

単語結合型辞書引きを用いた日英機械翻訳用辞書の構成

Construction of a Dictionary for MT using Combined Word Retrieval

宮崎 正弘*

Masahiro MIYAZAKI

池原 悟**

Satoru IKEHARA

横尾 昭男**

Akio YOKOO

* 新潟大学: Niigata University

** NTT情報通信処理研究所: NTT Communications and Information Processing Laboratories

あらまし

日英機械翻訳システムにおいて、大規模辞書を効率的に構築し、維持管理することはきわめて重要である。本論文では、解析辞書（日本語辞書）と変換辞書（日英対訳辞書）の独立性を確保し、辞書を可能な限りコンパクトにすること狙い、解析辞書と変換辞書にどのような基準、条件で見出し語を収録したらよいかについて論じ、各種辞書の単語収録単位の違いを吸収するものとして単語結合型辞書引き提案した。

複合語は短単位語（語基）を組合せて数限りなく生成される。従って、このような複合語は、解析辞書には原則として収録せず、複合語は語基の組合せとして、その内部構造を解析する。一方、変換辞書には目的言語に応じて適切な訳を生成するため語基の他に複合語を収録し、複合語の内部構造の解析により生成された部分複合語を基に、複合語内の語基を組合せて変換辞書引きを行う。この過程により、複合語は変換辞書にある見出し語の最適な組合せに最構成される。

本方法により、大規模辞書の効率的構築と維持管理が可能になると共に、日本語の複合語に対する解析と変換処理の調和が実現できた。

1. まえがき

日本語文を英語に翻訳する場合、短単位語（語基¹⁾）を組合せて適切な訳を生成できない長単位語（複合語²⁾）が多い。特に現在、機械翻訳の対象となっている科学技術文書（論文、マニュアルなど）や新聞記事文（産業、経済分野など）などでは、専門用語を中心に多くの複合語が出現する。

従来、多くの機械翻訳システムでは、このような複合語を解析辞書に収録し、入力文の解析において複合語をそれ以上分割できない一つの単語とみなす、複合語の内部構造は解析していない。しかし、このような方式では、以下のように、辞書作成過程のみならず、アルゴリズム構成上も重要な問題が生じる。

- ①複合語は無限に生成されるので、すべての複合語をあらかじめ辞書に収録しておけない。
- ②辞書の収録語数が際限なく増大し、辞書の構築、維持・管理がやりにくくなる。特に、解析に必要な意味属性などの意味情報を、語基だけでなく、多くの複合語に対して付与するには、多大の工数を要する。
- ③分ち書きにおける単語分割誤りの要因ともなる（図1の例1を参照）。
- ④複合語外から複合語内の語基への係り受け解析ができないため、複合語の周辺の語との意味的関連を考慮した柔軟な訳出ができない（図1の例2を参照）。

これに対して、本論文では、日英機械翻訳システムにおいて、上記問題点を解決するため、解析辞書（日本語辞書）、変換辞書（日英対訳辞書）にどのような基準、条件で見出し語を収録したらよいかについて論じ、各辞書の単語収録単位の違いを吸収する方法として単語結合型辞書引きを提案する。

本方法では、解析辞書、変換辞書の独立性を確保するため、解析辞書は原則として語基を収録し、変換辞書には目的言語に応じて適切な訳を生成するため、語基の他に複合語も収録する。まず、日本語の複合語は語基の組合せとして複合語の内部構造を解析し、同時に複合語外から複合語内の語基への係り受け等も解析する。以上の解析結果に基づき、複合語内の語基を組合せて変換辞書引きを行う単語結合型辞書引きを行い、複合語を変換辞書にある見出し語の最適な組合せに最構成する。

本方式は、日本語の用言運用形が副詞化したり（例：激しく→violently）、日本語の名詞+格助詞「の」が形容詞化するなど（例：近代の→modern）、日本語と英語の単語や品詞が1対1に対応しないため、解析辞書と変換辞書の単語収録単位、品詞の違いを吸収するためにも有効である。

例1) 自然言語処理プログラム

- 自然 言語 処理 プログラム (×)
→ 自然 言語 处理 プログラム (○)

例2) コンピュータの 故障検出 する

- do failure detection of computer (×)
コンピュータの 故障 検出 する
→ detect failure of computer (○)

図1. 複合語の辞書収録による処理誤りの例

2. 日本語辞書と変換辞書の単語収録条件

機械翻訳用の辞書において、解析辞書と変換辞書の独立性を確

*¹単独で語を構成できるか否かによって語基と接辞に分けられるが、ここでは、接辞も語基に含め、以下単に語基と呼ぶ。

**上記で定義した語基を複数個結合して作られる語を合成語と呼ぶこともあるが、ここでは”複合語”と呼ぶことにする。

保することは、きわめて重要である。そのために解析辞書は原言語の解析を行うのに必要な情報のみを収録し、目的言語に依存した情報は原言語と目的言語の対応を記述した変換辞書に収録することが望ましい。このような辞書構成をとることにより、多言語翻訳を行う場合でも、目的言語に対応した変換辞書を準備しさえすれば、解析辞書は何の変更も加えることなく共通に使える。また、変換辞書の変更によって、解析が大きな影響を受けることがないため、解析過程が安定する。

