

古語辞典を用いた古語動詞の格フレーム獲得

神山義之[†] 松尾剛^{††}
上原徹三[†] 石川知雄[†]

[†] 武藏工業大学工学部 ^{††} パイオニア株式会社

最近、日本語について単語辞書・格フレーム辞書などの電子化情報が作成され自然言語処理のために利用されている。しかし、これらは現代文に関するものであり、古典文については存在しないのが現状である。そこでわれわれは、古語辞典と現代語の格フレームから古文用の格フレーム情報を作成する方法を試みた。本手法では、古語辞典により得られる訳語を手がかりに、対応する現代語動詞の格フレーム情報を求めて古語動詞の格フレームを推定する。この際、現代語の格助詞から古語の格助詞への変換を行う。また実際の古文（伊勢物語）に現れる動詞とそれに係る格文節の実例と、上の結果として得た当該動詞の格フレーム情報を対応づけるという方法で、一つの評価を行った。その結果、評価可能な動詞について、正しい格フレームと考えられるものが約 60 % であることが分った。

Obtaining Case Frames for Verbs in Old Japanese Language using Japanese Old-Word Dictionary

YOSHIIKU KAMIYAMA,[†] TAKESHI MATSUO,^{††}
TETSUZO UEHARA[†] and TOMOO ISHIKAWA[†]

[†] Faculty of Engineering, Musashi Institute of Technology

^{††} PIONEER CORPORATION

Recently electronic media containing Japanese word dictionary and case frame dictionary are developed for natural language processing. However, these data are for modern Japanese language and not for old Japanese language. We propose a method in which we get case frames for old Japanese verbs using an old-word dictionary and case frames for modern verbs appearing in translation part of the old-verb items in the dictionary. We consider how to convert case particles in modern Japanese into those in old Japanese. To evaluate this method, we compare the resultant case frames obtained with actual examples of verbs and corresponding case phrases appearing in an old Japanese story (Ise Monogatari). The experiment shows that the rate of correct case frames is about 60 % of the evaluated verbs.

1. はじめに

現在、コンピュータで扱う日本語文は主に現代文である。古文にはそれぞれの時代により特色の異なる数多くの文献が存在するが、それらの理解が困難な人達はだんだん増えつつある。そこで、古文の分野においてもコンピュータによる解析などの処理が考えられる。例えば、文を解析する文法解析は現代人の読解支援、古典の機械翻訳、文章検索等への応用が考えられる。

現代文の文法解析には形態素解析、構文解析、意味解析等があり、格文法がこれらに広く使われている。この格文法は、形態素解析と構文解析にお

いては曖昧性の排除に役立ち、また意味解析においても重要な手法として用いられている。

格文法処理ではコンピュータで理解できる形で動詞の意味情報を与えた格フレームが重要な役割を果たす。現代語の動詞については、この格フレーム辞書が開発され利用されている¹⁾。この格文法は、格助詞の省略が多い古文に対しても有効であると考えられる。しかし古文に対しては作成されていない。

そこで、われわれは古文で使用できる格フレームを、古語辞典および既存の現代文用格フレーム辞書を用いることにより半自動的に獲得する。古語辞典から得られる古語と現代語の対応関係により、

現代文用格フレーム辞書を引き、獲得される格フレームを古語用に変換する。また、実際の古文(伊勢物語)に出現する動詞とそれに係る格文節の実例を用いて、古文用格フレームの妥当性を調べる。

以下、使用する辞書について2章で述べる。次に3章では古文の格フレーム辞書の作成方法を述べる。4章では獲得した格フレームの評価方法について、5章では結果と考察について述べる。最後に本研究の結論と今後の課題を述べる。

2. 古語辞典と現代文用格フレーム辞書

古語動詞の格フレームを獲得する実験において、古語辞典と現代語の格フレーム辞書を用いる。古語辞典は、その中の動詞(すなわち古語動詞)見出しに対して記述されている現代語による訳語、あるいは説明文(今後は共に訳語と呼ぶ)の中に現れる現代語動詞を取り出すために用いる。この古語動詞に対応する現代語動詞について、現代語の格フレーム辞書から格フレーム情報を求める、というのが本方法の大筋の考え方である。以下に、これらの辞書情報についてより詳しく述べる。

