

計算機による日本語文書校正のための
基礎データの収集と解析

3B-6

その1 KWICによる特定表現の抽出とその結果

鈴木 恵美子 中山 妙子 吉岡 千草 山田圭以 福田恭子
東京家政学院筑波短期大学

1. はじめに

コンピュータは数値計算をするためのものだと思われており、実際大量の数値データの処理に威力を発揮しているが、私たちのゼミでは、将来的には計算機(ワードプロセッサ)により日本語文書の校正処理を行うことを目的とし研究を進めている。それを行うためにはまず、大量の日本語文書の構成に関するデータと起こり得る誤りのデータを収集し、統計を取る必要があると考えている。

今回は、これらを行うための基本的なツールであるKWICのプログラムを開発した。また、これを使用して、特定の表現(論文や報告書によく使われる「～に関する」、「～に対する」)の出現状況やその表現の前後の単語関係を調べて、その結果を考察したのでそれについて述べる。

それぞれ200以上のひらきがあることがわかる。「～に関する…」が1つ出現するために必要な頁数は、Vol.8で2.55ページ、Vol.21で5.62ページと3ページ以上も差があるのに対し「～に対する…」が1つ出現するために必要な頁数は、Vol.8、Vol.10を除いては平均している。当初、この数字をもとに「～に関する…」 「～に対する…」それぞれ5000例を収集することを目標として読み進めたが、物理的に入手できる論文誌の数も制限があったため、最終的に論文誌158冊、「～に関する…」が3398例、「～に対する…」が3800例で、収集作業は終了した。全体的に見ると、古い年代に発行された論文誌より、新しい論文誌の方が「～に関する…」 「～に対する…」の出現率が高いことがわかった。しかし、Vol.20 Vol.21では減少している。これは、雑誌の名前がVol.19までは「情報処理」だったが、Vol.20からは、「情報処理学会論文誌」と変わると共に内容が変化したためだと考えられる。

2. 大量の文書からの
特定表現の抽出

図1 Vol.ごとの総出現数(～に関する) 図2 Vol.ごとの総出現数(～に対する)




図3 No.に対する総出現数(～に関する) 図4 No.に対する総出現数(～に対する)




図1よりVol.ごとにみた「～に関する…」の出現数は最高値がVol.19の326、最高値がVol.9の80で、範囲は246である。

図2よりVol.ごとにみた「～に対する…」の出現数は最高値がVol.18の367、最高値がVol.8の49で、範囲は318である。

図3よりNo.ごとにみた「～に関する…」の出現数は最高値がNo.6の455、最高値がNo.11の152で、範囲は273である。

図4よりNo.ごとにみた「～に関する…」の出現数は最高値がNo.6の455、最高値がNo.8の221で、範囲は234である。

3. 入力ファイルの
形態について

人手によって見つけられた、キーワードを含む一文をMS-DOSファイルにキーワードから入力してデータファイルを作成する。データを入力する際の注意としては、

1. 全て全角で入力する
2. 公式は記号化して別に記録しておく
 $ax^2 + bx + c \rightarrow (式A)$

```

大小区別(無効)INS
a:kan15.dat (前西面) level=1 (X001:Y00001)
1 スパース行列処理に関する通常のGauss消去法の消去順序を変更すること
2 により、発生する非零要素数に関して、ほぼ消去の全域にわたり、かなり改良
3 されたアルゴリズムを提案した。
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44

```

図5 入力ファイル

Collection of data and its analysis to be used for Japanese proofreading by using the computer
emiko SUZUKI, taeko NAKAYAMA, chigusa YOSIoka, kei YAMADA, yasuko FUKUDA
Tokyo Kaseigakuin Tsukuba Junior College

