

日英機械翻訳における用言の訳し分けと構文意味辞書

白井 諭[†] 井上浩子[‡] 横尾昭男[†] 池原 悟[†]

[†]NTTコミュニケーション科学研究所

[‡]NTTアドバンステクノロジー

1 はじめに

意味解析技術の重要性が指摘されているが、機械翻訳では、動詞と名詞の意味的共起を結合価パターンとして記述し、それを原言語と目的言語で対にしたパターン対(構文意味辞書)の使用が有効であることが知られている。この方法には、パターン記述精度とパターン対収集の2つの課題がある。

パターン記述精度の問題については、日英機械翻訳では、名詞の意味属性を2,000種類以上に分類すれば、日本語の用言を訳し分けるのに必要なパターン対が記述できることが知られている[池原93]。

パターン対収集の問題についても、種々のヒューリスティックスや学習技術に応用した方法が提案されている。例えば、黒橋らは例文とシソーラスを用いて文型を同定する方法を提案し、精度は人手作成の方法と同等以上である可能性を示している[黒橋92]。また、アルモアリムらは学習技術を用いたパターン対の自動抽出方法を提案し、6動詞に対し各27~80の対訳用例を用いたパターン対の抽出実験に成功している[Almuallim 94a][Almuallim 94b]。しかし、日英翻訳では使用頻度の高い和語動詞のパターン対の機械学習だけで1,000万ペアの単純な日英対訳文が必要であると言われており[金田94]、作成すべきパターン対の総数が不明であること、パターン対の網羅的収集に必要な単純な用例を多数収集するのは困難であることなどの基本的な問題が未解決である。

これに対し、訓練されたアナリストであれば、類推により1例文から1パターンを作成することが期待される。そこで本稿では、人手による3つのパターン対作成方法を実験し、日英機械翻訳にはどれだけの数のパターン対が必要か、どのようにすれば作成できるかについて和語動詞1,000語を中心に検討する。そして、その結果を踏まえることにより、パターン対全体の必要数についての推定を試みる。

2 パターン対収集の方法

結合価パターンを記述するには、格要素となる名詞が2,000種類以上に分類されている必要がある[池原93]。本稿ではこの条件を満たしている日英翻訳システムALT-J/E[池原89]の枠組みを対象にパターン対の作成方法を検討する。

2.1 和英辞書を参照する方法

(1) パターン対収集の方法

パターン対を収集する第1の方法として人間用の辞書の使用が考えられる。和英辞書には、日本語の語句に対し、語義ごとに対応する英語の語句、語法、例文などが記載されている。従って、用言の項目に対する語法や例文を分析し、格要素、副詞要素などの日本語側の制約条件を整理すれば、パターン対を作成することができる。

(2) 収集されたパターン対の数

数冊の和英辞書から得たパターン対は、当初、汎用パターン対10,000件、慣用パターン対5,000件であった[池原93]。その後、類似の汎用パターン対の統合や慣用パターン対の一部の汎用パターン対化により、汎用パターン対10,000件と慣用パターン対3,000件から成る構文意味辞書が完成した[横尾94]。

(3) 翻訳実験における充足性

この構文意味辞書を使用して、情報処理装置関連の仕様書(1,361文)の翻訳実験を行なったところ、試験文中に現れた用言の種類は142件で、辞書から使用されたパターン対は、120用言に対する154件であった。試験文中の22の用言(22パターン)はパターン対が登録されておらず、23の用言に対しては合計25のパターン対が不足していることがわかった[白井94a]。中でも、パターン対が不足している用言は、単語当たりの語義の多い和語動詞が多く見られた。

A Japanese to English semantic structure dictionary to select translation patterns for Japanese predicates

Satoshi SHIRAI[†], Hiroko INOUE[‡], Akio Yokoo[†] and Satoru IKEHARA[†]

[†]NTT Communication Science Laboratories and [‡]NTT Advanced Technology Corporation

2.2 日本語辞書の語義を参照する方法

(1) パタン対収集の方法

和語動詞は語義が多いため、パタン対を網羅的に収集するのは容易でない。和語動詞については、従来、日本の言語学者（20名あまり）を中心に、その語義と対応する用例を収集分析する研究が進められており、漢字表記の揺らぎを除く861動詞に対して、語義と語義毎の用例がIPA L動詞辞書[IPA 87]としてまとめられている。