ここでは、解析辞書としての日本語辞書と変換辞書の独立性の維持を狙い、複合語、活用語に対する辞書収録の形態と正書法の確立されていない日本語における表記のゆれの吸収の方法、等について論じる。また、これらの議論を通じて、日本語辞書、変換辞書の単語収録条件を明らかにする。

2. 1 複合語の扱い

日本語では、造語力の強い漢字等により助詞を介さずに名詞（接辞などの名詞相当語を含む）が二語以上連続した名詞連続複合語（以下、単に“複合名詞”と呼ぶ）が限りなく作り出される。このような複合名詞は科学技術文書や新聞記事といった、現在、機械翻訳の対象となっている実用文には数多く現われる。しかし、このような複合名詞をすべて辞書に収録することはできない。

そこで、辞書の見出し語は語基を原則とし、複合語は処理によって語基の組合せに分割して扱う。ただし、語基の組合せに分割できない複合語は長単位で辞書に収録する。専門用語を始めとする複合語の多くは、語基の組合せに分割できるため、長単位で解析辞書に収録すべき単語は多くないのに対して、語基を組合せて適切な訳出ができる複合語は、かなり多い。従って、変換辞書には、このような複合語を多数、収録する必要がある。

ここで、4章で提案する変換辞書における単語結合型辞書引きを用いれば、日本語辞書と変換辞書の単語収録単位の違いを吸収できる点に着目して、日本語辞書には、適切な訳出を行っため変換辞書に収録した複合語を収録しない。このようにすることにより、日本語辞書と変換辞書の独立性を確保できるだけでなく、日本語辞書をコンパクトにすることができる、辞書の構築や維持管理がしやすくなる。特に、解析に必要な意味属性などの意味情報を多くの複合語に対して付与しなくてすむ等の利点がある。また、複合語の構造解析アルゴリズムを強化しさえすれば、複合語を多数、日本語辞書に収録することによる単語分割誤りを減らすことにも期待できる。

2. 2 活用語の扱い

単語の区切りがなく、べた書きされる日本語文の自動分ち書きを効率的に行うため、日本語の活用語は、通常、以下の2つの形態で日本語辞書に収録される。

①規則的な活用を行うもの

…不変化部分と変化部分に分離して収録する。

②不規則な活用を行うもの（助動詞、変格活用動詞など）

…すべての活用形を収録する。^{*1}

これに対して、変換辞書には活用語の代表形（通常、終止形）を収録し、日本語辞書と変換辞書の単語収録単位の違いを吸収するため、活用語を終止形に変換し、元の活用形、法情報（活用語が助動詞、補助用言で様相、相・時制などの属性をもつ場合）を付与する。ここで、活用語が助動詞などで、活用語に対応する訳語が目的言語でない場合には、法情報を基にした構文構造の変換等を行う必要がある。

2. 3 表記のゆれの扱い

日本語では明確な正書法が確立されていないため、同じ語を漢字、ひらがな、およびその混ぜ書きといった各種の形式で表記したり、数詞を漢数字、算用数字、およびその混ぜ書きといった各種の形式で表記したり、送りがなのゆれがあるなど、表記上のゆれがある。このような表記上のゆれは、日本語内に閉じたものであるので、日本語文の解析処理の早い段階で解消しておき、変換辞書には、表記のゆれのある語のうち、その代表形（以下、これを標準表記と呼ぶ）のみ見出し語として収録することが、変換辞書のコンパクト化の観点から望ましい。

日本語の表記上のゆれを解消するため、表記のゆれのある語について、そのすべての形を日本語辞書に見出し語として収録し、見出し語に対応する標準表記を辞書中に記述することが考えられる。しかし、このような方法では日本語辞書の収録語数が膨大となってしまう。そこで、以下のような辞書と処理を併用した方法で表記のゆれを解消する方法を提案する。

（1）処理による表記のゆれの解消

①漢字の異字体の解消

入力文中にある漢字の異字体は、異字体と代表字体の対応を示すテーブルを用いて、代表字体に変換する。

例) 附属 → 付属、廻転 → 回転

②カタカナ外来語の表記のゆれの解消

入力文中にある外来語表記用の特殊なカタカナ文字（ α ）は、 α と代表字体の対応を示すテーブルを用いて代表字体に変換する。

例) ヴィオリン → バイオリン

また、分ち書き処理を行った場合、カタカナ既知語^{*2}（ β ）の直後にある長音「一」一文字の未知語は、直前の β と統合して一語（標準表記は β のまま）とする。

