回と 30 万語中の 9 回であれば、それぞれの総語数で割って 10 万語あたりの調整頻度に換算し、10 回と 3 回として議論を行う。

こうした頻度の調整は母語間の比較を行う際に多く行われるが、タスク間の産出の比較を行う際にも同様の調整が必要となる。とくに I-JAS の場合、「対面調査」と言っても、そこには性質を異にする多くのタスクが含まれており、これらを比較する研究も必要であろう。そこで、本章では、I-JAS の対面調査のデータを用い、参加者がそれぞれのタスクにおいて産出した語数を概観することとしたい。

なお、インタビューデータの総語数については、参加者発話 (K) だけを指す場合と、参加者発話と調査者発話の両方 (K + C) を指す場合があるので注意が必要である。

8.2 タスク別産出語数

I-JAS には 800 万語のデータが収録されているが、その内訳はどのようになっているのであろうか。まず、タスク別および全体の総語数について確認する。なお、本章で言う語数とは形態素の数のことである。



第3部

I-JAS の使用法

本書第1部では、I-JASの構築過程を示し、第2部では収集されたデータを計量的に概観してきた。いよいよ第3部ではコーパスを「実際に使ってみる」こととしたい。

まず、第9章と第10章では、国立国語研究所コーパス検索アプリケーション「中納言」上でI-JASを検索するやり方を詳しく解説する。「中納言」では、文字列検索と、形態素解析を行ったデータをもとに行う短単位での検索の2種類方法があるが、9章では前者を、10章では後者を扱う。

第11章では、コーパスから得られた頻度の処理に関して、計量的な学習者コーパス研究の進め方や心構えについて解説を行う。

第3部の3つの章は、コーパス研究になじみのない入門者を主たる対象者として、具体的な手順について詳しく説明しているので、説明に沿って、ぜひ実際にI-JASを検索していただきたい。

第9章

「中納言」の基本検索

9.1 はじめに

5.2節で述べたように、I-JASにはダウンロード版とオンライン版がある。前者はI-JASに含まれるテキストデータをダウンロードし、利用者が各自のコンピュータ上で自由に分析する方法である。使用するコンコーダンス（コーパスから用例を検索するソフトウェア）は利用者の側で用意する。一方、後者は国立国語研究所コーパス検索アプリケーション「中納言」（以下「中納言」）上で検索を行う方法である。この場合、インターネットに繋がる環境さえあれば、利用者の側で他に用意すべきものはない。

両者を比較すると、ダウンロード版のほうが検索の自由度が高いが、コーパスやコンコーダンスに関する知識や経験がないと、I-JASのような大型コーパスからほしい用例を自力で取り出すのは難しい。一方、「中納言」を使えば、初心者であっても、ほしい用例を簡単に取り出すことができる。

そこで、第9章と第10章では「中納言」でのI-JAS検索方法について解説する。「中納言」には「文字列検索」と「短単位検索」という2つの検索方法があるので、第9章では前者を中心に基礎的な検索手法を解説し、10章では後者を中心に応用的な検索手法を解説する。ただし、「中納言」上でI-JASを使用するには登録手続きが必要なので、次節では、まず、その方法から紹介したい。

9.2 事前登録

「中納言」でI-JASを利用するには、(1)「中納言」のユーザー登録と、(2)I-JASの利用申請という2つの手続きが必要になるが、これらは同時に完了

第10章

「中納言」の応用検索

10.1 はじめに

短単位検索では、形態素解析で付与された形態論情報を利用することができる。これにより、文字列検索ではできなかった、以下のような応用検索が可能となる。

- [1] 活用形一括検索
- [2] 品詞指定検索
- [3] 共起検索

[1] は、動詞の活用形（例：「行かない」「行きます」「行く」「行けない」「行けば」「行こう」「行って」）や語の異表記（例：「やはり」「やっぱり」「やっぱ」など）を一括で検索する方法である。短単位検索では、短単位ごとにその基本形の情報が付与されたデータを使うことになるので、基本形（各種の活用形の祖型という意味で「語彙素」と呼ぶ）を指定するだけで、上記のような例を一度に検索対象にすることができる。

[2] は、特定の語について品詞を指定して検索したり、あるいは、語を指定せず、任意の品詞の語をすべて検索したりする方法である。たとえば、「感動詞（フィラー）」を一括検索することもできる。

