

効率的な英文解析のための多品詞解消方式

小原 和博

NTT 情報通信処理研究所

本論文では、効率的な英文解析を行なうために有効な多品詞解消方式を新たに提案するとともに、科学技術英文を対象とした多品詞解消実験による評価結果ならびに英文解析時間の短縮効果について述べる。主な結論は以下のとおりである。

(1) 多品詞解消能力： 100文を対象とした多品詞解消実験を行なった結果、本論文で提案する多品詞解消方式により、①1単語当たり1.27の多品詞性が、出力時には1.10の多品詞性に解消できることがわかった。②そのときの正解率は98.6%であった。

(2) 英文解析時間の短縮効果： 入力英文の品詞の組合せごとに句構造ルールとの照合を図る構文解析手法を前提とした場合、①多品詞解消モジュールを利用したときの英文解析時間の短縮効果は単語数に対してほぼ指數関数的に増大する可能性がある。②23単語(試験文の平均単語数)の英文を解析する場合には、約20倍速く英文解析できる可能性がある。

Resolving Categorial Ambiguities for Efficient English Sentence Parsing

Kazuhiro Kohara

NTT Communications and Information Processing Laboratories
1-2356 Take Yokosuka-Shi Kanagawa 238-03 Japan

This paper presents not only a new algorithm for resolving categorial ambiguities(multiple parts of speech) but also its capability given by an evaluation experiment on 100 sentences. Its qualitative effects on parsing time are also discussed, assuming a parsing method pursuing all categorially possible parse paths in breadth-first fashion. Main results are as follows.

(1) According to the categorial disambiguation experiment, the number of POS per word can be reduced from 1.27 to 1.10. The correctness of the disambiguation is 98.6%.

(2) According to the estimation of shortening effects, the processing speed by the parser with the categorial disambiguation module can be about 20 times faster than that without the disambiguation module, in the case of parsing a 23 word sentence.

1 はじめに

自然言語理解や機械翻訳などの英文解析では、品詞のあいまい性、句や節の係り受けのあいまい性など様々なあいまい性の解消が重要な問題となる。このうち本論文では多品詞性の解消の問題について議論する。

英単語のもつ品詞のあいまい性のために、英文解析では品詞の組合せ数の爆発的増加に直面する。そこでこの問題の解決策として、構文解析モジュールと独立した多品詞解消モジュールを用意しておき、これにより予め品詞の数を効率的に減少する方法が考えられる。

これまで自然言語の構文解析に関して、アルゴリズム、言語、文法といった様々な側面から多くの研究がなされてきた[3]～[10]。しかし多品詞解消の研究は、英文解析時間の短縮に極めて有効であるにもかかわらず、これまで余り研究されていない[1]。数少ない研究報告[1][2]はあるものの、多品詞解消能力の十分な評価や、英文解析時間の短縮効果への定量的評価がなされていない。

そこで本論文では、効率的な英文解析を行なうために有効な多品詞解消方式を新たに提案するとともに、科学技術英文を対象とした多品詞解消実験による評価結果ならびに英文解析時間の短縮効果について述べる。

2 多品詞解消方式

本論文で扱う品詞の分解能は以下に示す13品詞である。

- (1)名詞、(2)代名詞、(3)関係代名詞、
- (4)冠詞、(5)形容詞、(6)副詞、(7)関係副詞、(8)前置詞、(9)接続詞、(10)

be動詞、(11)助動詞、(12)自動詞、
(13)他動詞

各品詞には必要に応じて適當なプロバティを用意する。例えば、形容詞には限定用法だけに用いられる形容詞か否か、他動詞には「ed形」(例: solved)か「ing形」(例: resolving)か否か(例: resolve)というプロバティを付与する。

2.1 多品詞解消ルール

多品詞解消ルールの例を図1に示す。実際のルールは 23×23 (動詞にはed形、ing形の欄を追加し、品詞の他にカンマ、ピリオド、文頭の欄を追加) のマトリックスから成る。

多品詞解消ルールには、いかなる場合にも該当する品詞の並びを許さない無条件ルール(図1で×で示したルール)と、該当する品詞の並びに対して特別の解消条件を与える条件ルール(図1で数字で示したルール)がある。

B	名詞	冠詞	自動詞	他動詞	ピリオド	
A			ing	ed	ing	ed
冠詞		×	×	×	×	×
形容詞	22	×		×	×	9
自動詞	14	14	×	×	×	
ing						
ed	14	14	×	×	×	
他動詞			×	×	×	×
ing						
ed						

