

ICOT Technical Memorandum: TM-1099

TM-1099

日本語文章の構造化解析

福本 淳一、安原 宏(沖)

September, 1991

© 1991, ICOT

ICOT

Mita Kokusai Bldg. 21F
4-28 Mita 1-Chome
Minato-ku Tokyo 108 Japan

(03)3456-3191~5
Telex ICOT J32964

Institute for New Generation Computer Technology

日本語文章の構造化解析

福本 淳一 安原 宏

沖電気工業(株)総合システム研究所

概要

論説文は、ある事柄についての書き手の考え方や意見など書き手の主張を述べることを目的とした文章であり、このような文章においては、書き手の主張を読み手である読者に伝えるために論旨が展開されている。この論旨の展開構造が、文章の構造であり、書き手が文章において主張したいことであると考えられる。本稿では、このような文章の構造化のため、新聞社説記事を用いた文脈現象の解析を行った。その結果を基に文章構造のモデルについて考察した。

Japanese Text Structure Analysis

Jun-ichi Fukumoto, Hiroshi Yasuhara

Systems Laboratory, Oki Electric Industry Co., Ltd.
11-22, Shibaura 4-chome, Minato-ku, Tokyo 108, Japan

Abstract

Japanese texts such as newspaper editorials are written to show writer's opinion and thinking to readers. I call such opinion "Writer's intention". Such kinds of texts are composed centering around the Writer's Insistence. In this paper, we analyzed context phenomena in Japanese newspaper editorials and stored context data from these texts. We discussed text structure model based on this analysis.

1 はじめに

論説文は、ある事柄についての書き手の考え方や意見などの書き手の主張を述べることを目的とした文章であり、このような文章においては、書き手の主張を読み手である読者に伝えるために論旨が展開されている。この論旨の展開構造が文章の構造であり、書き手が文章において主張したいことであると考えられる。現在までに筆者らは、論説文として新聞の社説記事をとりあげ、書き手の主張という観点から文章の構造化についての分析を行ってきた[1]。構造化のため、まず、文章中の各文を書き手の主張に基づいてタイプ分類を行い、各文のタイプ情報と主題提示情報、および、文章中に表れる接続詞等の機能語の情報を用いることで文の連接関係を求め、これにより文章を木構造の形式に構造化を行ってきた。文章全体は、話題の転換部分でいくつかの部分構造の分割し、各部文構造においては、その中で中心となる主張文を根とする木構造となっている。

本稿では、この文章構造の詳細化のため、新聞社説記事を用いて文章中に表れる文脈現象として照応現象と文の連接関係についてのデータの抽出を行い、そのデータの解析から文章構造のモデル化のための考察を行った。

以下では、2章で文脈現象のデータとして抽出を行った照応現象データ及び文の連接関係データについて述べた後、3章で文章構造のモデル化について述べる。

2 文間関係の解析

文間の関係を決定する要因としては、名詞語句等の照応関係、指示語による関係、一貫性関係、接続詞等の語句による関係等がある[4][6][7]。ここでは、新聞社説記事を調査対象とし、社説文章中に表れる照応現象、文の連接関係についてのデータの収集を行い、そ

の解析を行った。

2. 1 照応現象の調査

照応現象とは、コンテキスト内のある要素をその前後にいる文の中において、別の形式で表現する現象のことと言う。あるいは、名詞などの語句が、その前後のコンテキスト内で言及されているモノ・コトを指示参照する現象であるとも言える[2]。我々は、文章中の関連性のある語句の関係が文間の関係の決定にどのような影響を与えていたかの調査をして照応現象を調査を行ってきた[2]。そこでは、文章中で関係があると思われるもの語句を広く収集し、これをデータとして蓄積した。照応現象データは、照応語とそれが指示参照するものである先行詞とこれらの間の照応関係について、図1に記入フォーマットを用いて収集した。

<先行詞>		<照応語>	
パラグラフ番号	文番号	パラグラフ番号	文番号
述語		述語	
照応語又は先行詞	: 構要書	照応語又は先行詞	: 構要書
(付高語)		(付高語)	
備考:			

図1 照応現象データ調査フォーマット

調査対象としては、昭和62年8月から10月までの朝日新聞社説記事70編を用いた。各項目の抽出基準は以下の通りである。

(a) 照応語

- ・人称代名詞 「彼」など
- ・ゼロ代名詞 (明かに省略されていると判断できる主格のものについてのみ調査する)
- ・指示代名詞 「これ」「それ」
- ・指示連体詞 「この」「その」+体言
- ・指示連用詞 「こう」「そう」+用言