2.1 古語辞典

古語辞典は古語の単語を見出として、それに対する現代文の訳語や文法事項について記述している。

本稿で使用する「学研全訳用例古語辞典」²⁾は、古文学習に必要な約12000語を収録し、各見出語に対して訳語、漢字表記、品詞、その他の情報を記載している。以下、本稿では単に「古語辞典」と記す。

図1に、使用するデータの書式と用語の定義を例を用いて示す。古語見出し「あいす」に対して、漢字表記は「愛す」、品詞は「他動詞」である。また語義を4つ持つことから、現代文では4通りの意味で使用される。同語義に含まれる訳語、例えば訳語1の「かわいがる」と「愛情をそそぐ」は、同じ意味を持つ類似語の関係にある。

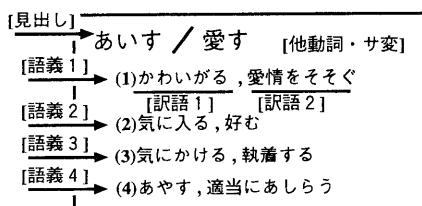


図1 古語辞典の書式

2.2 現代文用格フレーム辞書

本実験では、現代文用格フレーム辞書としてEDR日本語動詞共起パターン副辞書¹⁾を用いる。

格フレーム情報としては、動詞そのもの情報(概念情報を含む)と、その動詞に係り得る格要素の情報が含まれる。格文節に関する情報は、表層格に対応する深層格の種類(概念関係子)、および深層格を満たし得る概念の範囲を示している。概念の範囲を示す概念情報は、動詞と係り得る格要素の各々に付与され、概念識別子と概念説明文とから成る。前者は単語の概念を表した記号であり、後者は概念識別子の意味の把握を容易にするために与えられた現代語である。

例えば、「執着する」の格フレームの1つは、「agentがgoalに」という格要素情報を持つ。この「agent」や「goal」が深層格すなわち概念関係子であり、これらの取り得る概念範囲が概念識別子によって記述される。この場合の「agent」の取り得る概念範囲は概念識別子「30f6b0」で表されている。この概念識別子だけでは辞書の読者に分かりにくないので、概念説明文が付加されている。概念識別子「30f6b0」に対応して記述された概念説明文は「人間」であり、これにより概念識別子「30f6b0」とは「人間」のことを意味するのであり、動詞「執着する」の「agent」の概念範囲が「人間」でなければならないことが判る。これらの情報を、全ての格要素が持つ。また動詞「執着する」自身に対しても概念識別子と概念説明文が与えられている。

3. 古文用格フレーム辞書の作成

現代文の文法解析で広く使われる格文法を、古文の分野で使用することを目的に、現在まで作成されていない古文用格フレームを半自動的に獲得し、辞書化することを目指す。ここでは、古語の動詞と現代語の動詞の意味が同じであれば、その動詞に対する格の使われ方は現代文でも古文でも変わらないと考え、これを基礎に置いている。そこで古語動詞の格フレームを、既存の現代文用格フレームから変換して作成するという方法を取る。

古語動詞の格フレームを獲得するに当たって、訳語の格フレームを利用する。初めに、古語と対応関係にある訳語を使って、その古語の格フレームとして利用できる現代文用格フレームの選択を行う。次の段階で、古文用格フレームとして選択された候補の中から、より信頼度の高い格フレームだけを残すしほり込み処理を行う。ここで、選択としほり込みの段階を分けることで、信頼度の変更が容

易になる。次に獲得した格フレームを古文で使用できるように、格助詞の変換を行う。

以下で、これらの処理を順に説明する。

3.1 古文用格フレーム候補の獲得

古語動詞の訳語は現代語であるため、訳語が分かれれば、その概念識別子、および表記を用いて、EDR 日本語動詞共起パターン副辞書を検索することが可能となる。

そこで、古語辞典を使用することで古語動詞の訳語を抽出し、EDR 日本語単語辞書からその訳語の概念識別子を得た上で、以下の 2 通りの手法を用いて適当な格フレームの選択を行う。

方法 1 同じ概念識別子を持つ動詞を用いた獲得

訳語の概念識別子を用いて、EDR 日本語動詞共起パターン副辞書を検索する。もし同じ概念識別子を持つ動詞が存在すれば、候補としてその格フレームを獲得する。これは、同じ概念を共有する類似語の格フレームが利用できると考えたためである。また、このときに類似語でなく訳語そのものである(つまり見出し、概念識別子が共に一致する)場合は、区別をして登録する。