例) データ／＼ → データー（「／＼」は単語境界）

③繰り返し記号に関するゆれの扱い

入力文中にある繰り返し記号（「々」、「ゝ」、「ゞ」）は、対応する文字に置換する。^{*3}

*1 「行っ」（五段動詞「行く」の音便形）のように特定の活用形で例外的な活用をするもの（カ行は通常イ音便となる）は、活用形で例外的な形のみ収録する。

*2 カタカナ語で長音のゆれについては、長音化しない方のみ、日本語辞書に収録しておく。

*3 日本語辞書には、原則として繰り返し記号を用いない形で収録しておく。

例) たゞみ → たたみ、かゞみ → かがみ
いちゞみ → いちいち、一歩々々 → 一步一歩

ただし、「々」が連続しない場合（例：「佐々木」「日々」「三々五々」）は、例外的に「々」を用いた形も日本語辞書に収録しておき、「々」を含む単語が辞書にない場合のみ上記のような文字の置換を行う。これは、固有名詞などは、通常「々」を用いて表記すること、「々」を漢字で置換することにより入力文字の情報の一部が縮退すること（たとえば、副詞「一々」は「一一」となり、数詞と同型語となってしまう）などのためである。

④数詞の表記のゆれの解消

種々の形式で表記された日本語の数表現を文献1で提案されている日本語の数表記の標準形に変換する。

（2）辞書による表記のゆれの解消

①送りがなのゆれの解消

すべての可能な形を見出し語として辞書に収録する。

例) 行(な)う → 行う、行なう

申(し)込(み) → 申込、申込み、申し込み

②同一字種内の表記のゆれの解消

すべての可能な形を見出し語として辞書に収録する。

例) 二葉 ←→ 双葉、衣装 ←→ 衣裳、コンペア ←→ コンベヤ

③異った字種間の表記のゆれの解消

すべての自立語（接辞、補助用語を含む）について、そのひらがな書き、混ぜ書き等の形を辞書に収録することは、辞書の収録語数の増大を招くだけでなく、分ち書き処理における単語分割誤りの要因ともなる。従って、自立語のうちひらがな書き、カタカナ書き、混ぜ書きされることが多い語のみ日本語辞書に見出し語として収録する。

なお、日本語辞書を通常の見出し語の他に、読み（ひらがな表記）でも検索できるようにすれば、日本語辞書の収録語数を増やすことなく、本来、ひらがな以外で表記されることが多いひらがな語の辞書引きができる。また、カタカナ → ひらがな変換した後、日本語辞書を読みで検索することにより、本来、カタカナ以外で表記されることが多いカタカナ語の辞書引きができる。このような読みによる検索は、分ち書き処理において、ひらがな未知語、カタカナ未知語が検出された場合等に、必要に応じて行なうことにより、分ち書き精度の向上が期待できる。

2.4 同義語の標準化

日本語内で、ある単語（γ'）を別の単語（γ）に置換しても意味の等価性が保たれる場合、日本語辞書内にその代表形（γ）を記述することにより標準化し、変換辞書には代表形のみ記述することにより、変換辞書のコンパクト化が図れる。この場合、γ' → γの置換によりその意味は変わらないが、γ'が特別な慣用表現や複合語を形成し、かつそのような表現においてγ' → γ

の置換不可の場合、γをγ'の代表形とはせず、γ'を代表形とする。また、γ' → γの変換では等価とならないがγに適当な法情報（δ）を付与することにより等価となる場合、γ'はδが付与されたγに変換される。

例) 泳げる(γ') → 泳ぐ(γ) [δ = '可能']

2.5 その他

2.2～2.4節で述べた代表形、標準表記以外の語を変換辞書に収録しなければならない場合としては、2.1節で述べた複合語の他に、以下のようなものがある。

①日本語の用言の非終止形が、目的言語において他の品詞になる場合。

例) 激しく（形容詞・連用形） → violently（副詞）

②日本語の用言+付属語列が、目的言語において他の品詞になる場合。

例) 注意して（動詞+接続助詞） → carefully（副詞）

③日本語の体言+付属語列が、目的言語において他の品詞になる場合。

例) 木の（名詞+格助詞：木材の意） → wooden（形容詞）

④日本語において、用言とその格要素（名詞+格助詞など）が、目的言語においてひとまとまりの単語、句などになる場合。

例) 背が高い（名詞+格助詞+形容詞） → tall（形容詞）

⑤日本語において、格助詞+用言+付属語列（全体で格助詞相当語となる）が、目的言語においてひとまとまりの単語、句などになる場合。

例) に対して（格助詞+動詞+接続助詞） → to（前置詞）

上記①～⑤については、日本語辞書と変換辞書の単語収録単位や品詞の違いを吸収するため、単語結合型辞書引き、品詞変換などを行なう必要がある。

3. 複合語の構造解析

複合名詞（サ变动詞、形容動詞の語幹となる複合語を含む）は、複合語の内で最も出現頻度が高く、かつ解析上、問題となる。ここでは、このような複合名詞を対象に、変換辞書の単語結合型辞書引きを行うのに必要な構造解析法について述べる。

3.1 複合名詞内の係り受け解析

複合名詞の解析については、既に文献2で複合名詞を構成する単語間の意味的結合関係を係り受け解析によって解析する方法が提案されており、それによって高精度の複合語自動分割が実現されている。ここでは、文献2の方法に基づき複合名詞内の係り受け解析を行い、複合名詞を日本語辞書にある語基の組合せに自動分割するが、以下のように係り受け規則を拡充した。従来の主要な係り受け規則を表1に示す⁽²⁾。