[3] は、複数の短単位からなる連鎖を検索する方法である。前章の例で言えば、「それ」＋「から」と指定して、「それから」を検索したり、さらには、品詞を組み合わせて、「代名詞」＋「助詞」と指定して該当するすべての用例（例：「私は」「彼が」「彼女の」など）を検索したりすることができる。

第 11 章

計量研究の方法

11.1 はじめに

第 9 章および第 10 章では、国立国語研究所コーパス検索アプリケーション「中納言」上で I-JAS のデータを検索する方法を具体的に示した。I-JAS の検索によって、我々は、様々な用例だけでなく、各種の頻度データを得ることができる。学習者コーパス研究では、質的な用例分析と計量的なデータ分析が車の両輪となる。本章では、このうち、後者に注目し、計量的な学習者コーパス研究の進め方について入門的な解説を行う。

計量研究の実践に関して述べるべきことは多いが、ここでは、(1) 必要標本数の確認、(2) 有意性検定、(3) 多変量解析の 3 点に限って、その概要を示したい。また、計量研究をめぐる最近の学界の状況についても言及を行う。

11.2 必要標本数の確認

11.2.1 必要標本数とはなにか

母語話者コーパスと異なり、学習者コーパスのサイズは総じて限定的である。ゆえに、学習者コーパスの研究者は、議論しようとする母集団に対して手元のデータがどの程度の代表性を持っているか確認しておく必要があるだろう。

統計学では母集団に対して必要な標本数を決める公式が存在する。母集団の人数を N 、想定する回答の枝分かれ率を p (通例 0.5)、許容する誤差を ME (Margin of Error)、必要とする信頼水準 (Confidence Level : CL) に呼応する定数を k とすると、必要な最低標本数 n は以下の式で定義される (Ishikawa, 2017; 石川, 2019b)。



第4部

I-JAS の分析

本書第1部ではI-JASの構築過程を示し、第2部では収集されたデータを計量的に概観し、第3部ではI-JASの使用方法について述べた。第4部では、これまでの議論をふまえ、I-JASデータを用いた簡単な研究の一例を示したい。第4部には5つの章が含まれるが、第12章と第13章では、作文データをマクロ的に分析し、その全体特徴を議論する。一方、第14章と第15章では発話の書き起こしデータを用い、個別的な調査対象を設定した上で、ミクロ的に問題を検討する。第16章では本書全体の総括と今後の展望を示す。

まず、第12章では、jReadabilityというオンラインシステムを用いてストーリーライティングの作文データを分析し、語数・漢字等使用率・文長等を議論する。

第13章では、同じくjReadabilityを使用してストーリーライティングの作文データを分析し、語彙レベルとリーダビリティを議論する。

第14章では、対話タスクのデータを用い、語彙の中でも、とくに副詞に対象を絞って、その使用状況を概観する。

続いて、第15章では、同じく対話タスクのデータを用い、語法・文法の中で、とくに、丁寧体否定文の使い分け(ないです/ません)の問題を取り上げて検討する。

最後に、第16章では、関連する研究分野(日本語教育・第二言語習得研究、縦断研究、計量言語学研究、世界の学習者コーパス研究)から見たI-JASへの期待について述べる。

第12章

作文における産出量と語彙特徴

12.1 はじめに

多くのコーパス分析では、何らかの検索システムに対して、キーワードを入れて、データを得るという方法が用いられている。これは、コーパスの部分に対するアプローチであり、コーパスをミクロ的に分析していることになる。

これとは別にコーパスデータの全体を丸ごと分析するという方法がある。これはコーパスに含まれるテキストデータを何らかの解析システムで解析し、数値データを得る方法であり、コーパスを言わばマクロ的に分析していることになる。

前者の方法を部分検索型と呼ぶなら、後者の方法は全文解析型の研究と呼ぶことができる。

表1 部分検索型と全文解析型

部分検索型が有効な場合	全文解析型が有効な場合
<ul style="list-style-type: none">● 調査のターゲットが明示的に決まっている場合● 何らかの仮説を持っている場合● 特定の語句の使い方を細かく調査したい場合	<ul style="list-style-type: none">● 調査のターゲットは必ずしも明示的でなく、データを解析しながら事実を発見したい場合● コーパス全体の傾向を把握したい場合