- ・サ变动詞の語幹
- ・名詞、名詞句
- ・代名詞的表現 「両国」「同氏」など

(b) 先行詞

照応語によって指示参照されている語、句、文、パラグラフを選択した。また、照応語が文章中の内容を指示参照している場合は、その内容を含む文、パラグラフを選んだ。背景的な知識などにより推定されるものについては、対象外とした。

(c) 照応関係

- ・同一名詞による照応
- ・上位－下位関係
- ・部分－全体関係
- ・指示語による照応
- ・ゼロ代名詞による照応

(d) 照応の距離

照応関係の存在する文間の距離を測定する。
前方照応の場合に正值をとる。

以上の基準に基づき3003件のデータの収集を行った。照応関係別に分類したものを見ると示す。

表1 照応関係分類表

関係名	件数
同一名詞	2108
上位－下位関係	75
	80
部分－全体関係	53
	58
指示語	10
	453
ゼロ代名詞	166
	5
合計	3008

2.2 文の連接関係の調査

文章構造の解析を行うため、照応現象データの収集に用いた同じ社説文章を用いて文章中の任意の文の間に認められる文間関係データを図2の記入フォーマットにしたがって収集した。

<前文>	<後文>
パラグラフ番号－文番号 文タイプ名【上位タイプ名】	パラグラフ番号－文番号 文タイプ名【上位タイプ名】
関係名	
備考:	

図2 文間関係データ調査フォーマット

調査は、新聞社説記事において文章中の任意の2文を選択し、その間に存在する文間関係が存在する場合、その前の文を前文、後の文を後文とし、その文間に存在する関係を設定した。また、それぞれの文タイプ情報についても設定した。この調査で用いた文タイプ名、関係名は以下のとおりである。

(1) 文タイプ名

これまでに、書き手の主張という観点から文章中の文を主張文と叙述文に分類を行い、主張文を8つに細分類してきた。この主張文の分類に加え、叙述文についても10に細分類を行ったものを文タイプ情報として用いた。以下にその意味と新聞社説記事中に現れた表現を示す。

○主張文

- ・問掛文…疑問表現を用いて書き手が読み手に対して問い合わせを行う
のではあるまいか どう～のか
恐れはないか どう～だろうか
ありはしないか あるのだろうか
- ・断定文…書き手がある事柄について断定を行う
である ことである
のである 明らかである

- のではない のだ
- ・推量文…書き手が推測で物事を述べる
 - だろう ではあるまい
 - べきだろう とはいえない
 - かもしれない やむをえまい
 - ・要望文…書き手がある要望を述べる
 - ~たい 期待する
 - ~したい てもらう
 - てほしい てもらいたい
 - ・判断文…書き手がある判断を行う
 - と考える はずだ
 - はずはない といえる
 - とは言いがたい ているようだ
 - ・意見文…書き手の意見を述べる
 - ではならない 必要がある
 - 望ましい 必要である
 - 当然だ 大切だ
 - ・理由文…話題になっている事柄についての原因理由を述べる
 - からだ ているからである
 - わけだ わけではない
 - ためだ
 - ・義務文…義務的な表現を述べる
 - なければならない べきだ
 - ねばならない べきである

○叙述文

- ・現在 「る」で終わる形
- ・過去 「た」で終わる形
- ・可能 できない いえない
- ・伝聞 と聞く という
- ・様態 強い 厳しい 多い
- ・叙述 名詞+だ
- ・存在 がある はない にある
- ・継続 つつある
- ・状態 ている てくる てしまう
- ・使役 させる せる

(2) 関係名

文間関係の分類としては、永野[4]や市川[5]

によるものがある。これらをもとに、次のような文間関係を設定した。

結果	目的	逆接	序列	追加
並列	累加	対立	比較	転換
限定	反復	根拠	制約	補充
連係	呼応	前提	背景	例示

以上の記入要領にしたがって朝日新聞朝刊社説記事70編から2145件の連接関係データの収集を行った。データを関係名ごとに分類したものを表2に示す。

表2 文間関係分類表

関係名	件数
背景	118
累加	362
対立	42
根拠	78
前提	57
序列	19
転換	450
制約	12
結果	12
追加	56
反復	78
補充	218
目的	5
並列	77
例示	80
連係	283
逆接	160
比較	7
限定	16
呼応	15
合計	2145