図1 多品詞解消ルールの例

無条件ルールは全部で 111箇所があり、条件ルールは全部で 62箇所がある。

ed 形でも ing 形でもない動詞に関する無条件ルールの例を以下に示す。

- ①自動詞あるいは他動詞は冠詞の直後に来てはいけない。
- ②自動詞あるいは他動詞は、自動詞あるいは他動詞の直前に来てはいけない。
- ③他動詞はビリオドの直前に来てはいけない。

単語 B が単語 A の直後にある場合の、条件ルールの例を以下に示す。

[条件 9] 単語 A が限定用法だけに用いられる形容詞を含む多品詞語であり、しかもそれがビリオドの直前にある場合には、単語 A から形容詞を削除する。
[条件 14] 単語 A が多品詞性のない完全自動詞であり、単語 B が名詞を含む多品詞語の場合には、単語 B から名詞を削除する。 単語 B に多品詞性がなく、しかも単語 A が完全自動詞を含む多品詞語の場合には、単語 A から自動詞を削除する。

[条件 22] 単語 A が形容詞を含む多品詞語 (all と such 以外) であり、単語 B が冠詞の場合には、単語 A から形容詞を削除する。 単語 A が all か such であり、単語 B が冠詞の場合には単語 B の品詞を形容詞に決定する。

解消ルールは直後の多品詞性を解消するための前方ルールと、直前の多品詞性を解消するための後方ルール、両方向の多品詞性を解消するための両方向ルールに分れる。 また解消ルールは一定の品詞を削除するための禁止ルールと、一定の品詞を選択するための選択ルールに分れる。 無条件ルールは全て禁止ルールである。

2.2 多品詞解消アルゴリズム

多品詞解消アルゴリズムの主要部を以下に示す。

[STEP 1] i 番めの入力単語の品詞の数 $A_{in}(i)$ を求める。

[STEP 2] $A_{in}(i)$ の積 S を求める。

[STEP 3] 入力順に $A_{in}(i) > 1$ と $A_{in}(i+1) = 1$ の 2 単語列を検出して、その単語列に該当する後方ルールと両方向ルールを適用する。

[STEP 4] 入力順に $A_{in}(i) = 1$ と $A_{in}(i+1) > 1$ の 2 単語列を検出して、その単語列に該当する前方ルールと両方向ルールを適用する。

[STEP 5] S を更新する。

[STEP 6] S が減少し、かつ、全ての $A_{in}(i)$ がまだ 1 でない場合には [STEP 3] からの処理を繰り返す。 その他の場合には多品詞解消処理を終了する。

本アルゴリズムの特徴は次のとおりである。

(1) 多品詞性のない単語と多品詞性のある単語が並んでいる単語列を検出して、その部分に多品詞解消ルールを適用する。 これにより制御が簡単で効率の良い多品詞解消処理を実現できる。

(2) 必ずしも品詞を 1 つに決定することはせず、極めて正解率の高い解消ルールにより、品詞の数を無理なく減少させる。 これにより修復のためのメカニズムが不要となりさらに制御が簡単になる。

3 多品詞解消実験

3.1 実験方法

科学技術文献から抽出した100文を対象に、多品詞解消アルゴリズムを机上でトレースすることにより多品詞解消実験を行なった。

図2に多品詞解消の実験例を示す。この場合、*then*の形容詞と、*follows*の他動詞が後方ルールにより削除され、*chip*の他動詞が前方ルールにより削除され、*chip*の自動詞、*design*の自動詞と他動詞が両方向ルールにより削除される。品詞数の積は36通りから1通りに減少し、また、1単語当たりの品詞数の相乗平均は1.82個から1個に減少する。

入力英文	入力の品詞(Ain)	出力の品詞(Aout)
<i>Then</i>	adv,adj(2)	adv (1)
<i>the</i>	article(1)	article(1)
<i>chip</i>	n,vt,vi(3)	n (1)
<i>architecture</i>	n (1)	n (1)
<i>design</i>	n,vt,vi(3)	n (1)
<i>follows</i>	vt,vi (2)	vi (1)
.	period (1)	period (1)
品詞数の積	(36)	(1)
品詞数の相乗平均	(1.82)	(1.00)

図2 多品詞解消実験例

3.2 実験結果

表1に実験データを示す。入力文の単語数をn、入力時の品詞数の相乗平均をAin(av)、出力時の品詞数の相乗平均をAout(av)とすると、試験文100文での相加平均は以下の通りである。

$$\begin{aligned} n &= 22.9 \text{ 単語} \\ A_{in(av)} &= 1.27 \text{ 品詞} \\ A_{out(av)} &= 1.10 \text{ 品詞} \end{aligned}$$

