

Generating Candidates for Rewriting Based on an Indicator of Complex Dependency and It's Application to a Writing Tool

横林, 博

九州大学システム情報科学研究所知能システム学部門

菅沼, 明

九州大学システム情報科学研究所知能システム学部門

谷口, 倫一郎

九州大学システム情報科学研究所知能システム学部門

<http://hdl.handle.net/2324/5973>

出版情報：情報処理学会論文誌. 45 (5), pp.1451-1459, 2004-05. Information Processing Society of Japan

バージョン：

権利関係：ここに掲載した著作物の利用に関する注意 本著作物の著作権は（社）情報処理学会に帰属します。本著作物は著作権者である情報処理学会の許可のもとに掲載するものです。ご利用に当たっては「著作権法」ならびに「情報処理学会倫理綱領」に従うことをお願いいたします。



推薦論文

係り受けの複雑さの指標に基づく文の書き換え候補の生成と
推敲支援への応用横 林 博[†], 菅 沼 明[†], 谷 口 倫 一 郎[†]

文章の推敲支援を行うツールは多数存在するが、その多くは推敲支援に役立つ情報を提示するのみである。それらの情報を用いれば推敲作業自体は楽になるが、文章をどのように書き換えるかは書き手自身が考える必要がある。我々の研究室では、本稿に先立って係り受け解析過程モデルを作成した。このモデルは係り受けの複雑さの指標を基に文の複雑さを判定し、係り受けの複雑な文を抽出することができる。しかしどのように書き換えれば文の複雑さが減るかについては何も提示しない。そこで、この指標が下がるように、構文情報のみを用いて文の書き換え候補を作成することを考えた。複雑さの指標が下がれば、その文は書き換える前よりも複雑さが減っているといえる。さらに、この書き換え候補による推敲支援方法について述べる。

Generating Candidates for Rewriting Based on an Indicator of
Complex Dependency and Its Application to a Writing ToolHIROSHI YOKOBAYASHI,[†] AKIRA SUGANUMA[†]
and RIN'ICHIRO TANIGUCHI[†]

Many writing tools for Japanese documents only notice a point of improving a sentence to a writer. He has to consider by himself how to rewrite a text. Our laboratory has proposed the model which imitates human dependency analysis for a Japanese sentence. The model can extract a complex sentence based on the indicator of complex dependency. It does not notices, however, anything about the method of decreasing the complexity of the sentence. In this paper, we describe a generating method of candidates for rewriting based on the indicator. We apply, furthermore, the method to a writing tool.

1. はじめに

近年、個人用 PC が急速に普及し、個人が簡単に PC を扱えるようになった。これらの PC は、ワープロソフトを標準搭載し、その結果個人で容易にワープロソフトを扱えるようになった。このワープロソフトには、文章作成支援機能の 1 つとして、文章校正支援機能も含まれるようになってきた。校正支援機能を用いると、校正作業に役に立つ情報が提示され、書き手はその情報を用いて校正作業を行うことができる。校正作業の次に書き手が行う作業としては推敲作業がある。推敲作業では、文法的には間違っていないが読みにくい文や曖昧な表現を含む文を発見し、書き手の

意図が読み手に伝わりやすい文に書き直す作業を行う。ただし推敲作業に役立つ情報を提示するようなツールはまだ少ないようである。

本稿では、推敲支援に役立つ情報として文の係り受けに関する情報に着目し、文章の推敲作業に役立つ情報を提示する方法について述べている。書き手は気づかないうちに係り受けが複雑な文を書いていることがある。さらに、読み返したときにも、文章の流れを熟知しているために、そのことに気づかないことがある。文章の推敲作業を支援するシステムは、このような書き手が気づきにくい箇所を指摘できるとありがたい^{1),2)}。また、指摘した箇所がなぜ推敲が必要であるのか理由を提示できるとさらに良いと考えられる。システムは推敲作業を効率良く行うための情報を提示す

[†]九州大学

Kyushu University

現在、パナソニックコミュニケーションズ株式会社

Presently with Panasonic Communications Co., Ltd.