（1）用言性名詞の係り受け規則の拡充

サ变动詞化する名詞α（サ变动詞型名詞）、形容動詞化する名詞β（形容動詞型名詞⁽¹⁾）などの用言性名詞に関する係り受け規

*1 「自動」「～型」「～性」「近代」のような連体詞的に使われる連体詞型名詞を含む

表1. 複合語における係り受け規則

番号	係り受けの型	例
1	前置助数詞-数詞	約 <u>1</u> 〇、第 <u>八</u> 回
2	数詞-後置助数詞	二 <u>本</u> 、5.0 <u>パーセント</u>
3	後置助数詞-助数詞接続型接辞	5.0 <u>Kg</u> 強、数 <u>%</u> 台
4	数詞-数詞接続型接辞	1.00 <u>未満</u> 、1.0 <u>以下</u>
5	固有名詞-固有名詞接続語	地名 東京 駅、関東 平野
		人名 平野 副 社長、二郎 君
		組織名 三井 信託 銀行
		その他の 固有名詞 明治 時代、アイヌ 人
6	役職接続型接辞-役職	美濃部 前 都 知事
7	姓-名	加藤 一二三
8	包含関係のある地名の連接	神奈川 県 横須賀 市 武
9	接頭語-単語*1	極 超 短波
10	単語*1-接尾語	大型 機 用
11	非用言性名詞-非用言性名詞	一日 一日 朝、県立 高校
12	単語*2-サ変動詞型名詞	データ 处理
13	サ変動詞型名詞-単語*2	処理 手順
14	単語*2-形容動詞型名詞	人気 絶頂
15	形容動詞型名詞-単語*2	特別 料金

単語*1: 数詞、固有名詞、形式名詞を除く名詞

単語*2: 名詞

則を表2～表3のように拡張した。

主な拡張点は以下の通りである。

①サ変動詞型名詞の係り受け規則

- α の前方の単語（直前の語以外）との格関係のチェック
- α と α が連接した場合における格関係、連体修飾、並列用法の判定
- α の連体修飾用法における同格のチェック

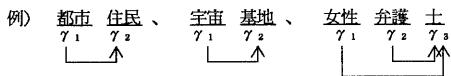
②形容動詞型名詞の係り受け規則

- β の直前の単語との格関係（主格以外）のチェック
- β の後方の単語との連用修飾、並列、連体修飾（主格以外）のチェック

(2) 非用言性名詞の係り受けの規則の拡充

連接する非用言性名詞 γ_1 と γ_2 が意味的に強く結合するような γ_1 と γ_2 の一般名詞属性の組合せを共起属性表の形で用意し、 γ_1 と γ_2 の係り受けをチェックする。ただし、 γ_2 の直後に「者」、「土」、「所」、「場」など語基との結合力の強い接尾語（強結合型接尾語と呼ぶ） γ_3 がある場合、 γ_1 と γ_2 の係り受けをチェックし、 γ_1 と γ_3 の係り受けが不成立の場合のみ、 γ_1 と γ_2 のチ

ックを行なう。

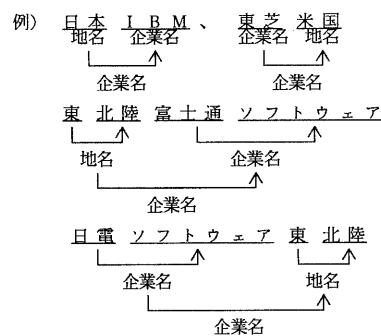


なお、 γ_1 と γ_2 （または γ_3 ）と係り受けが成立せず、 γ_1 と γ_2 の一般名詞属性が同等の場合には、 γ_1 と γ_2 は並列とみなして係り受けを成立させる。

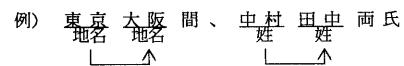


(3) 固有名詞の係り受け規則の拡充

- ①連接する固有名詞における特殊な共起パターンを検出し、係り受けを成立させる。

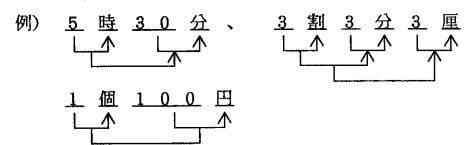


- ②固有名詞が連接し、係り受けが成立しない場合、各固有名詞の固有名詞属性が同等ならば、各固有名詞は並列とみなして係り受けを成立させる。

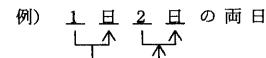


(4) 数詞の係り受け規則の拡充

- ①連接する数表現（数詞+後置助数詞）における特殊な共起パターンを検出し、係り受けを成立させる。



- ②同型の数表現が連接し、係り受けが成立しない場合、各数表現は並列とみなして係り受けを成立させる。



3. 2 複合名詞の構造規則

複合語を構成する語基数 n が 3 以上の場合、複合語内の語基が部分的に結合してまとまり、複合語内により小さな複合語（部分複合語）を作る*1。このような部分複合語は、基本的には以下の過程により生成される。