以降、類似語の格フレームを G(同じ概念識別子を持つことから概念の頭文字 G より取った)、訳語そのものの格フレームを M(見出し語の頭文字 M より取った)と呼ぶことにする。図 2 に、古語動詞「あいす」の格フレーム候補を、その訳語「執着する」の概念識別子によって獲得する例を示す。

- (イ) 「執着する」の表記を用いて EDR 日本語単語辞書より概念識別子「0f55b5」を得る。
- (ロ) 「0f55b5」の概念識別子を持つ類似語の格フレームを EDR 日本語動詞共起パターン副辞書で検索する。
- (ハ) 存在する場合、格フレームの見出しと訳語が一致するかを調べる。ここでは「執着する」で一致するため”訳語の格フレーム(M)”として、古文用格フレーム辞書に登録する。

方法 2 概念説明文を用いた獲得

古語辞典の古語の訳語は、單文によって表記されることが多い。そこで、EDR 日本語動詞共起パターン副辞書の動詞の概念説明文から格フレームを求める方法を検討した。概念説明文は、概念識別子の意味を把握しやすいように与えられた現代語であり、單文で書かれることが

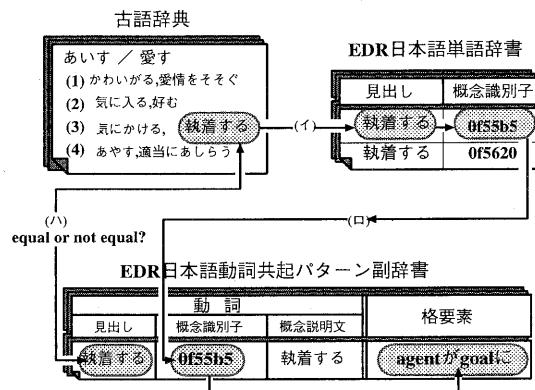


図 2 同じ概念識別子を持つ動詞を利用した獲得

少なくない。EDR 日本語動詞共起パターン副辞書から、古語の訳語文と一致する概念説明文を検索し、存在すれば、その概念説明文を持つ動詞の格フレームを候補として獲得する。図 3 に、古語動詞「あいす」の訳語「気にかける」における、概念説明文を用いた獲得の例を示す。EDR 日本語動詞共起パターン副辞書から「気にかける」の概念説明文を持つ動詞を検索する。その結果、「顧みる」の概念説明文が「気にかける」であるため、この格フレームを候補として獲得する。以降、この条件で獲得した格フレームを S(説明文の頭文字 S から取った) と呼ぶことにする。

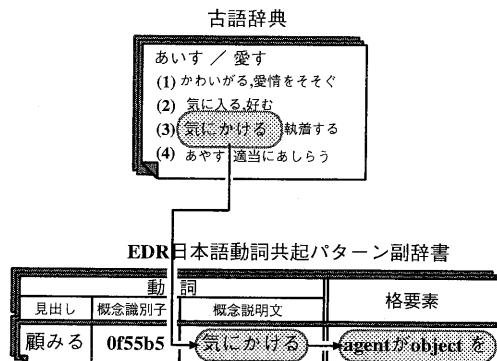


図 3 概念説明文を利用した獲得

方法 1 と方法 2 は、訳語を単位に、並行して行われる。同語義中に複数の訳語が存在する場合、それぞれが 2 つの方法で格フレームの候補を検索し、後述するしづらこみ処理で、より信頼性の高いも

のだけを残す。

しかしこれらの方法で格フレーム候補が獲得できない訳語も存在する。原因は、古語の訳語が單文で表記されていることが挙げられる。そこで、訳語を形態素解析し、最小単位の動詞を抽出した上で上記と同様の手法を試みる。ただし訳語を形態素解析した結果、複数の動詞が現れる場合は、最後尾のものを選び、また「する」「なる」といった動詞に関しては、獲得を試みなかった。