本論文の内容は 2003 年 3 月の火の国情報シンポジウム 2003 にて報告され、火の国情報シンポジウム 2003 プログラム委員会により情報処理学会論文誌への掲載が推薦された論文である。

るだけで、実際に書き直すかどうかの判断は書き手が下す。この書き手とシステムとの協調系を考え、我々は推敲支援システムを構築している。

本研究では本研究に先立って、係り受け解析過程モデルを作成した³⁾。これは人間の係り受け解析過程を模したものであり、このモデルによって、文の係り受けの複雑さの指標を得ることができる。この指標を用いることで、係り受けに関して読みにくい文を抽出し、推敲を要領良く行うことが可能になる。しかし、係り受け解析過程モデルは構文情報を基に複雑な文を抽出するのみで、具体的な推敲作業は書き手の判断に委ねられている。また文を書き直した後に、係り受けの複雑さの指標をすぐに再計算できる仕組みがないため、訂正後の文が訂正前に比べて読みやすくなっているかどうかは分かりにくい。

本稿で提案する手法は、構文情報のみから係り受けを推定し、それを用いて係り受けの複雑な文を抽出している。さらに、係り受けの複雑さの指標が高い文に対して、構文情報だけで書き換え候補を作成し、書き手に提示する。具体的には、係り受けの複雑さの指標が低くなるように、修飾節の入れ替えや長い文の分割を行って書き換え文の候補を生成する。さらに、この抽出手法と書き換え候補生成法を推敲支援へ応用する方法を提案する。この手法により、文の内容を熟知していない読み手が陥るかもしれない係り受けの判断を書き手に提示することで、書き手に再考を促すことができる。

2. 係り受け解析過程モデル

2.1 人間の係り受け解析過程

一般的に、人間が文を理解するときには、形態素解析、構文解析といった作業を行っていると考えられる。本稿では、この構文解析の文法として、係り受け文法を用いる。

上記の作業を人間が行うためには、ある種の記憶機構が存在している必要がある。この記憶領域を用いたモデルとして、村田らが文献⁴⁾で用いたモデルがある。このモデルでは、文を理解するときに短期記憶に格納する必要があるものは、係り先が未決定な文節であると考えている。またその短期記憶の容量については 7 ± 2 程度のチャンクであると提唱されている。そこで、文理解の過程において使用される短期記憶の容量も、 7 ± 2 程度であると仮定することができる。

これらのことから、人間の係り受け解析過程を模したモデルを作成して文を処理したときに、短期記憶の容量を超えるような文は、モデルの解析能力を超えた

文であるということがいえる。そして、そのような文は分かりにくい文である可能性が高いと考えられる。

我々の研究室では、このモデルを計算機上に構築し、 7 ± 2 を超える文を提示するシステムを作成した。次節ではこの係り受け解析モデルの概要について説明する。

2.2 係り受け解析過程モデルの概要

係り受け解析過程モデルは、大きく分けて、入力処理部、係り受け判断部、短期記憶スタックの3つの部分からなる。

2.2.1 入力処理部

入力処理部は、入力文に形態素情報を与え、文を文節に区切る。そして、文の先頭の文節から順に係り受け判断部に文節を渡す。

2.2.2 係り受け判断部

係り受け判断部は、後述する短期記憶スタックから取り出した文節と、入力文節との間の係り受けの有無を判断する。係り受け判断部では文の係り受け情報を用いて、文の係り受け解析を行い、文を読む動作を擬似的に再現する。

2.2.3 短期記憶スタック

係り受け解析過程モデルでは、短期記憶スタックと呼んでいるスタック型の短期記憶を持っている。短期記憶スタックの記憶単位をブロックと呼び、データの出し入れはブロック単位で行う。短期記憶スタックへ1ブロック保存する動作を push、短期記憶スタックから1ブロック取り出す動作を pop と呼ぶ。

文を処理していく過程で、係り先が未決定な文節は、スタックに push する。その後スタック中の文節と係り受け関係が成立する文節が表れると、その2つの文節を結合する。この作業を文の最後まで繰り返し、使用したブロックの最大段数を係り受けの複雑さの指標として使用する。

2.3 動作アルゴリズム

係り受け解析過程モデルでは、文が入力されると、文頭から係り受け解析を行っていく。そのときのスタック操作の基本動作アルゴリズムを以下に示す。

操作 1 まず入力処理を行う。入力処理では、入力された文を文節ごとに区切り、すべての文節を未処理文節列に入れる。その後操作 2 に進む。

操作 2 未処理文節列の最初から1つ文節を取り出し、係り受け判断部に送る。取り出した文節は未処理文節列から取り除く。この文節を入力ブロックと呼ぶ。その後操作 3 に進む。