*1 ここでは、最大の部分複合語を複合語と考え、 $n = 2$ の場合も含んだすべての複合語を対象に議論を進める。

表2. サ変動詞型名詞の係り受け規則

項目番号	係り受けの型	係り受けの条件		例
		係り先単語	備考	
1	格関係 ↓ γ_1 : が、を、に、 のために、 α 格関係or連体修飾or並列 ↓ α : 一方が非動作性名詞としても使われる場合、または自動詞性の場合、当該単語を γ_1 とする。上記の置換が行われず、 α 、 α_1 の一方が形容詞化する場合、当該単語を β とする。	α の前方の単語* α の直近の単語より順次、係り受けをチェックする。 本チェックは項目2のチェックの前に行う。	[格関係] ・動作主、対象、起点、目標、道具、手段、材料、目的、結果、原因、理由、時間、場所、数量、様態、状態、共同 [格関係or連体修飾or並列] 以下の①または②の場合は並列とする。 ① α と α_1 の意味属性が同等で、かつサ変動詞化した場合の必須格の格パターン②が一致する。 ② 格関係、連体修飾の何れもが成立しない。	・情報 处理 を ↑ ・データ 自動 収集 を ↑ ・故障 検出 を ↑ ・処理 命令 (で) [連体修飾] する ↑ ・整理 整頓 し ↑ [格関係] [並列]
2	連体修飾 ↓ α : する γ_2 : するという する事により生じた	α の後方の単語* α の直近の単語より順次、係り受けをチェックする。	[連体修飾] ① γ_2 :(が、を、に、のために、...) α する → α する γ_2 (γ_1 と γ_2 の格は重複しない) ② α と γ_1 の意味属性が同等 → α するという γ_2 (同格) ③ γ_2 の意味属性が抽象物、抽象的関係を表す特定の語 → α することによって生じた γ_2	・予想 最高 気温 (を) する ↑ ・発光 現象 する ↑ するという ・勤務 成績 する事によって 生じた ↑

*1: 接頭語+単語は一つの単語とみなす。

*2: 用言のとりうる格、格を表示する助詞、格要素となる名詞の意味属性。

(凡例)

 α : サ変動詞型名詞、 β : 形容動詞型名詞、 γ : その他の名詞

表3. 形容動詞型名詞の係り受け規則

項目番号	係り受けの型	係り受けの条件		例
		係り先単語	備考	
1	格関係 ↓ γ_1 : が、に、... β : 格関係 ↓ α_1 : が、に、... β	β の直前の単語* 項目2のチェックの前に本係り受けをチェックする。	[格関係] ・主体/対象 ～が β だ ～が～に β だ ～が～を β だ ～は～が β だ	・栄養 豊富 が ↑ ・研究 热心 に ↑
2	連体修飾 ↓ β : な、的、の γ_2 : の 運用修飾 ↓ β : に、的 α_2 : 本係り受けが成立せず、 α_2 が非動作名詞としても使われる場合には α_2 → γ_2 運用修飾or並列 ↓ β : かつ β_2 : 例 大型/計画	β の直近の単語から順次、係り受けをチェックする。	[連体修飾] ① γ_2 :(が、に、...) β だ → β (な、的、の) γ_2 (γ_1 と γ_2 の格は重複しない) ② γ_2 の γ_1 が β だ → γ_1 が β (な、的、の) γ_2 (γ_1 が β の部分、属性、所有物、動作である。) [運用修飾or並列] β が運用修飾的に使われない場合、並列とする。	・一様 データ (が) [な] ↑ ・大型 切断 機 (が) [の] ↑ ・栄養 豊富 食品 (の) [が] ↑ [な] ↑ ・高速 处理 [に] ↑ ・自動 データ 处理 [に] ↑ [的] ↑ ・完全 自動 [に] ↑ [運用修飾] [かつ] ↑ [並列] ・小型 軽量 [並列]

*: 接頭語+単語は一つの単語とみなす。

(凡例) α : サ変動詞型名詞、 β : 形容動詞型名詞、 γ : その他の名詞

部分複合語 ← 語基+語基

部分複合語 ← 部分複合語+語基 | 語基+部分複合語

部分複合語 ← 部分複合語+部分複合語

すなわち、語基同士が結合して部分複合語を作り、このようにして作られた部分複合語に語基が結合したり、部分複合同士が結合して、より大きな部分複合語が作られる。このように隣接した語基や部分複合語が結合する過程を繰返して、より大きな構造を作りながら複合語が構成されると考えるのである。

ここでは、3. 1節で述べた複合名詞内の係り受け解析の結果

を基に、複合名詞内の語基がどのように結合して、部分複合語、より大きな部分複合語、さらに全体の複合語を構成しているのかを解析する方法について述べる。

(1) 部分複合語生成ルール

部分複合語生成ルールを補強文脈自由文法流の書換え規則で以下のように表現する。

```
Xi {syn= $\alpha$  [, semg=( $\beta_1, \dots$ ), semp=( $\gamma_1, \dots$ ) ] }  
← yj {aj} zk {ak} | Yj {Aj} zk {ak} |
```