収集したデータのうち接続詞等の語句によって決まった関係を除いたものを、主張文-叙述文、叙述文-主張文、主張文-主張文の文間関係についてまとめたものをそれぞれ表5、表6、表7に示す。叙述文-叙述文に関して

は、タイプ間の関係から得られる関係に傾向がなかったため、ここでは除外した。

これらの文間関係データの解析およびこれらの関係の見直しを行うことで、文タイプ情報によって文間の関係を決定することができるもののがいくつか存在した（主張文—主張文について15件、主張文—叙述文について6件）。その他のものについては文タイプ情報だけでは文間の関係を決定することができなかった。

2.3 文脈現象データの解析

文の連接関係と照応現象の関連を調査するため、同一文間に照応現象データと文間関係データが共に存在するものについて調査を行った。調査結果をまとめたものを表3に示す。また、各連接関係での各照応関係の割合を示したものを見4に示す。

表3 文間関係と照応現象との関連表

関係名	全体	階不等	ゼロ代	同一名詞	全体・部分	部分・全体	下位・上位	上位・下位
結果	8	6	1	1	5	0	0	0
目的	2	2	0	0	0	0	0	0
並列	65	23	7	32	0	1	4	1
序列	4	0	1	3	0	0	0	0
追加	15	6	3	5	0	0	0	1
並列	11	1	2	8	0	0	0	0
原因	144	67	15	62	4	1	4	4
対立	13	5	0	7	0	0	2	1
比較	3	1	0	2	0	0	0	0
転換	97	12	1	72	5	2	2	3
範囲	3	2	0	1	0	0	0	0
反復	21	9	9	9	0	0	0	0
順序	33	9	4	16	0	0	5	2
制約	2	0	0	1	0	0	1	0
研究	128	35	12	66	3	2	3	3
連係	65	23	6	33	1	1	1	1
時序	3	1	0	2	0	0	0	0
前後	27	8	3	14	0	0	0	2
背景	52	25	5	26	5	1	0	0
指示語	22	4	3	13	0	0	2	4
合計	729	237	66	367	16	6	19	13

（数字は、件数を示す）

部分—全体、全体—部分、上位—下位、下位—上位、ゼロ代名詞の各関係については、データ数が少ないため連接関係を決定することができなかった。指示語については、累加、背景関係が比較的多く表れ、転換関係が少ないという傾向があった。このことから指示語が用いられた場合、その指示語の参照している文に関して話題が変わらず、前文を引き継いだ内容が述べられる傾向がある。同一名詞

表4 各照応現象の割合

関係名	表示語	ゼロ代	同一名詞	全体・部分	部分・全体	下位・上位	上位・下位
結果	75	13	13	0	0	0	0
目的	100	0	0	0	0	0	0
並列	34	10	47	0	1	6	1
序列	0	25	75	0	6	6	0
追加	40	20	33	0	0	6	7
並列	9	18	22	0	6	6	0
累加	42	10	43	3	1	3	3
対立	34	0	54	0	0	0	8
比較	33	0	67	0	0	0	0
転換	12	1	24	5	2	2	5
限定	47	0	33	0	0	0	0
反復	39	22	39	0	0	0	0
範囲	27	12	48	0	0	6	6
制約	0	0	50	0	0	30	0
補充	28	10	55	3	0	3	3
連絡	35	9	49	2	2	2	2
時序	33	0	67	0	0	6	0
前後	30	11	52	6	6	6	7
背景	44	4	38	4	2	6	0
指示語	18	14	59	6	6	9	0
合計	33	9	50	2	1	3	2

（数字は、割合%を示す）

については、並列、転換関係が多く表れる傾向があった。並列関係は同じ内容が並列的に述べられているという関係であり、このような場合には同じ語句が用いられる傾向があることが分かる。しかし、同じ名詞が使われた場合でも転換関係が多くあらわれたことから、同一名詞語句の反復情報のみでは単純に話題の転換とすることはできなく、その他の情報が必要である。

また、話題の変わる部分である転換関係のみに注目して文の連接関係データの解析を行った。14社説分の連接関係データについて、各文タイプの連接関係のうち転換関係は以下の割合であった。

主張文—主張文	17% (9/53)
主張文—叙述文	54% (40/74)
叙述文—主張文	9% (8/91)
叙述文—叙述文	22% (24/111)

のことから、主張文に統く叙述文において話題の転換が行われる傾向が強いことがわかる。また、文においては、「は」等により主題の提示が行われるが、この情報を加えた上で主張文—叙述文について更に分類すると、