そこで、第2の方法としてこの辞書を使用したパタン対の収集を考える。具体的には、IPA L動詞辞書の各語義に示されている用例文に対し、日本語原文に忠実で、かつ英語として十分通用する英訳文を翻訳家に作成してもらい、その対訳から構文意味辞書に登録するパタン対の収集を試みる[白井94b]。

(2) 収集されたパタン対の数

上記の方法では、861の和語動詞に対して、5,243文（和文75,000字、英文40,000語）の例文が得られた。現在、パタン作成作業は、実施中であるが、これらのうちの740動詞に対する4,500例文から1,290パタン対が新規に作成され、既存のパタン対のうち、410件が修正された。逆に、第1の方法で得られたパタン対には、第2の方法では得られないもののがかなり多く含まれていることもわかった。

これらの結果から、第1の方法、第2の方法のいずれの場合にも、得られたパタン対には欠落が多いことがわかる。

(3) 追加拡充の程度

IPA L用例辞書は、日本語動詞の語義分類に基づいて、用例が作成されている。従って、日英翻訳用のパタン対の観点からは、日本語動詞の語義とパタン対との対応関係（1語義が1パタンに対応するか）が問題となる。そこで、日本語の語義の多い代表的な4動詞について、語義とパタン対の対応関係を調査した（表1[白井94b]）。その結果によれば、両者が1対1に対応するものは、4割にとどまり、両者は必ずしも対応しないことがわかった。即ち、IPA L辞書の語義分類は、英語に訳出する上では必ずしも適切でないことを意味している。日英翻訳では、日本語と英語の意味的対応関係に即して、日本語を分類する必要のあることがわかる。

表1 IPA L語義とパタン対の対応

分類 動詞	「語義」対「パタン対」の関係					合計
	1対1	1対n	m対1	m対n	保留	
あがる	8	5	1	3	1	18
あげる	14	2	1	1	3	21
だす	8	9	5	4	1	27
でる	13	3	10	4	2	32
合計	43 43.9%	19 19.4%	17 17.3%	12 12.2%	7 7.1%	98 100%

2.3 人の知識を内省する方法

(1) パタン対収集の方法

前節までの結果から、人間用の和英辞書、日本語辞書の双方からパタン対を収集しても、まだ十分な数が得られないことがわかった。日本語例文とパタン対の関係を観察したところ、同じ動詞を使用しても、動詞の使われ方のニュアンスが異なるときに、新たな英語パタンが必要となる場合が多いことに気づく。そこで第3の方法として、英語の理解できる日本人が辞書等を手がかりにして自分の知識を引き出し、日本語としてニュアンスの異なる用法を可能な限り列挙するという方法で用例の収集を試みることにした。

列挙する用例は、作業にかかる時間にもよるが、ある程度の時間以上考えても用例が思い浮かばなくなるまで抽出することとした。用例数の具体的な抽出目標数としては、いくつかの動詞に対する試行結果に基づき、IPA L動詞辞書の語義数の3～4倍に設定した。また、これらの日本語用例に対する英訳は、3.2節と同様に翻訳専門家に依頼して対訳用例集を作成することとした。

(2) 収集されたパタン対の数

上記の方法に基づけば、約半年年の作業により、300動詞（漢字表記の異なり見ると450動詞、語義数では1,700件）に対し、用例5,200文（和文65,000字、英文34,000語）が収集された。また、収集した用例のうちランダムに選択した30動詞（1,100用例文）からパタン対の抽出を試行したところ、新たに300パタンが抽出された。第1、第2の方法で得られなかったパタン対が、動詞当たり平均10パタンも見つかったことになる。

3 パタン対収集方法の評価

3.1 用例数とパタン対数の比較

適当に選んだ約30の和語動詞に対して2節で述べた3方法を適用し、得られた用例数とパタン対数を比較した(表2)。表から以下のことがわかる。

- ①第1の方法に加えて第2の方法を実施すれば、第1で得られるパタン対の数の2倍近くのパタン対が収集できる。
- ②第1、第2の方法に加えて第3の方法を実施すれば、第1、第2で得られるパタン対の数のさらに2倍以上のパタン対が収集できる。