操作 3 短期記憶スタックから1ブロック pop する。これを popped ブロックと呼ぶ。短期記憶スタックが空で、入力ブロックが文末ブロックであった

ら、処理を終了する。そうでない場合は、操作 4 に進む。

操作 4 入力ブロックと popped ブロックとの間で係り受け関係があるかの判断を行う。係り受けが成立した場合、それらを結合し、それを入力ブロックとして操作 3 に戻る。係り受けが成立しない場合は、popped ブロックと入力ブロックをこの順でスタックに push し、操作 2 に戻る。

前述のとおり、人間の短期記憶容量は 7 ± 2 程度であるといわれている。つまり、文を読む際にこの数よりも多くのことを覚えなければならないときに、人間は文の理解に困難を感じると考えられる。係り受け解析過程モデルにおいても、短期記憶スタックの使用容量が 7 ± 2 を超えるような必要があるとき、モデルの処理能力を超えた文であると考えられる。そこで、文を処理するときに使用した短期記憶スタックの段数の最大値を係り受けの複雑さの指標とする。

3. 文の書き換え候補の作成

係り受け解析過程モデルを使用すれば、係り受けの複雑な文を抽出することが可能である。ただし、モデルはどの文が複雑であるかを指摘するのみで、その文をどのように書き換えれば読みやすくなるかについてはまったく関与しない。よって指摘された文を読みやすくするには、文のどの部分が複雑になっていて、どのように書き換えれば文が読みやすくなるかを書き手が考える必要がある。

そこで書き手の推敲作業の負担を少しでも減らせるように、モデルによって抽出された文を対象に、推敲作業に役立つ情報として書き換え候補文を作成することを考える。

3.1 修飾節の入れ替え

日本語は、修飾句・修飾節前置型の言語である。係り受け解析過程モデルではこの修飾節に着目し、修飾節の係り受けが複雑な文を抽出することを目的としていた。文の修飾節が複雑になればなるほど、その文は読みにくくなると考えられる。

修飾節・修飾句にはいくつかの修飾語が含まれており、それらの修飾語ごとに、修飾語の長さや修飾語が含まれている文節の数が異なることが多い。ゆえにこれらの修飾語の並びによって文の読みやすさが変化することが予想される。文献 5) には、修飾語の順序に関して、長い修飾語は先に、短い修飾語は後にした方が、その文が読みやすくなると記述されている。そこでこのルールを利用して、修飾節の語順を入れ替えることによって文を読みやすくすることを考える。

3.1.1 係り受けの複雑さの指標と文の読みやすさの関係

文の読みやすさの目安としては、係り受けの複雑さの指標がある。そこで修飾語の順序と係り受けの複雑さの指標を調べることにする。修飾語として長い文節が後ろにきている簡単な例を例文 1 に示す。括弧内は係り受けの複雑さの指標である。

例文 1) 上空に花子の風船が針の先のような小さな点として現れた (4)

これを修飾語の長い順に入れ替えると例文 2 になる。

例文 2) 針の先のような小さな点として花子の風船が上空に現れた (3)

例文 1 では「上空に」「花子の風船が」「針の先のような小さな点として」が修飾語であり、係り受けの複雑さの指標は 4 である。この 3 つの修飾語の中で「針の先のような小さな点として」が最も文節数が多い。そこで例文 2 のように、この連文節が一番最初にくるように文節を並べ替えると、結果的に係り受けの複雑さの指標が減ることが分かる。

3.1.2 修飾節の切り出し

長い修飾節を前に、短い修飾節を後にすると係り受けの複雑さの指標が低くなることが分かった。そこでこのルールを利用して、指標が低くなるように文を書き換えることを考える。そのためにはまず修飾節単位で文を分ける必要がある。

そこで、各文節を連文節としてまとめていく作業を行う。連文節とは、2 つ以上の連続した文節がひとまとまりとなって、1 つの文節と同様の働きをするものである。文頭から文節を検査していき、以下の 2 つの条件を基に連文節を判定していく。連続する文節間で係り受け関係が成立せず、かつ下の条件を満たさない場合は、そこで連文節がいったん切れるものとする。連文節の判定には各文節の係り受け情報と係りの資格⁶⁾を用いる。

条件 1: 検査対象文節が連体修飾要素の修飾語に係っているときは、その修飾語と連文節になる。

条件 2: 検査対象文節に連体修飾要素の修飾語が存在するときは、その修飾語と連文節になる。

たとえば図 1 では、「上空に」は連体修飾要素ではなく、次の文節である「花子の」を修飾しないため「上空に」は連文節にはならず単独で修飾語になる。次の文節「花子の」は係りの資格が連体修飾要素で、かつ次の文節に係るため「花子の」と「風船が」が連文節になる。同様に「針の」と「先のような」は連文節になるが「先のような」は「点として」に係るためにここで区切られる。「小さな」と「点として」は 1 つの連




図1 修飾節の切り出し
Fig.1 Segmentation of the modifier.

