

本文研究の立場からみたテキスト・データベースの機能について

田 嶋 一 夫 ・ 星 野 雅 英 (国文学研究資料館)

1. はじめに
2. 文学研究におけるテキスト情報の活用
3. 索引誌作成の現状と問題点
4. テキスト・データベースの必要性

1. はじめに

人文科学という学問において、テキスト(本文)そのものが研究対象となる分野は、文学、歴史学、言語学、国語学、心理学、等が考えられる。なかでもテキストに対する研究比重の高いところは文学である。ここでは、その研究の全体にわたってテキスト分析がかかわっていると言える。その他においても、いわゆる“本”が研究対象となるところでは、そのテキストの緻密な分析が必ず伴うであろう。こうした意味でテキストのデータベースの活用される分野は、人文科学研究のすべてと言っても過言ではない。しかし、もっとも多くのかかわりを持ち、重要な資料としての意味を持つのは文学研究である。

しかし、文学研究の中でも、テキストが分かち書きされている英文学や仏文学等の西欧文学と、日本文学のように分かち書きされていない分野では、大きな差違がある。ここでは日本文学のテキストを念頭におきつつ、テキスト・データベースのあり方について考察する。

2. 文学研究におけるテキスト情報の活用

テキストを主な研究対象とする文学研究において、テキストの情報をどのように活用するかを考えると、およそ次の2点になる。

1) 本文批判の際の資料として

2) 作品分析、本文分析の際の資料として

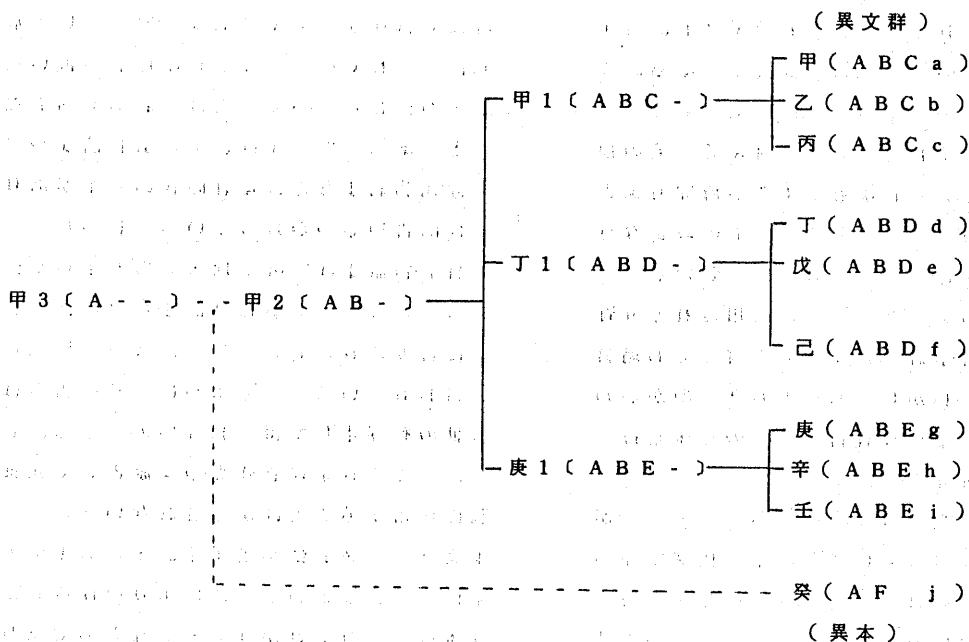
まず、本文批判の問題を考えると、文学研究(古典)のテキストは、写本という形で伝えられている。しかし原作者の書いた原本が伝存していることはきわめて稀有なことである。たとえば、「伊勢物語」や「源氏物語」などは鎌倉時代の写本があり比較的古いものが残っている。しかし、「竹取物語」は室町末期までの写本しか伝わっていない。「蜻蛉日記」などは江戸初期に書写されたものまでしか残っていないと言われている。このように多くの古典は後世の転写本しか得られないのである。したがってこれを成立時点の文献として無批判に使用することはゆるされない。ここに本文批判の必要性が生ずる。またテキストを伝える書写という方法により製作された写本は、それぞれがユニークなものであり、絶対に同一の写本はありえない。しかも各写本は必ずその依拠した親本の特徴的な本文の影(因子)を保持しているはずである、と考えられる。とするならば、現存するばらばらで相互に孤立していると思われる写本群について、その本文の特徴的な因子(異文)を比較対照発見し、分析、整理することによって、しだいにその祖先の本文に近づきうると思われる。これにより原作者の原本への遡源も可能であると論理的