- | |
|------------------|
| ○ 叙述文で主題提示あり |
| 転換関係 27例　その他 16例 |
| ○ 叙述文で主題提示なし |
| 転換関係 13例　その他 17例 |

となる。したがって、主張文に続く叙述文において主題の提示が行われた場合、話題が転換すると扱うことができる。

3 文章構造のモデル化

これまでに我々は、文の連接関係を一方が主で他方が従であるような主従関係として提えることで文章の構造化を行ってきた。しかし、実際の文章中には以下のように主従を決定しにくいものとして、文章中で並列関係となる文や連続してある事柄が述べられる文がある。文章中で並列関係になるものとしては、ある文の連接関係が並列関係とされたものや、また「第1に」「第2に」「第3に」のような接続的表現を用いることで、いくつかの文がまとまった形で序列的に並んでいるものもある。（数字はパラグラフ番号・文番号を示す）

- | |
|---------------------------------------------------------------|
| 5-1 第1に、水の節約が、水道料金の値上げにつながるぬようにしなければならない。 |
| 8-1 第2に、給水配管の漏水対策を積極的に進めてほしい。 |
| 9-1 第3に、最も重要なのは、今回の水不足が、東京集中によってひき起こされた構造的な問題だ、という認識を持つことである。 |

（昭和62年8月30日付け朝日新聞社説記事より）

また、文間関係に主従関係がなく連続しているものとしては、以下のものがある。

- | |
|-------------------------------------------------|
| 1-1 ジョギング中の突然死や社長の急死などの不幸な事件が、このところ目立っている。 |
| 1-2 産業構造が変わり技術革新が進んで、働く人のストレスもつのってきた。 |
| 1-3 高齢化への歩みが速まるなかで、働き盛りの中高年の健康管理が特に重要な問題になっている。 |

（昭和62年10月2日付け朝日新聞社説記事より）

この例では、いくつかの事柄が順に列挙されており、文間には直接は主従の関係に当るものは考えられない。

文の連接関係の中で主従関係は決定できないが、なんらかの関係があるものについてはそれらをグループとしてまとめて表現することで扱うことのできる。

また、従来まで部分構造として表現されていたものもこのグループ化によって表現することができる。これは、文章中の文の連接関係を主従関係として表現された木構造において、同じ内容について述べられている部分をグループ化することで表すことができる。このグループ化を部分構造内部にも取り入れることで、ある内容について述べられている部分がまとめられるため、木構造中の係り受けのスコープが表現される。

以上のように文章構造を表現するためには、各ノード間の連接関係を主従関係と認識することで文章を木構造の形に構造化することができる。その際、同じ話題について述べられているものはグループとしてまとめてノード間の係り受け関係のスコープを表現することができる。また、文間に連接関係は認められないが、話題の変化がないものや並列関係にあるものも同様にグループとしてまとめることができる。このようにして、文章の構造をネットワーク構造として表現することができる。

4 おわりに

本稿では、論説文などの文章を書き手の主張という観点から構造化するため、新聞社説記事を用いて文章中に表れる照応現象及び文の連接関係をデータとして収集し、その解析を行った。この解析から文の連接関係を決定する為のいくつかの規則性を見つけることができた。また、これらの調査を基にしてこれまでの木構造形式の文章構造をグループ化を用いることでネットワーク構造への拡張について考察した。

今後の課題としては、このような構造化のための文章の構造化のためのモデルおよびそのモデルに基づく言語仕様を定義し、この言語仕様で記述した規則を用いて文章構造の解析を行うことがある。そのための言語処理系の実現も必要である。また、文章構造を解析する規則を記述するため、文脈現象データの更に詳細な解析も必要である。

【謝辞】

本研究は、第5世代コンピュータプロジェクトの一環としてICOTからの委託で行われたものであり、研究を進めるにあたり有益な助言を下さいましたICOT第6研究室の田中室長に感謝いたします。また、研究協力頂いた沖電気工業(株)の甲斐氏、(株)沖テクノシステムズラボラトリの柴田、田中、斎藤各氏に感謝いたします。

【参考文献】

- [1] 福木淳一："筆者の主張に基づく日本語文章の構造化",情報処理学会自然言語処理研究会 78-15, 1990.
- [2] 柴田、田中、福木："新聞社説記事における照応現象",情報処理学会第40回全国大会, 1990.
- [3] 上野、正保、田中、菱沼、日向："日本語と外国語との照応現象に関する対照研究", 国立国語研究所報告79, 1984.
- [4] 永野賢："文章論総説－文法論的考察－",朝倉書店, 1986.
- [5] 市川孝："国語教育のための文章論概説",教育出版, 1978.
- [6] 木下、小野、浮田、天野："日本語テキスト理解における文脈構造抽出法",「談話理解モデルとその応用」シンポジウム, pp.125-136, 1989.
- [7] B.Grosz, C.L.Sidner："The Structures of Discourse Structure", Technical Report, CSLI, CSLI-85-39, 1985.