文節になる．図1の文は最終的に5つの修飾句に分けられることになる．

3.1.3 指標に基づく修飾節の入れ替え

前項で作成した修飾句を並べ替えて、係り受けの複雑さの指標が低くなるように文を作成する．修飾句の並べ替えは以下の手順で行う．

手順1: 文頭から順に修飾句を検査し、近くに係る修飾句から順に結合していく．複数の修飾句が同じ文節に係る場合は、文節数の多い順に並べ替えて、1つの修飾句にまとめる．

手順2: 手順1を文末の修飾句まで繰り返す．

図1を文頭から検査していくと、「針の先のような」が「小さな点として」に係っていることが分かる。「小さな点として」に係っている修飾句は「針の先のような」だけなので、この2つの修飾句を1つの修飾句にまとめる．その後「現れた。」に前の3つの修飾句が係っていることが分かる．そこでこの3つの修飾句を、文節数が多い順に並べ替える．この場合は「針の先のような小さな点として」が4文節で最も文節数が多いので、この修飾句が最初にくることになる．この手順で並べ替えると最終的には例文2になる．

修飾句の並べ替えに関しては、係助詞「は」を含む修飾句(以下主題要素と呼ぶ)は並べ替えないことにする．その理由としては、日本語は「主題要素+修飾節+述部」という語順になりやすいからである．その根拠として、京都大学テキストコーパス⁷⁾の15513文を用いて主題要素が修飾句の先頭にくるかどうかを調査した．その結果を表1に示す．この結果から、主題要素は約7割の確率で修飾句の先頭にきていることが分かる．

また接続詞、接続助詞を含む修飾句(以下接続要素と呼ぶ)も、主題要素を含む修飾句同様並べ替えないことにする．接続要素を含む修飾句の前後の修飾句を入れ替えると、生成された文の意味が変化している可能性が高いからである．

3.2 長い文の分割

新聞記事や学術論文を読んでいると、時折やたらに長い文を発見することがある．長い文の種類としては、文中に節構造がいくつも含まれているものや、修飾節がだらだらと長いもの等が存在するが、無駄に長い文というのは読み手にとって苦痛である．そこで推敲支

表1 主題要素の出現する位置
Table 1 Position of the subjective phrase.

主題要素の位置	文数
文の先頭	3,514
接続要素 or 副詞の次	333
最初の修飾句と連文節になる	1,857
修飾句の先頭にくる数の合計	5,704
主題要素を含む文	7,998
主題要素が先頭にくる割合	71.3%




図2 文の平均文節数と係り受けの複雑さの指標の関係
Fig.2 Relation between our dependency indicator and number of phrases.

援として、長い文を機械的に分けることを考える．

例文3は125文字、27文節で、京都大学テキストコーパスの中でも長い方の文である．文の長さに関しては感覚的な判断は可能だが、具体的な数値に基づく判断というのは案外難しい．

例文3) それぞれに大きな政治的变化であり、戦後政治に強烈なインパクトをもたらしたが、いまこの一年半を振り返ってみると、政治的大変化はあってもそれが在来の政治構造の深奥部を突き崩す政治の大変革に至っていないところに、国民のもどかしさと失望感の増幅がうかがえる(10)

3.2.1 処理対象とする文の条件

本研究では文の読みにくさの目安として、係り受けの複雑さの指標を使用している．そこでまずは文の長さや係り受けの複雑さの指標との関係を調べた．調べるにあたって、前述のテキストコーパス15,513文を調査の対象とした．その結果を図2に示す．

図2は平均文節数と係り受けの複雑さの指標との関係を示している．グラフから指標が高くなるほど文節数が増えているのが分かる．また指標7以上の文の平均文節数を表2に示す．

表2を見ると、指標7以上の文の平均文節数が17.4になっているのが分かる．そこで指標が7、文節数が17という条件でグラフを区切ると図2のようになる．図2の①の領域に入る文は長い文であるが指標は高

表 2 文の平均文節数

Table 2 Average of number of phrases in a sentence.