本研究は、財団法人日本科学協会の御財科学研究助成によって実施したものです。

4. 特定表現の抽出方法

ここで、KWICのプログラムの流れについて述べる(図4参照)。

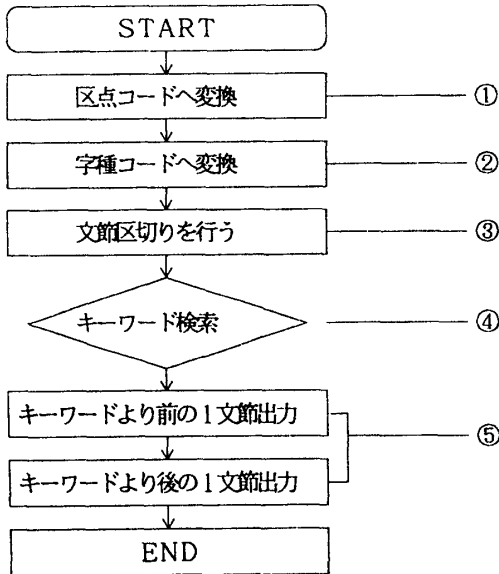


図6 KWICのフローチャート

2バイトコードのままでは、文節区切りの判断が煩雑になるため、①の部分で全ての文字を区点コードに変換する。

次に②の部分で区点コードを見て、字種別にコード化する。

表1 区点コード別字種コード

記号	区点コード	字種コード
記号	0102~0390	6
ひらがな	0401~0483	0
カタカナ	0501~0586	1
漢字	1601~9404	2

ここで、我々が必要としていたのは、キーワードの前後一文節のみであるが、後の処理のことを考えて③の部分で予め、文全体を文節区切りしておく。

文節区切りの基準としては、日本語の文章は普通ひらがなから漢字が変わる所で文節が区切れるので、それが出現したら文節として区切りとした。さらにその他にも文節が区切れると思われる場合(「私のコンピュータ」などは、ひらがなからカタカナに変わる時に文節が区切れる)についても文節区切りの条件とした。

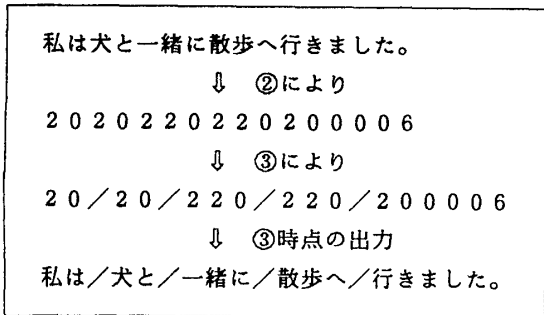


図7 文節区切りの例

④の部分でキーワード(ここでは「～に関する」と「～に対する」)を本文中から探索する。

⑤の部分で、予め処理③で区切られた文章のうちは前後一文節だけを出力する。

5. 出力結果

下にKWICのプログラムを実行した時の出力結果を掲げる

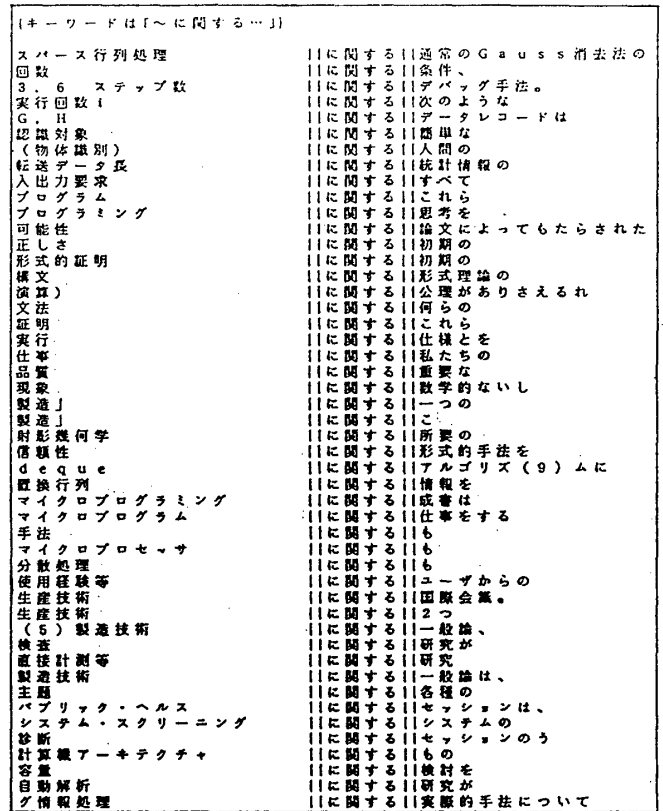


図8 出力ファイル

6. おわりに

今後の課題としては、今回のKWICのプログラムでは入力形式に制限があったので、今後なくしていくことと、文節区切りの精度を上げることである。また、次に発表する辞書を使用して辞書引きできるようにしたい。

【参考文献】

- 1) 千早 耿一郎 「悪文の構造」, 木耳社
- 2) 情報処理学会第45回全国大会講演論文集
- 3) 田中 他 「日本文の自動分かち書き(ひら仮名文字列の分かち書き)」, 情報処理学会第20回全国大会講演論文集
- 4) Borland international, Inc. 「Turbo Pascal リファレンスガイド」, (株) マイクロソフトウェア アンシエイツ