$y_j \{a_j\} Z_k \{A_k\} | Y_j \{A_j\} Z_k \{A_k\}$
 $\{a_{j(k)}\} = \{\text{syn}=\alpha', [\text{semg}=(\beta_1', \dots), \text{semp}=(\gamma_1', \dots, " \delta' ")]\}$
 $\{A_{j(k)}\} = \{\text{syn}=\alpha'', [\text{semg}=(\beta_1'', \dots), \text{semp}=(\gamma_1'', \dots, " \delta'' ")\}$
 X_i : 新たに生成される部分複合語
 Y_j, Z_k : 新しい部分複合語を構成する部分複合語
 y_j, z_k : 新しい部分複合語を構成する語基
 $\{ \}$ 内は X_i, Y_j, Z_k, y_j, z_k の品詞、一般名詞属性、固有名詞属性、表記を記述する。[] 内は省略可であることを示す。
 syn : =以下に品詞を表示
 semg : =以下に一般名詞属性のリストを表示
 semp : =以下に固有名詞属性のリストを表示
 " δ " : 語基または部分複合語の表記(δ)を" "内に表示

(2) 部分複合語の生成

数表現や固有名詞表現は隣り合った語基や部分複合語同士が局所的に次々に結合して、数詞や固有名詞相当の部分複合語を構成することが多い。一方、接辞や用言性名詞は数表現、固有名詞、その他の非用言性名詞、およびそれらから生成された部分複合語と結合して、さらに大きい部分複合語を構成することが多い。以上の点を考慮して、部分複合語生成ルールに以下の優先順位をつけ、隣接し、かつ係り受けが成立する語基や部分複合語に対して、優先順位の高い順に本ルールを適用する。以上の過程によりボトムアップに部分複合語を生成していく、複合語に一致する部分複合語が生成された時点で生成を終了する。^{*1}

[部分複合語生成ルールの優先順位]

- ① 数詞関連ルール
- ② 固有名詞関連ルール
 - 1) 人名(役職関連表現を除く)関連
 - 2) 地名関連
 - 3) 人名、地名、組織名以外の固有名詞関連
 - 4) 組織名関連^{*2}
 - 5) 人名(役職関連表現^{*3})関連
- ③ 非用言性名詞関連
- ④ 接辞関連
 - 1) 接頭語関連(接頭語が後方の語基に係る場合で、この時点でルールが適用できない場合、後方の語基から部分複合語にまとめられ適用可能となった時に適用する)
 - 2) 接尾語(強結合型接尾語)関連

*1複合語に一致する部分複合語が生成されなかった場合、複合語 α は最も大きな部分構造(部分複合語や語基)の組合せ $\alpha_1, \alpha_2, \dots, \alpha_N$ に分割されている。 $\alpha_1, \dots, \alpha_{N-1}$ の中で係り先がないものについて係り受け規則を再度適用して、係り先を確定する。この結果、再度部分複合語生成規則を適用し、より大きな部分複合語の生成が可能となる。

*2組織名は、地名、人名など他の固有名詞(部分複合語を含む)を含むより大きな構造をもつ部分複合語を生成することが多い。

*3役職は人名、組織名など複数の固有名詞(部分複合語を含む)と次々と結合して、より大きな構造をもつ部分複合語を生成することが多い。

*4本接尾語の直前の語基、部分複合語が用言性名詞で、かつ当該用言性名詞の直前の語基、部分複合語と係り受けが成立する場合は、本ルールを適用せず、⑤で用言性名詞関連ルールを適用する。

*5複合名詞でもよい。

3) 接尾語(強結合型接尾語以外)関連^{*4}

⑤用言性名詞関連

部分複合語の生成例を図2に示す。

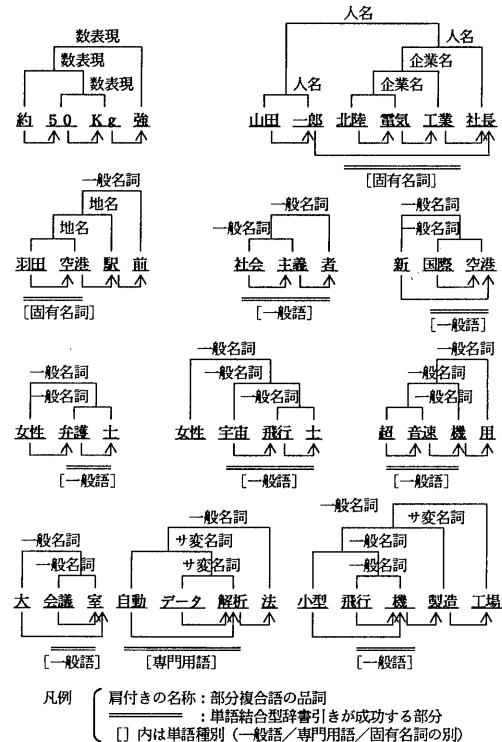


図2. 部分複合語の生成と単語結合型辞書引きの例

3. 3 複合語外から複合名詞内への係り受け角解析

名詞句中に複合名詞がある場合、複合語外から複合名詞内の語基への係り受けが生じる可能性がある。

ここでは、複合名詞を含む名詞句が「 α のB」、「 α とB」(α は名詞^{*5}、Bは複合名詞)の場合について、複合語外(「 α の」、「 α と」)から複合名詞B(語基例 β_1, \dots, β_N より構成されているものとする)内の語基 β_k への係り受けを以下のように解析する。