	平均文節数
文全体	13.5
指標 7 以上の文	17.4
指標 9 以上の文	18.5

くない、つまり文の長さが読みにくさにそれほど影響を与えていない文の集まりである。このような文は名詞句の羅列等によって文が長くなっている場合が多く、読みにくさは感じないと思われるため書き換えの対象にはしない。④の領域に入る文は指標は高いが短いという文の集まりである。これらは、文の長さとは異なる要因で係り受けの複雑さの指標が高くなっていると考えられるので、書き換えの対象からは外す。そこで、今回は③の領域の文を処理の対象とする。

3.2.2 区切る場所の設定

前節で述べた条件を基にして文を区切ることにする。ただし長い文を闇雲に切れればよいというわけではない。長い文には主に以下の2つの種類が存在すると考えられる。

- 複数の節構造が接続詞等によって接続されて、長くなっている文
- 連続した修飾節がだらだらと続いている文

この2つは文法的にまったく異なるもので、この2つの原因を区別せずに文の分割を考えることは不可能である。ゆえに、それぞれの場合に対して文を区切ることを考えることにする。

3.2.3 接続要素による長い文の分割

文章を書いているときに、複数のことを1つの文のみで丁寧に説明しようとする、結果的にその文が長くなりすぎて、読み手が読みにくいと感ずる文になることがある。このようなときは1つの文のみで説明しようとするのではなく、複数の文に分けて説明したほうが文のテンポが良くなり、読み手も理解しやすくなる。

ただし文を区切るときには、任意の箇所では切れればよいというわけではない。当然ながら文の意味的な区切りを考慮する必要がある。そこで、複数の節を持つ文に対しては「接続要素+読点」を満たす文節で区切ることにする。この文節を含む例を下に示す。この文では「したいものだが」で文を区切ることになる。

例文 4) ことしこそポスト冷戦、バブル崩壊を踏まえ、二十一世紀を見据えた新しい日本の在り方に展望を切り開く年に、したいものだが、肝心の政界の方は依然として行き着くあてのない漂流を続けている。

この「接続要素+読点」を満たす文節は、連用中止法であることが多い⁸⁾。この連用中止法は、2つの文をつないで1つの文にするときに用いられる。連用中止法でつながれる文は、前件と後件とで主語がすり変わったり、文の照応がねじれたりして、それ自体推敲の対象となりうる。また、上で述べたような多くの項目を詰め込んでしまっ、て、文意が通りにくくなることもある。そのために「接続要素+読点」を満たす文節で区切って2つの文とすることを採用した。

書き換え候補を作成するときは、本来ならば接続助詞の代わりに接続詞を使用するのが理想的である。ただし、1つの接続助詞が複数の意味を持つ場合が多く、的確な接続詞をあてがうのは難しい。そこで現時点ではシステムが分割できると判断した箇所まで文をいったん切って、残りを別の文として書き手に提示する。どのように文をつなぐかは書き手の判断にゆだねることにする。

3.2.4 逆茂木型の文の書き換え候補の生成

前述のとおり、日本語は修飾句・修飾節前置型の言語である。この修飾句・修飾節が長い文、または修飾節の中の言葉にさらに修飾節が係るような文は読みにくくなる。文の構造を木に例えると、文の概要が幹になり、修飾句・修飾節が枝となると考えられる。日本語の修飾句・修飾節前置型の言語では、枝が文の先頭に向けて茂る形となり、幹が分かりにくくなる。このような文を文献 9) では逆茂木型の文と呼んでおり、書き手の意図が読み手に伝わりにくく、読みにくい文になりやすいと述べている。

逆茂木型の文を係り受け解析過程モデルで処理すると、出力される係り受けの複雑さの指標はそうでない文に比べて大きくなることが多い。枝である修飾節が多く存在するほど、スタックに積むブロックの数も多くなるからである。そこで枝である修飾節を抽出し、それを別の文に分けることによって、文を読みやすくすることを考える。

逆茂木型の文の修飾節の検出は、各文節の係りの資格を用いて行う。まず文頭から文節を検査していき、係りの資格が「連体修飾要素/用言」である文節を探す。見つかった場合は、その文節から文の前方に検査していく。検査する文節の係り先が、先ほど検出した「連体修飾要素/用言」の文節を最初に飛び越える場合を検出する。この検出された文節の後ろの文節から「連体修飾要素/用言」の文節までを逆茂木型の文の枝の範囲とする。

たとえば図 3 では、文頭から検索していくと「持ってきた」の係りの資格が「連体修飾要素/用言」であ




図3 逆茂木文の枝の検出例

Fig. 3 Detecting the modifying clause.