以上から、和語動詞についていえば、第1の方法では1,500動詞に対する4,000パタン対が収集され[池原93]、第2の方法では1,000動詞に対し1,500パタン対が新たに収集され、第3の方法では1,200動詞に対する4,000パタン対がさらに収集される見込みである。

なお、第3の方法による用例収集では網羅性が問題となるが、一部の動詞について別のアナリストが用例を作成したところ、格要素の名詞などは異なるものの、パタン対を作成する上では等価とみなせる例文が再現率90%以上で収集されたので、アナリストによる差異はあまり問題ではないと思われる。

3.2 必要なパタン数と用例数の見積もり

日英機械翻訳において、パタン対記述の対象となる述語には、和語動詞のほか、サ変動詞や形容詞系の述語がある。サ変動詞の場合は1動詞あたり1～2パタンのものが多いと予想され、内省による用例文の作成は比較的容易であり、第3の方法によるパタン対収集が可能である。形容詞系の述語は和語動詞と同様に多義性があり、第2、第3の方法によりパタン対を収集する必要がある。

以上を踏まえてパタン対の数を推定すると表3を得る。表3では、推定されたパタン対の数に対し本稿の方法によりどれだけ収集できる見込みかも示す。この表から、日英機械翻訳では、汎用パタン、慣用パタンを含めると、約25,000のパタン対が必要と推定されること、また、これらのパタン対は、第1、第2の方法に加えて、第3の方法を実施することにより収集可能となることがわかる。

表2 収集されるパタン対の数(和語動詞の場合)

IPAL表記	漢字表記	方法1	方法2で収集			方法3で収集		一般P の合計	慣用P
		で収集	語義数	例文数	追加P	用例数	新規P		
あく	空く 開く	4 5	10	12	4 2	13 12	4 4	12 11	1 0
あける	空ける 明ける 開ける	4 4 3	11	17	1 0 1	14 9 9	5 2 2	10 6 6	0 1 1
あがる	上がる	7	18	31	16	90	16	39	12
あげる	上げる	8	21	31	13	98	16	37	14
いれる	入れる	5	19	30	12	113	28	45	10
うまる うずまる	埋まる	2	5 3	6 4	2	5	1	5	0
うめる うずめる	埋める	3	4 4	5 4	1	9	0	4	1
おちる	落ちる	8	11	21	7	53	23	38	1
おとす	落とす	6	14	19	5	53	15	26	3
きまる	決まる	3	8	17	2	32	10	15	2
きめる	決める	3	14	20	4	28	5	12	0
くずす	崩す	6	4	4	2	8	2	10	0
くずれる	崩れる	5	4	6	2	13	4	11	0
さく	割く 裂く	2 1	5	7	0 5	4 3	2 0	4 6	0 0
さく	咲く	1	1	1	0	3	2	3	0
さける	避ける	3	6	11	0	9	2	5	0
さける	裂ける	1	1	3	2	4	1	4	0
たつ	立つ 発つ 建つ 経つ	5 2 1 2	13	24	4 0 0 0	75 6 5 3	30 1 0 0	39 3 1 2	11 0 0 0
たつ	断つ 絶つ	4 4	1 3		0 0	6 6	1 2	5 6	0 0
たてる	立てる 建てる	8 1	9 1	17	7 0	69 5	29 0	44 1	7 0
だす	出す	16	27	53	15	95	22	53	21
でる	出る	22	32	49	5	145	38	65	18
はいる	入る	7	23	34	11	105	31	49	5
合 計		156	271	426	123	1102	298	577	108

4 おわりに

日英機械翻訳において、用言の意味を訳し分けるのに必要なパターン対の数とその収集手段について述べた。具体的には、単語当たりの語義が多くパターン対作成が困難な和語動詞を中心に検討し、①和英辞書からパターン対を収集する方法、②日本語動詞の語義対応の用例文を英訳してパターン対を抽出する方法、③それらを参考に、人の知識に基づいて作成した用例文を英訳してパターン対を抽出する方法、の3つのパターン対用例収集の方法を比較した。その結果、主要な約1,000の和語動詞を意味に応じて訳し分けるには、7,500件のパターン対が必要であることがわかった。また、従来の和英辞書から収集できるパターン対の数は必要数の約1/4であること、和英辞書と日本語辞書の語義分類を使用する場合は約1/2であること、必要なパターン対を網羅的に収集するには人の知識を内省して用例を作成する方法が適していることなどがわかった。