部分検索型は、いわゆる仮説検証的研究や課題解決的研究において有効と言える。一方の全文解析型の研究は、データから仮説を発見していくタイプ

第13章

作文における語彙レベルとリーダビリティ

13.1 はじめに

第12章では、I-JASのストーリーライティング収集された作文データを分析することで、習熟度の上昇に伴い、語数・タイプ／トークン比率(TTR)・漢字使用率・内容語使用率・文長等に変化が生じることを確認した。本章では、この議論を発展させ、作文における語彙のレベルと作文全体のリーダビリティを概観することとしたい。

この目的に即し、「日本語教育語彙表」の6段階の語彙難易度(Sunakawa et al., 2012)と「jReadability」の6段階の文章難易度(李, 2017)に基づいてI-JASのストーリーライティングのデータを分析する。

分析データの作り方は12.2節と同様であるため、13.2節では、「日本語教育語彙表」の概要と「jReadability」を使った研究事例を紹介し、13.3節で結果を述べる。

13.2 データと方法

13.2.1 「日本語教育語彙表」

語彙の難易度に関する調査研究では、旧日本語能力試験の「出題基準」を用いた研究が多いが、「出題基準」はテスト作成のための資料であること、1980年代に作成された古い資料であることから、本書では「日本語教育語彙表」を使用する。

「日本語教育語彙表」とは、日本語教育用の語彙データベースであり、17,929語の見出し語で構成されている。この語彙表には、すべての見出し語に対して、6段階の難易度「初級前半語彙、初級後半語彙、中級前半語彙、

第14章

発話における副詞の使用

14.1 はじめに

すでに述べたように、学習者のL2産出を分析するには、その全体的な性質を大掴みにすることを目指すマクロ的なアプローチと、特定の語彙や文法項目に絞って調査を行うミクロ的なアプローチが存在する。第12章と13章では、マクロ的なアプローチによる調査の実践例として、jReadability(李, 2017)というオンラインサイトを使用し、I-JASのストーリーライティングタスクで得られた作文データを「全文解析」し、学習者の習熟度に応じて、語数・漢字漢語使用率・文長・語彙レベル・リーダビリティがどのように変化するかを概観した。

これに対し、第14章と第15章では、調査対象をより狭く絞ったミクロ的なアプローチに基づき、発話データ分析の実践例を示す。第14章では語彙に関して「学習者の副詞使用」を、第15章では文法・語法に関して「学習者の丁寧体否定文使用」を論じる。

なお、こうした調査を実施するには、(1)コーパスから必要な用例を抽出し、(2)用例を整理し、(3)頻度情報を取り出して分析する、という一連のプロセスが必要になる。本章および次章では、読者が自身で分析過程を追体験できるよう、また、読者自身の関心テーマについて独力で分析を行えるよう、分析の手順についても詳しく解説することとしたい。

14.2 学習者による副詞の使用

日本語の各種品詞の中で、副詞は行為の程度や状態を示す働きを持つ。副詞には様々なものが存在するが、くだけた発話ではどのような副詞が多く使

第 15 章

発話における丁寧体否定文の使用

15.1 はじめに

第 14 章では、調査対象を絞ったミクロ的なアプローチによる研究の実例として、発話における語彙、とくに、学習者の副詞使用の問題を取り上げた。第 15 章では、文法・語法に注目し、同じく発話における学習者の丁寧体否定文使用の問題を考えてみたい。

文法や語法については、従来、正用と誤用を厳格に二分する研究が多かったが、コーパス研究の進展に伴い、両者は連続体に位置付けられるようになり、「言えるか言えないか」よりも、「どのような環境で何がどの程度どのように用いられるのか」という言語の「振る舞い」の解明に研究上の関心が向けられるようになってきている。本章においても、こうした立場から、丁寧体否定文使用の実態を探っていく。

15.2 学習者による丁寧体否定文の使用

学習者の問題に入る前に、まずは、母語話者の状況を考えてみよう。そもそも、日本語の文否定は、普通体(常体)では 1 つの文型しか存在しないが、丁寧体(敬体)では 2 つの文型が存在する。

- (1) 私はそれを知らない。
- (2) 私はそれを知りません。
- (3) 私はそれを知らないです。

ここで問題になるのは、動詞否定におけるマセン系とナイデス系の使い分