① 「 α のB」の場合:

複合名詞 $\alpha \beta_i$ ($i = 1 \sim N$)において、 α と β_i に係り受

けが成立するような i の最小値 I を求める。 I が求まれば「 α 」の係り先は β_1 とする。 I が求まなければ「 α 」の係り先は複合名詞全体とする。

②「 α と B 」の場合：

複合名詞 $\alpha \beta_j$ ($j = 1 \sim N$)において、「 α と β_j 」に並列関係が成立するような j の最小値 J を求める。 J が求まれば「 α と」の係り先は β_1 とする。 J が求まなければ「 α と」の係り先は複合名詞全体とする。

複合語外から複合名詞内の語基への係り受けがある場合、係り元の名詞 α を β 内の係り先語基 (β_1 または β_2) の直前に挿入して β 内の語基とし、「 α と β 」で 1 つの部分複合語を生成し、既に生成されている β 内の部分複合語の構造内に組込む。図 3 に複合語外から複合名詞内への係り受けがある場合の複合名詞構造解析結果の変更例を示す。

なお、複合語外からの係り先が複合名詞全体の場合には、「 α の B 」や「 α と B 」において、「 α と B 」は独立に解析してよいため、上記のような変更を行わない。

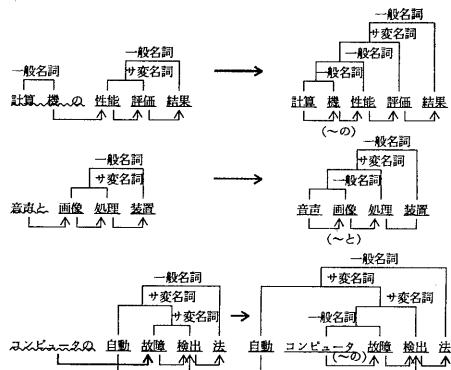


図 3. 複合名詞構造解析結果の変更例
(複合語外から複合名詞内の語基への係り受けがある場合)

4. 変換辞書の単語結合型辞書引き

日本語辞書と変換辞書の単語収録単位は、2 章で述べたように異なっており、変換辞書には語基の他に、語基の組合せで構成される種々の長単位語を見出し語として収録する。従って、日本語辞書と変換辞書の単語収録単位の違いを吸収する機構が必要となる。

ここでは、複数の語基より構成された複合語などの長単位語を、変換辞書にある長単位語を含む見出し語の最適な組合せに再構成するため、複数の語基を組合せて変換辞書引きを行う単語結合型辞書引きを提案する。

4. 1 複合名詞の単語結合型辞書引き

複合名詞 α は日本語辞書に収録された語基の組合せとして、3 章で述べた方法によって α の内部構造を解析し、部分複合語を生成する。また、3. 3 節で述べたような名詞句中に出現する複合名詞 (α) においては、「 α 外から α 内の語基への係り受け解析を行い、「 α 内語基への係り受けがある場合、係り元の名詞を α 内に組み込み構造解析結果を修正する。

α に対する変換辞書の単語結合型辞書引きは、「 α の部分複合語構造に基づき、以下のように行う。

- ① 最大の部分複合語である複合語全体 α で辞書検索し、検索成功ならば*1 終了、不成功ならば②へ。
- ② α を最も大きな部分構造（部分複合語や語基）の組合せ $\alpha_1 \cdots \alpha_N$ に分割する。
- ③ $\alpha_1 \cdots \alpha_N$ において α_i が部分複合語ならば、 α_i で辞書検索する。辞書検索成功ならば、 α_i に含まれる部分複合語があつてもこれ以上小さな単位で辞書検索しない。辞書検索不成功ならば*2、 α_i を②と同様にして最も大きな部分構造の組合せ $\alpha_{i1} \cdots \alpha_{iN}$ に分割し、 $\alpha_{i1} \cdots \alpha_{iN}$ において α_{ij} が部分複合語ならば③と同様に α_{ij} で辞書検索する。以下、同様の処理を繰返し、辞書検索すべき部分複合語がなくなった時点での処理を終了する。

上記、①～③の処理によって抽出された辞書検索成功した部分複合語を用いて α を再構成したものが、 α の単語結合型辞書引きの結果である。図 2 に単語結合型辞書引きの例を示す。