これらの値は文献1と文献2とで余り差がない。

次に、多品詞解消アルゴリズムにより品詞を削除した件数と、正解品詞を削除してしまった件数とからアルゴリズムの正解率を求めるとき、全体で98.6%となる。この値も文献1と文献2とで余り差がない。

以上から平均的にみると、22.9単語の英文を多品詞解消モジュールに入力した場合、1単語当たり1.27の多品詞性が、出力時には1.10に多品詞解消されることがわかる。また、そのときの正解率は98.6%である。

多品詞性の残りやすいポイントは以下の通りである。

① カンマの直前の多品詞語

例：... design, ...

② (前置詞と接続詞)の多品詞語

例： as after

③ (形容詞と副詞)の多品詞語

例： more high even

④ *that*と、動詞を含む多品詞語が並んでいる単語列

例：... a prompt that matches ...

⑤ *ed*形 / *ing*形の動詞

例：... algorithms tailored to ...

表1 多品詞解消実験データ

	文献1(50文)	文献2(50文)	全体(100文)
平均単語数(単語)	23.2	22.7	22.9
入力時の品詞数の相乗平均(品詞)	1.31	1.24	1.27
出力時の品詞数の相乗平均(品詞)	1.11	1.10	1.10
品詞を削除した件数x(件)	296	260	556
正解品詞を削除した件数y(件)	3	5	8
正解率 $(x - y) / x (\%)$	99.0	98.1	98.6

[文献1] Muroga,S.: VLSI System Design, John Wiley & Sons(1982)

[文献2] Abraham,E et al.: The Optical Computer, Scientific American(Feb.1983)

これらの多品詞性は、2単語間の接続関係を中心とした解消ルールでは解消が困難なものばかりである。中には3単語以上のスコープを見る解消ルールにより多品詞解消できる場合もあるが、ほとんどは本格的な構文解析により解消されるものである。

副作用の生じた主なポイントは以下のとおりである。

①接続詞と接続詞の単語列

例：But if we want to...
(Butの接続詞を削除)

②前置詞と前置詞の単語列

例：...are referred to as the...
(asの前置詞を削除)

③現在形他動詞とto以外の前置詞の単語列

例：...require from 1 to 10...
(requireの他動詞を削除)

④文末にある原形他動詞を削除

例：...is difficult to change.
(changeの他動詞を削除)

これらの副作用を除く方法として、解消ルールの制限条件を強化する案と、解消ルールを削減する案が考えられる。しかし、前者の案では解消時間が増大するという問題が生じ、後者の案では多品詞解消能力が低下するという問題が生じる。これらの問題はトレードオフの関係にある。

4 英文解析時間の短縮効果

実験結果に基づき、多品詞解消モジュールを利用した場合の英文解析時間の短縮効果について試算してみる。但し、構文解析の手法として、入力英文の品詞の全ての組合せに対して句構造ルールとの照合を図る方法(Breadth-First Parsing[10])を想定する。

4.1 短縮効果の理論式

多品詞解消モジュールへの入力時の品詞の組合せ数(各単語の品詞数の積)をj、出力時の品詞の組合せ数をkと

し、 j 通りの構文的あいまい性をもつ英文の構文解析時間 $f(j)$ 、多品詞解消時間を $g(j)$ とする。このとき、解消モジュールのない場合の英文解析時間 T_0 と、ある場合の英文解析時間 T_1 は以下のようになる。

$$T_0 = f(j) \quad (1)$$

$$T_1 = g(j) + f(k) \quad (2)$$

構文的に正しい品詞をもつ英文の構文解析時間を f_0 とする。その他の品詞の組合せに対する構文解析時間を $(1/m)f_0$ とすると（一般的に言って、 $m > 1$ ）、 $f(j)$ 、 $f(k)$ は以下のようになる。