ることが分かる。そこから前方に検索していくと、「彼は」が「持ってきた」を飛び越えて「読んだ」に係っているのが分かるので、「太郎が」から「持ってきた」までを逆茂木型の枝の修飾節であると判断する。

逆茂木型の文の書き換え候補を生成するときは、まず、上記の処理で枝と判断された部分を取り除いた幹の部分をもつ文とする。その後、抽出した枝の部分を別の文として生成する。これだけでは幹の文と枝の文との意味的な継ぎりが消滅してしまうので、「連体修飾要素/用言」の文節が修飾する体言を枝の文に補う必要がある。本手法では、枝の文の先頭に主題要素として、「その」+ (修飾される体言) + 「は」を補うことにした。図3の例では、「彼は本を読んだ。」と「その本は、太郎が昨日学校に持ってきた。」という文が生成される。

4. 評価

修飾節の並べ替えと長い文の分割に関する評価実験を行った。評価実験の対象とした文は、九州大学工学部電気情報工学科2001年卒業論文(466文)とした。括弧記号を含む文は正しく処理できないため、前もって取り除いてある。

4.1 修飾節の入れ替えの評価

上記の466文の中で、修飾節の入れ替え処理の対象となったのは86文存在した。これらの文の係り受けの複雑さの指標を表3に示す。また修飾節を入れ替えた後の文の係り受けの複雑さの指標の増減を表4に示す。入れ替え処理の対象となった文の中から例をあげる。

例文5) 並列構造は、図のように、機能面に関して文形式の並列構造と非文形式の並列構造に分けることができる(8)

例文6) 並列構造は、文形式の並列構造と非文形式の並列構造に図のように、機能面に関して分けることができる(4)

例文5は文自体は短い、「文形式の... 並列構造に」が述語の直前に存在するため、それまでのブロックが蓄積される分、指標が大きくなっている。そこでこの修飾句を他の修飾句よりも前に出すと、例文6のよう

表3 修飾節入れ替えの評価対象文

Table 3 Sentences in which our method permuted modifiers.

係り受けの複雑さの指標	文の数	係り受けの複雑さの指標	文の数
10	3	6	16
9	2	5	19
8	11	4	12
7	20	3	3

表4 修飾節入れ替え後の指標の増減

Table 4 Tide of the indicator after our permutation of modifiers.

入れ替え後の指標の増減	文の数	入れ替え後の指標の増減	文の数
-4	1	-1	28
-3	4	0	31
-2	17	1	5

表5 接続要素で分割した後の文の指標の増減

Table 5 Tide of our indicator after our sentence division.

書き換え後の指標の増減	文の数	書き換え後の指標の増減	文の数
-4	1	-2	3
-3	1	-1	6

に指標が下がることになる。

上にあげた例文では読点を含めた修飾句をそのまま入れ替えて文を作成している。これに関してはシステム側で修正することが困難なため、読点の打ち直し等、細かい修正は書き手に任せることになる。また修飾節の入れ替えは係り受け情報を用いて行っている。この処理では、係り受け情報が正しいことを前提にしているため、誤った係り受け情報が出力されると生成された文の意味が異なる可能性が高くなる。

4.2 長い文の分割の評価

4.2.1 接続要素による長い文の分割

466文の中で処理の対象となったのは11文である。これらの中で、分割した後の長い方の文の指標の増減を表5に示す。評価した文の中から例をあげる。

例文7) 並列構造解析において重要な点は、後置要素の終点文節まで読み進めて、そこでどの文節列とどの文節列がはじめて並列になっているかがわかることである(8)

例文8) そこではじめてどの文節列とどの文節列が並列になっているかがわかることである(5)

例文7は指標が8、文節数が17の文である。この文では、文中に接続要素「読み進めて」が存在するため、そこで区切ることになる。例文8は例文7を2つに分けた後の、長い方の文であるが、分ける前に比べ

表 6 逆茂木型の枝を除去した文の指標の増減

Table 6 Tide of our indicator after deleting the modifying clause.