4. 2 複合用言の単語結合型辞書引き

サ変動詞語幹 α 、形容動詞語幹 β となる複合名詞に用言の活用語尾・付属語 (γ) が連接すると、以下のように $\alpha\gamma$ や $\beta\gamma$ の形の複合用言を構成する。複合用言を構成する場合、 α や β の内部構造は、複合名詞ほど複雑にはならない。

- ① γ = 「する」の場合（英語の動詞に対応）

例) 故障 検出 する、工業化 する
- ② γ = 「だ」、「な」、「の」の場合（英語の形容詞に対応）

例) 栄養 豊富 だ、近代的 な
小型 軽量 の、全自動 の
- ③ γ = 「に」（英語の副詞に対応）

例) 超高速 に、効率的に

ここで、 α 、 β については、3 章の方法を適用して α 、 β の内部構造を解析し、必要に応じ α 、 β 外からの、 β 内の語基への係り受けを解析しておく。

α 、 β に対する変換辞書の単語結合型辞書引きは、以下のよう

*1 部分複合語の品詞と検索された語の品詞が一致しなければならない。例) 完全自動化→サ変動詞名詞

*2 部分複合語の品詞が固有名詞（組織名）の場合には、図 4 の例に示すような誤りを防ぐため、辞書検索が失敗してもより小さな部分複合語による辞書検索を行わない。

にして行う。

- 1) α 、 β 外から α 、 β 内の語基への係り受けがない場合
 $\alpha \gamma'$ 、 $\beta \gamma'$ で単語結合型辞書引きを行う。ここで γ' は $\gamma = 「な」$ の場合、 $\gamma' = 「だ」$ とする以外、 γ と同じ字面を設定する。検索成功ならば終了、不成功ならば2)と同様の処理を行う。
- 2) α 、 β からの α 、 β 内の語基への係り受けがある場合
 α 、 β の構造解析結果に基づき α 、 β 内の語基に適当な付属語などを補い、通常の文の形に変換し、変換処理を行う。

例) 故障検出する → 故障 を 検出する
コンピュータの 故障検出る
→ コンピュータの故障 を 検出する
栄養豊富な 食品 → 栄養 が 豊富な食品
研究熱心な 人 → 研究 に 熱心な人

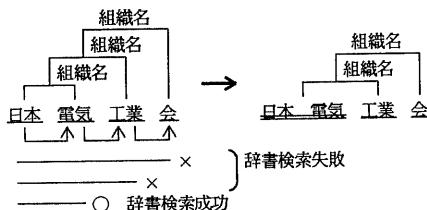


図4. 単語結合辞書引きによる複合語再構成の失敗例

5. あとがき

日英機械翻訳システムにおいて、解析辞書（日本語辞書）には原則として語基のみ収録し、変換辞書（日英対訳辞書）には目的言語に応じて適切な訳出を行うため語基の他に複合語などの長単位語も収録することにより、解析辞書と変換辞書の独立性を確保し、辞書のコンパクト化が可能な辞書システムが構成できることを論じた。

さらにこのような辞書構成法を可能とするため、各辞書の単語収録条件の差を吸収することを狙い、複合語を解析辞書にある語基の組合せとして内部構造を解析し、その結果に基づき複合語内の語基を組合せて変換辞書引きを行う単語結合型辞書引きを提案した。

本方式は日英機械翻訳システム A L T - J / E ⁽⁸⁾ に組み込まれ、その効果が確認されている。A L T - J / E への適用結果によれば、本手法は、大規模辞書を効率的に構築し、維持管理することを可能とした。特に、解析に必要な意味属性などの意味情報を多くの複合語に対して付与しなくてすむ点などに利点がある。

また、単語結合型辞書引きの前処理として行われる複合名詞の構造解析においては、部分複合語の概念を新たに導入し、複合語外から複合名詞内の語基への係り受けも考慮して、語基間の係り受け解析結果を基に、複合名詞内の語基がどのように結合して部分複合語を構成し、それらがより大きな部分複合語にまとめられるかという点を自動解析する方法の概略を示した。本解析法の詳

細とその定量的評価については、別途報告したい。

今後、複合名詞に未知語を含む場合の扱い、複合名詞がもっと複雑な名詞句中にある場合の扱い、係り受け解析と部分複合語生成の融合等について検討を進める予定である。

【謝辞】

本論文の方式は日英機械翻訳システム A L T - J / E を構成する技術の一つとして開発してきたものである。本システムの開発を通じて本方式に関する有意義な議論を頂いた白井主任研究員、中岩研究主任、並びに翻訳研究グループの諸氏に感謝する。

参考文献

- (1) 宮崎正弘：“日本文音声変換のための数詞読み規則”，情処論，Vol. 25, No. 6, PP. 1035-1043(1984)
- (2) 宮崎正弘：“係り受け解析を用いた複合語の自動分割法”，情処論, Vol. 25, No. 6, PP. 970-979(1984)
- (3) 池原, 宮崎, 白井, 林：“言語における話者の認識と多段翻訳方式”，情処論, Vol. 28, No. 12, pp. 1269-1279(1987)