には考えられる。

一例として書写の系譜を考えて見よう。ここに甲乙丙丁戊己庚辛壬癸という10本の写本があったとする。この10本を校合した結果A B C D E F a b c d e f g h i jの16個所の異文群が発見できたとする。この異文群が次図のようであったとすれば、甲乙丙の3本にはA B Cという共通本文があり、これが他の7本に比してより類似性が濃いと判断され甲1という共通祖本を持つと考えられる。同様にして丁戊己の3本

は丁1を共通祖本に、庚辛壬の3本は庚1を共通祖本に持つと考えられ、3系統に整理される。この3系統本は、C・D・E・-の異文群を持つ。同様にして遡っていけば、甲2、甲3が想定されてくる。これに対して癸本は他の3系統の9本に対して、より多くの固有本文群を持っていることになるから、異本関係にあると言える。(以上本文批判に関しては、伊地知鉄男編著「日本古文書学提要」の“文献学”の項を参照した。)

図



以上のようなプロセスを経て、共通の祖本の本文に近づきうると考えられる。このような異文の調査に本文情報の活用が考えられる。

次に本文分析や作品分析の問題を考えて見よう。一つの作品の形象性を分析する際に、あるキーワードをさがしだし、キーワードを分析する手がかりを見つけるなら

ば、きわめて有効な研究方法となる。この際Aという作品から見つけ出されたキーワードをB C D Eという作品におけるその語との用法上の違いを分析すれば、A作品の性格の一部を明らかにすることは可能である。また、使用語彙を計量的に分析し作品を解釈、分析することも可能であろう。さらには文体的特質の分析から、作品分析

を行うことも可能であろう。こうした方法をとる際に本文情報、ことに語彙情報が活用されている。

3. 索引誌作成の現状と問題点

次にテキストに対する情報がどのように活用されているかを見、かつかつそこにどのような問題点があるかを知るために索引誌作成の現状を分析する。

すでに、多くの語彙索引や術語、事項の索引が、文学研究や言語研究、歴史学の研究を目的として作成され公刊されている。これらは一部の例外を除いて手作業で作られている。この索引作成には膨大な労力が費やされている。これらの索引類を形式の面から整理してみると、

1) テキスト中に含まれるすべての語を対象として、その出現個所だけを示した総索引。→例1

2) テキスト中に含まれるすべての語を対象として、見出し語をたて、その出現個所を示し、さらにその語を含む句または、文脈まで示した総索引。→例2

3) ある索引について複数テキストを対象として、またその中のすべての語を対象として、語の位置を示し、さらに文脈まで示した文脈付き総索引。→例3

4) ある作品中から特定の語(人名、地名等)のみをとり出し、その語のテキスト中における出現個所を示した部分索引。→例4

5) あるテキストについて、句を見出し語として、その出現個所を示した句索引。→例5

6) 各種の資料(複数テキスト、複数作品)を対象として、術語をとり出し、その術語の含まれる文を掲出した事項索引。→例6
等になる。

索引例1

(「源氏物語大成」より)

あがり(上)①	四〇五
あがり(下)②	四〇六
あがり(上)③	四〇七
あがり(下)④	四〇八
あがり(上)⑤	四〇九
あがり(下)⑥	四一〇
あがり(上)⑦	四一一
あがり(下)⑧	四一二
あがり(上)⑨	四一三
あがり(下)⑩	四一四
あがり(上)⑪	四一五
あがり(下)⑫	四一六
あがり(上)⑬	四一七
あがり(下)⑭	四一八
あがり(上)⑮	四一九
あがり(下)⑯	四二〇
あがり(上)⑰	四二一
あがり(下)⑱	四二二
あがり(上)⑲	四二三
あがり(下)⑳	四二四
あがり(上)㉑	四二五
あがり(下)㉒	四二六
あがり(上)㉓	四二七
あがり(下)㉔	四二八
あがり(上)㉕	四二九
あがり(下)㉖	四三〇
あがり(上)㉗	四三一
あがり(下)㉘	四三二
あがり(上)㉙	四三三
あがり(下)㉚	四三四
あがり(上)㉛	四三五
あがり(下)㉜	四三六
あがり(上)㉝	四三七
あがり(下)㉞	四三八
あがり(上)㉟	四三九
あがり(下)㊱	四四〇
あがり(上)㊲	四四一
あがり(下)㊳	四四二
あがり(上)㊴	四四三
あがり(下)㊵	四四四
あがり(上)㊶	四四五
あがり(下)㊷	四四六
あがり(上)㊸	四四七
あがり(下)㊹	四四八
あがり(上)㊺	四四九
あがり(下)㊻	四五〇
あがり(上)㊼	四五〇
あがり(下)㊽	四五〇
あがり(上)㊾	四五〇
あがり(下)㊿	四五〇