書き換え後の指標の増減	文の数	書き換え後の指標の増減	文の数
-7	1	-3	1
-6	2	-2	4
-5	2	-1	4
-4	4	0	10

て指標が 3 下がっている。

4.2.2 逆茂木型の文の分割

466 文の中で処理の対象となったのは 28 文である。これらの文から逆茂木型の枝葉の修飾節を取り除いた文の指標の増減を表 6 に示す。評価した文の中から例をあげる。

例文 9) チェコスロバキアの全国的情報システムの作成を目標とした総合的長期計画の一環としてとりあげられている情報科学における近代的方法の適用について述べ、大きな国立情報機関で達成されつつある主要方向を示す (11)

例文 10) 情報科学における近代的方法の適用について述べ、大きな国立情報機関で達成されつつある主要方向を示す (4)

例文 11) その情報科学は、チェコスロバキアの全国的情報システムの作成を目標とした総合的長期計画の一環としてとりあげられている (8)

例文 9 は「情報科学に」に係る修飾節が長いので、文が読みにくくなっている。このような場合はその修飾節を分けて、別の文とした方が読み手に意図が伝わりやすくなる。そこで「チェコスロバキアの」から「とりあげられている」までが 1 つの大きな修飾節となっているため、この修飾節を抜き出して例文 11 のように 1 つの文とする。そうすると文の幹の部分为例文 10 になり、書き換える前に比べて指標が大幅に下がっていることが分かる。

逆茂木型の文の書き換え候補の生成では、枝の修飾節から生成する文に、その修飾節が修飾する体言を主題要素として補う手法を採用した。この手法が妥当であるかを調査した。その結果、上の例文 9~11 のように自然な文を生成できることが分かった。一方、下の例文 12~14 のように生成した文に違和感を感じる場合もあった。しかし、このような文の提示であっても、生成された文を基に書き手が若干の書き直しを行うことで違和感のない文になると考えられる。例文 13 と 14 では、下線部をそれぞれ「特別な現象が起こる。」と「その現象とは、」「ずれることである。」とすれば違和感のない文になる。このように、書き手とシステム

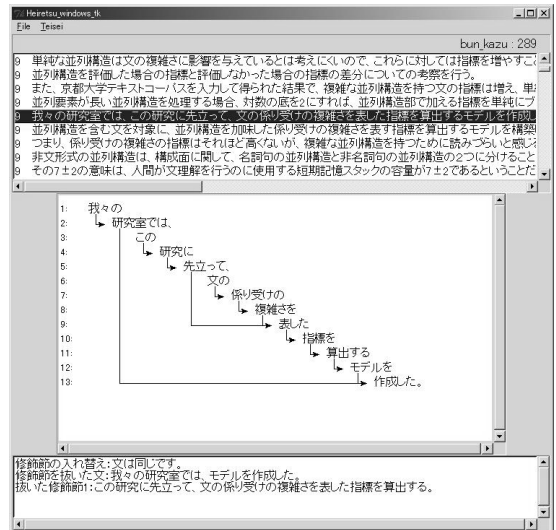


図 4 推敲支援情報を提示するインタフェース

Fig. 4 Interface of our system.

とが協調することを考えると、この手法は推敲支援法として有効であると考えられる。

例文 12) ホルマント周波数は同じ音素でも、発生者によって変動し、さらに、実際の文を発声した音声では、前後の音素の影響を受けてその周波数がずれる現象がある。

例文 13) ホルマント周波数は同じ音素でも、発生者によって変動し、さらに、実際の文を発声した音声では、現象がある。

例文 14) その現象は、前後の音素の影響を受けてその周波数がずれる。

5. 推敲支援への応用

係り受け解析過程モデルは、 7 ± 2 を基準にして文の読みにくさを判断することができる。このモデルでは構文情報のみを用いて文の複雑さを判定するため、モデルが抽出したすべての文が読みにくいとは考えにくい。提示した文の中から書き手に推敲を促すことは有意義であると考えられる。

そこで係り受け解析過程モデルをベースにして、本稿で提案した機能を用いて、推敲支援システムの構築を行った。システム構成は以下のとおりである。

- 形態素解析: 「茶釜」¹⁰⁾
- 係り受け解析: 「CaboCha」
- 読みにくさの判定: 係り受け解析過程モデル
- 推敲支援情報の提示: 自作インタフェース

係り受けの複雑さの指標を書き手に提示するインタフェースを図 4 に示す。インタフェースは 3 つのウィ

ンドウからなる．上から順に，文とその係り受けの複雑さの指標の一覧，構文情報，メッセージを表示する欄である．一番上のウィンドウでは，入力したテキストファイルの各文の係り受けの複雑さの指標を算出した後，指標の高い文から順に提示する．一番上のウィンドウで文を1つ選択すると，下2つのウィンドウに瞬時に解析結果を提示する．

本稿では推敲支援方法として，修飾節の入れ替えと長い文の分割を提案した．これらを推敲支援へ応用するときには，1つの文に対して両方の方法を組み合わせる結果を1つだけ出力するやり方と，両方の方法を別々に割り当ててそれぞれの結果を出力するやり方が考えられる．現状では後者のやり方で推敲対象文を評価して，出力されたそれぞれの結果を提示する．推敲作業自体は書き手の判断にゆだねることにする．