序 番	可視	保有	導入	叙述	比況	卒意	議題	状況	便候	現在	過去
開始文		開示1 開示2 開示3 開示4 開示5 開示6									
新定文	新定1 新定2	新定2 新定3 新定4 新定5 新定6									
議量文	議量1 議量2	議量1 議量2 議量3 議量4 議量5 議量6									
要説文		要説1 要説2 要説3 要説4 要説5 要説6									
判断文	判断1 判断2 判断3	判断1 判断2 判断3 判断4 判断5 判断6									
意見文		意見1 意見2 意見3 意見4 意見5 意見6									
理由文			理由1 理由2 理由3 理由4 理由5 理由6								
議論文		議論1 議論2 議論3 議論4 議論5 議論6									

表5 主張文-叙述文の文間関係

表6 叙述文-主張文の文間関係

類別	開端文	新定文	進度文	要復文	判斷文	意見文	理由文	總結文
可能	高級1 標準1 最低1	高級1 標準1	要復1 進度1	要復1 反復1 標準1				標準1
依附	進階2 反復2	反復2 比較1 標準1	進階1 標準1					
權威	標準1 標準2 顯示1 滿意2	進階2 標準2 顯示2 標準3 要復1 最高1 滿意2	要復2 標準2 顯示2 標準3 要復2 滿意2	要復1 標準1 最高1 滿意2	最高2 最高1 滿意2	標準1 要復1	最高2	
敘述	最高1 要復1 反復1 最高2 滿意2	進階3(最高) 要復1(要復2) 要復1(滿意3) 要復4(要復3) 要復2	進階3(最高) 標準1(滿意3) 要復1(要復3) 最高1 要復1(要復3) 要復2	要復1 標準1 最高1 滿意2 要復1 滿意2	最高1 標準1 最高1 滿意2 要復1 標準1 要復1 最高1 滿意2	進階1 標準1 最高1 滿意2 要復1 標準1 要復1 最高1 滿意2	最高1 標準1 最高2 滿意3 要復3	
主觀								
存在	最高1 滿意1	引用1 進階1 標準1 要復2 顯示1 滿意3	要復2 標準1 要復1 最高1 要復1 顯示1 滿意4	要復1 滿意1 要復1 滿意1	標準1 滿意1 最高2	進階1 標準1 滿意1	滿意1	
聽取		滿意1						
狀態	最高2 標準1 要復1 最高2 滿意1	引用1(要復2) 最高1(滿意2) 要復1(滿意3) 要復2 滿意4 要復3 最高1 滿意2 滿意5	引用1(進階2) 標準1(滿意2) 要復1(滿意3) 要復2 滿意4 要復3 最高1 滿意2 滿意5	要復1 標準2 滿意2 要復1 滿意3 要復2 滿意1 滿意5	要復1 標準4 滿意1 要復1 滿意3 要復2 滿意1 滿意6	最高2 最高4 滿意1 滿意3 滿意6	進階1 標準2 要復1 反復1 滿意1	最高1 標準1 要復1 最高2 滿意3
便移		反復4						
現在	進階1 標準2 要復2 反復1 標準1 要復2 滿意3	要復1(滿意2) 要復2(滿意1) 要復3(滿意1) 要復4(滿意1) 要復5 滿意4	要復2(最高1) 標準1(滿意2) 要復3(滿意1) 要復4(滿意1) 要復5 滿意4	引用1 要復4 標準1 要復1 要復3 要復2 滿意3	進階2 要復1 標準1 要復1 要復3 要復2 滿意4	標準1 要復1 滿意1 滿意2 滿意3	標準1 要復1 滿意1	進階1 標準1 要復1 反復1 滿意1
過去	進階1 標準1 要復1 滿意2	要復1(要復1) 要復2(滿意2) 要復3(滿意1) 要復4 滿意4	要復2 要復1 要復1 要復2 滿意3	要復1 要復1 標準1 要復1 滿意1	要復1 要復1 標準1 要復1 滿意1	要復1 要復1 標準1 要復1 滿意1	滿意1 標準1	引復1 要復1 最高1 滿意1

表7 主張文-主張文の文間関係