索引例2

(山田編「竹取物語総索引」より)

あがり(上)①	四〇五
あがり(下)②	四〇六
あがり(上)③	四〇七
あがり(下)④	四〇八
あがり(上)⑤	四〇九
あがり(下)⑥	四一〇
あがり(上)⑦	四一一
あがり(下)⑧	四一二
あがり(上)⑨	四一三
あがり(下)⑩	四一四
あがり(上)⑪	四一五
あがり(下)⑫	四一六
あがり(上)⑬	四一七
あがり(下)⑭	四一八
あがり(上)⑮	四一九
あがり(下)⑯	四二〇
あがり(上)⑰	四二一
あがり(下)⑱	四二二
あがり(上)⑲	四二三
あがり(下)⑳	四二四
あがり(上)㉑	四二五
あがり(下)㉒	四二六
あがり(上)㉓	四二七
あがり(下)㉔	四二八
あがり(上)㉕	四二九
あがり(下)㉖	四三〇
あがり(上)㉗	四三一
あがり(下)㉘	四三二
あがり(上)㉙	四三三
あがり(下)㉚	四三四
あがり(上)㉛	四三五
あがり(下)㉜	四三六
あがり(上)㉝	四三七
あがり(下)㉞	四三八
あがり(上)㉟	四三九
あがり(下)㊱	四四〇
あがり(上)㊲	四四一
あがり(下)㊳	四四二
あがり(上)㊴	四四三
あがり(下)㊵	四四四
あがり(上)㊶	四四五
あがり(下)㊷	四四六
あがり(上)㊸	四四七
あがり(下)㊹	四四八
あがり(上)㊺	四四九
あがり(下)㊻	四五〇
あがり(上)㊼	四五〇
あがり(下)㊽	四五〇
あがり(上)㊾	四五〇
あがり(下)㊿	四五〇

これらを分析してみると、次の点が指摘できるであろう。

1) 近年公刊されている索引の多くは、比較的小さな作品ないしは中程度の作品に限られていることである。「源氏物語」の索引(例1)は、索引部だけで合計1,500ページ(3分冊)に及ぶものであるが、これが刊行されたのは昭和28年である。また「古事類苑」(例6)は、洋装本で四六判50冊。明治12年に建議され大正7年に完成したという。30年に及ぶ大事業であったが、これはほぼ60年前のことであった。

2) 作品研究の進展は、一作品で一つのテキストのみならず複数テキストの索引を要求する。「竹取物語」研究のように、研究が進展し、より精緻な研究となっているところでは、例2、例3のように複数の索引が作られている。しかも例3のように九本のテキストを対照した索引までも作られている。

3) 複数作られた索引を見ると、見出し語(索引語)のとり方が微妙に異っているのである。これは研究者(索引作成者)にとって、語の認定に差違が生ずることと、語の単位がその研究目的、方法、さらに対象によって異っていることを意味する。したがって一つの固定の索引では、すべての研究者の要求を満たせないことを意味している。

4. テキスト・データベースの必要性

以上のように、テキスト情報の活用方法、テキスト情報の活用上の一側面としての索引誌の現状を見てみると、単に語のデータベースを作るのではなく、テキストそのもののデータベース化が望まれる。このデータベースは、単に現在公刊されているよう

な索引誌を作るベースとするだけではなく、語や句に対する要求、一文中の2~3語の組み合わせの検索、センテンスを検索する要求等、多様な要求に応えうること。また文学研究の多様な側面(本文批判や作品分析等)に応えうること。等をシステムのサポートすることが必要であろう。

このためには、データベースとしてのごく一般的な条件の他に、語や文の認識をさせておくこと。本文以外の情報(例えば、品詞情報など)をも保持しうること。がテキスト・データベースの必要条件であると言えよう。これを可能とする蓄積構造を持つことが不可欠であると考ええる。

本研究は、昭和55~56年度文部省科学研究費試験研究(2)(課題番号00581009)「国文学情報検索システム及び索引誌の作成に関する研究」(研究代表者 市古貞次)の一部であることを付記する。