6. おわりに

本稿では，構文情報を用いて文の書き換え候補を作成する方法を提案した．またそれらを推敲支援に応用する方法についても提案した．

今後の課題としては，読みにくい文の1つであると考えられる，曖昧な係り先を含む文の検出と指摘を考えている．また推敲支援情報を提示するインタフェースの改良を考えている．また本稿の推敲支援システムの客観的な評価を行うことも今後の課題である．

参考文献

- 1) 倉田昌典，菅沼 明，牛島和夫：日本語文章推敲支援ツール『推敲』のパソコン上での実用化，コンピュータソフトウェア，Vol.6, No.4, pp.55-67 (1989).
- 2) 牛島和夫：日本語文章推敲支援ツール「推敲」，*bit*，Vol.23, No.1, pp.4-14 (1991).
- 3) 小池康弘，菅沼 明，谷口倫一郎：係り受け解析過程モデルを用いた係り受けの複雑さの指標の作成とその推敲支援への応用，第14回情報処理学会九州支部研究会報告，pp.370-377 (2000).
- 4) 村田真樹，内元清貴，馬 青，井佐原均：日本語文と英語文における統語構造認識とマジカルナンバー 7 ± 2 ，自然言語処理，Vol.6, No.7, pp.61-71 (1999).
- 5) 本多勝一：日本語の作文技術，朝日文庫 (1982).
- 6) 菅沼 明，山村広臣，牛島和夫：日本語文における名詞句の並列構造の推定およびその推敲支援への適用，情報処理学会論文誌，Vol.38, No.7, pp.1296-1307 (1997).
- 7) 黒橋禎夫，齋藤由衣子，坂口昌子：コーパス作成の作業基準，京都大学テキストコーパス (1997).
- 8) 縄田晶裕，菅沼 明，牛島和夫：日本語文章推敲

支援ツール『推敲』における連用中止法の抽出，情報処理学会第47回全国大会論文集3，pp.229-230 (1993).

- 9) 木下是雄：理科系の作文技術，中公新書 (1981).
- 10) 松本裕治，北内 啓，山下達雄，平野善隆：日本語形態素解析システム『茶筌』version2.0 使用説明書，奈良先端科学技術大学院大学松本研究室 (1999).

(平成15年8月25日受付)

(平成16年3月5日採録)

推薦文

本論文は，日本語文章の係り受けの複雑さ指標に基づいて，複雑な文を抽出するとともに，複雑さが減少するような書き換え候補を生成する方法を提案・評価したものである．推敲支援を行うツールは多数存在するが，その多くは推敲支援情報を提示するだけであり，文章をどのように書き直すかは書き手自身が考える必要がある．これに対して本論文は書き換え候補を生成する点で新規性および有用性が高い．また，現実的な規模の文書に本手法を適用し，良い結果を得ている．以上の理由により，本論文を推薦するものである．

(火の国情報シンポジウム2003プログラム委員長長近藤 弘樹)

横林 博

2001年九州大学工学部電気情報工学科卒業．2003年同大学院システム情報科学研究科知能システム学専攻修士課程修了．同年パナソニックコミュニケーションズ(株)勤務，現在に至る．画像処理，生産技術，ユーザインタフェース等に興味を持つ．



菅沼 明(正会員)



1986年九州大学工学部情報工学科卒業．1988年同大学院工学研究科情報工学専攻修士課程修了．1991年同博士後期課程修了．同年九州大学工学部情報工学科助手勤務．1993年同大学工学部情報工学科講師，1996年同大学大学院システム情報科学研究科(研究院)助教授，現在に至る．工学博士．日本語情報処理，ユーザインタフェース，遠隔講義支援，画像処理等に興味を持つ．1994年本会奨励賞，1998年本会山下記念研究賞を受賞．電子情報通信学会，言語処理学会各会員．



谷口倫一郎（正会員）

1978年九州大学工学部情報工学科卒業．1980年同大学院修士課程修了．1980年同大学院総合理工学研究科助手，1989年同助教授，1996年九州大学大学院システム情報科学研究科（研究院）教授．画像処理，コンピュータビジョン，並列処理等に関する研究に従事．本会コンピュータビジョン研究会幹事，アクレディテーション委員会幹事等を務める．本会論文賞，坂井記念特別賞，映像情報メディア学会丹羽・高柳論文賞等を受賞．本会代表会員．