$$f(j) = (j-1)(1/m)f_0 + f_0 \quad (3)$$

$$f(k) = (k-1)(1/m)f_0 + f_0 \quad (4)$$

一般的に言って、 $g(j)$ は $f(j)$ よりも小さい。

$$g(j) = a \cdot f(j) \quad (5)$$

$$0 < a < 1 \quad (6)$$

但し、 a は定数とは限らない。

多品詞解消モジュールによる英文解析時間の短縮効果 E を以下のように定義する。

$$E = T_0 / T_1 \quad (7)$$

式(1)～(5)から E は次のようになる。

$$E = (j+m-1) / [a(j+m-1) + (k+m-1)] \quad (8)$$

4.2 短縮効果の推定値

入力英文の単語数を n としたとき、表 1 に示した実験結果から j と k の値を以下のように考える。

$$j = 1.27^n \quad (9)$$

$$k = 1.10^n \quad (10)$$

式(9)(10)を式(8)に代入すると

$$E = (1.27^{n+m-1}) / [a(1.27^{n+m-1}) + (1.10^{n+m-1})] \quad (11)$$

ある正しい品詞をもつ英文の構文解析時間を f_0 としたとき、他の品詞の組合せに対する解析時間を、途中で失敗しそうが別の解析木を作ろうが平均的に $(1/2)f_0$ と仮定する ($m = 2$)。

$n=22.9$ (平均単語数) と $m=2$ を式(11)に代入して求めた E と a の関係を図 3 に示す。

実際に設計中の多品詞解消プログラムと構文解析プログラムを見て、 f_0 と g の動的ルール数を机上で見積り、動的ルール数が解析時間に比例すると仮定して、以下の式により a を求めた。

$$a = g / [(j-1)(1/2)f_0 + f_0] \quad (12)$$

その結果、 a は高々 0.008 であることがわかった。 $a = 0.008$ と $m=2$ を式(11)に代入して、 E と n の関係をプロットしたものを図 4 に示す。図 4 から次のことが言える。

① 英文解析時間の短縮効果は単語数に対してほぼ指數関数的に増大する可能性がある。

② 23 単語（試験英文での平均的な単語数）の英文を解析するとき、多品詞解消モジュールを利用することにより約 20 倍速く英文解析できる可能性がある。

5 おわりに

効率的な英文解析のための多品詞解消方式について述べた。主な結論は以下のとおりである。

(1) 多品詞解消能力

100 文を対象とした多品詞解消実験を行なった結果、本論文で提案した多品詞解消方式により、

- ① 1 単語当たり 1.27 の多品詞性が、出力時には 1.10 の多品詞性に解消できることがわかった。
- ② そのときの正解率は 98.6 % であった。