また、上記の結果から推定すると、サ変動詞、形容詞系の述語、用言性慣用表現などを含むパターン対全体では、約25,000パターンが必要であること、それらのパターンも人の知識を内省する方法で抽出された用例から比較的容易に収集できる見込みであることがわかった。

現在、第1の方法で得られたパターン対を拡充するため、第2、第3の方法を並行して実施中であり、和語動詞、サ変動詞、形容詞系述語に対してそれぞれ、5,000件、4,000件、2,000件（合計11,000件）のパターン対を収集済みである。また、慣用パターンとしては3,000件が収集済みである。今後は、残され

たパターン対（汎用パターン約9,000件、慣用パターン2,000件）を整備していく予定である。

<謝辞>

本検討にご協力くださった山本弥生氏を始めとするNTTアドバンステクノロジーの各位に感謝する。

<参考文献>

- [Almuallim 94a] Almuallim, H., Akiba, Y., Yamazaki, T., Yokoo, A. and Kaneda, S.: A Tool for the Acquisition of Japanese to English Machine Translation Rules using Inductive Learning Techniques, CAIA 94, San Antonio, Texas
- [Almuallim 94b] Almuallim, H., Akiba, Y., Yamazaki, T. and Kaneda, S.: Two Methods for Learning ALT-J/E Translation Rules from Examples and a Semantic Hierarchy, The Proc. of the 15th International Conference on Computational Linguistics, Kyoto
- [池原89] Ikehara, S.: Multi-Level Machine Translation System, Future Computer Systems, Vol.2, No.3
- [池原93] 池原, 宮崎, 横尾: 日英機械翻訳のための意味解析用の知識とその分解能, 情処論Vol. 34 No. 8
- [IPA 87] 情報処理振興事業協会 技術センター: 計算機用日本語基本動詞辞書 I P A L (Basic Verbs), 解説編&辞書編
- [金田94] 金田, 秋葉, 石井, アルモアリム: 事例に基づく英語動詞選択ルールの修正型学習方式, 「自然言語処理における学習」シンポジウム論文集, 信学会&ソフトウェア科学会
- [研究社84] 小島, 竹林編: ライトハウス和英辞典, 第2版, 研究社
- [黒橋92] 黒橋, 長尾: 格フレーム選択における意味マ-カと例文の有効性について, 情処研報NL-91-11
- [白井94a] 白井, 横尾, 池原, 井上: 日英翻訳用構文意味辞書の記述精度の向上と作成支援, 第48回情処全大6Q-9
- [白井94b] 白井, 横尾, 池原, 井上: I P A L 動詞辞書との対比による日英翻訳用構文意味辞書の充足性の検討, 1994年秋期信学全大D-63
- [横尾94] 横尾, 中岩, 白井, 池原: 日英機械翻訳用スケルトン-フレッシュ型構文意味辞書の構成, 第48回情処全大6Q-8

表3 日英機械翻訳に必要なパターン対の数とその収集に必要な用例の数の見積もり (* 数字表記による異なり数)

比較項目		必要量の見込み		第1の方法(繰)		第2の方法(追加見込み=作業中)			第3の方法(追加見込み=部実施)		
パターンの種類		用言数	パターン対の数	用言数	パターン対の数	*対象用言数	用例数	パターン対見込	対象用言数	見込み用例数	パターン対見込
汎用パターン対	和語動詞	1,500	9,500	1,500	4,000	1,000	5,200	1,500	1,200	15,000	4,000
	サ変動詞	6,500	8,000	3,000	4,000	---	---	---	4,000	8,000	4,000
	形容詞系	2,000	3,000	1,100	2,000	200	2,400	500	500	2,000	500
	小計	10,000	20,500	5,600	10,000	1,200	7,600	2,000	5,700	25,000	8,500
慣用パターン対		---	5,000	---	3,000	---	---	---	---	不明	不明
合 計		10,500	25,500	5,600	13,000	1,200	7,600	2,000	5,700	25,000	8,500