(2) 英文解析時間の短縮効果

入力英文の品詞の組合せごとに句構

短縮効果

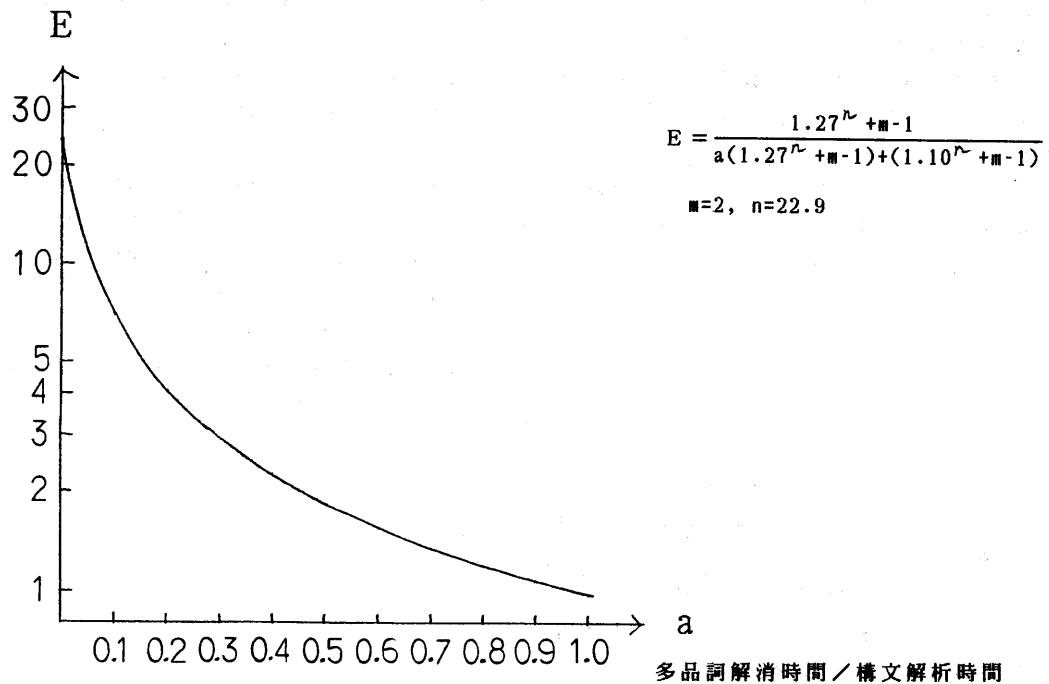


図3 英文解析時間の短縮効果1

短縮効果

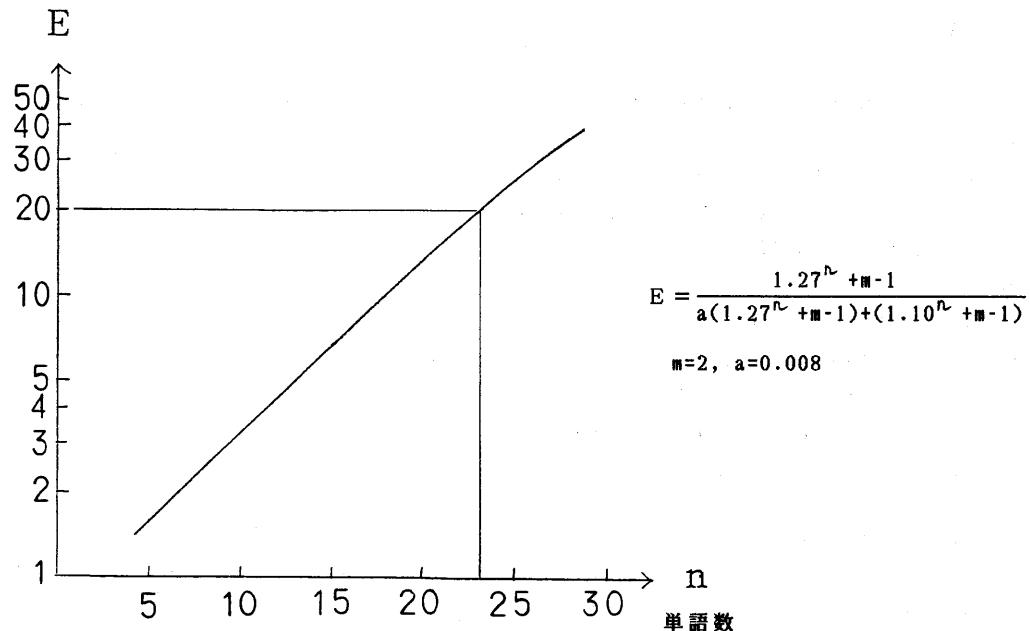


図4 英文解析時間の短縮効果2

造ルールとの照合を図る構文解析手法を前提とした場合、

①多品詞解消モジュールを利用したときの英文解析時間の短縮効果は単語数に対してほぼ指數関数的に増大する可能性がある。

②23単語(試験文の平均単語数)の英文を解析する場合には、約20倍速く英文解析できる可能性がある。

謝 辞

日頃御指導いただき阿部豊彦研究室長に感謝します。本論文に関して貴重な御討論をいただいた下村二三男主幹研究員、片桐恭弘主任研究員はじめ関係各位に感謝します。多品詞解消実験に関して多大なる御協力をいただいた菊井玄一郎君、三浦裕壮君、水嶋いづみ嬢に感謝します。

参考文献

- [1]Duffy,G.:Categorial Disambiguation, Proc. AAAI'86(1986)
- [2]山本利文、辻井潤一、長尾真:Mu-プロジェクトの英日機械翻訳システムにおける多品詞語の解消, N L 研 53-7 (1986.1)
- [3]Aho and Ullman:The Theory of Parsing, Translation and Compiling, Vol.1, Prentice Hall(1975)
- [4]Earley,J.:An Efficient Context-free Parsing Algorithm, CACM 6 (1970)
- [5]Tomita,M.:An Efficient Context-free Parsing Algorithm for Natural Languages, Proc. IJCAI'85(1985)
- [6]Pratt,V.R.:A Linguistic Oriented Programming Language, Proc. IJCAI'73(1973)

[7]Tanaka H. et al.:Predictive Control Parser:Extended LINGOL, Proc. IJCAI'79(1979)

[8]Woods,W.A.:Transition Network Grammars for Natural Language Analysis, CACM 13(1970)

[9]Tennant,H.:Natural Language Processing, Petrocelli Books(1981)

[10]Martin,W.A. et al.:Preliminary Analysis of a Breadth-First Parsing Algorithm: Theoretical and Experimental Results, TR261, MIT Laboratory for Computer Science(1981)