ここで最小動詞を用いて、上記と同様の手法を取るため、方法1(概念識別子の利用)で得られる格フレームには、形態素解析した訳語そのものの格フレーム、および類似語の格フレームの2通りがある。前者をKM、後者をKGと呼ぶことにする(Kは形態素の頭文字を取った)。また方法2(概念説明文の利用)により獲得される格フレームをKSと呼ぶ。図4に、訳語の形態素解析による最小動詞の抽出について示す。「適当にあしらう」をJUMAN³⁾によって形態素解析し、最小動詞「あしらう」を用いて方法1、方法2を行う。

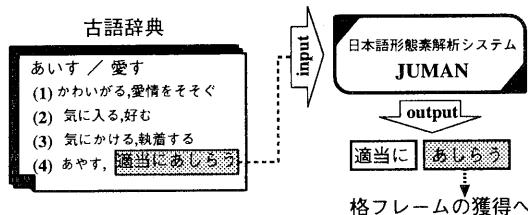


図4 訳語の形態素解析による最小動詞の抽出

3.2 格フレーム候補のしづり込み

格フレームは語義毎に1つ持つことが理想的である。そこで1つの語義中に複数の格フレーム候補が存在する場合、より信頼性の高いと考えられる格フレームのみを残して他のものは削除することを考える。この信頼性の高低は、格フレーム候補の獲得方法として挙げた6つの獲得条件に順位づけすることを行う。今回は経験的に以下のように定めた。数字の小さい方がより高い信頼性を持つことを示す。

- (1) M: 訳語の格フレーム, S: 概念説明文により獲得された類似語の格フレーム
- (2) G: 概念識別子により獲得された類似語の格フレーム
- (3) KM: 訳語最小動詞の格フレーム, KS: 概念説明文により獲得された訳語最小動詞の類似語の格フレーム

(4) KG: 概念識別子により獲得された訳語最小動詞の類似語の格フレーム

また、1つの語義が複数の訳語を持ち、それぞれが格フレームを持つ場合、語義の中で最大の信頼度を調べ、その信頼度を持つ格フレームのみを残す。図5に、1つの語義が3つの訳語を持ち、それぞれの条件で格フレーム候補が獲得された場合のしづり込みの例を示す。この語義中で、最も信頼度が高いのはM, Sであるため、それ以外の格フレームは削除される。

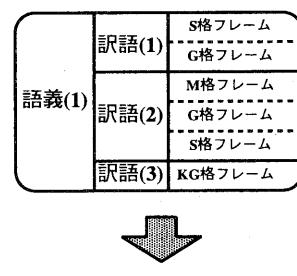


図5 格フレーム候補のしづり込み

3.3 古語の格助詞の調査と助詞変換セットの作成

古語動詞の格フレームの基になる現代語の格フレームを獲得したので、古文で使用できるように変換する必要がある。古文と現代文は、特に助詞に違いがあり、例えば古文においては、格助詞の省略や現代文とは異なる助詞を用いることがある。そこで文法書⁴⁾⁵⁾を調査し、格助詞の変換規則を作成した。変換規則を考えるに当たって、EDR日本語動詞共起パターン副辞書に存在する助詞と概念関係子の組合せを調べ、このセットを変換対象とする。古語助詞は同表記で、現代語の複数の意味で使われるため概念関係子と助詞をセットとして考えることで、概念関係子から現代語の助詞の意味を限定し、適切な変換を行うことができると考えた。以下にその手順を示す。

- (1) EDR日本語動詞共起パターン副辞書で、どのような格(概念関係子+助詞)が使用されているかを調べる。
- (2) 格の概念関係子がどのような概念を持つかを格フレーム内の例文と文法書を用いて特定する。

(3) 特定した概念に付き得る古語の格助詞を文法書を用いて調べる。

以上のように求めた変換規則を、助詞変換セットと呼ぶテーブルで保持する。古文用格フレーム辞書には現代文の助詞を登録しておき、使用する際に助詞変換セットによって変換する。このようにすることで新たな助詞変換規則の追加や不要な助詞変換規則の削除が容易に行える。表1に、作成した助詞変換セットの一部を示す。最左欄の現代語助詞に

表1 格助詞の変換規則（一部）

現代語助詞	深層格	深層格の概念	古語助詞
に (二格)	agent	受身・使役の相手	に
	object	動作の及ぶ対象 動作・作用の及ぶ対象	に と
	implement	動作する場合の方法・手段・材料	より にて して から
	goal	移動の終着 移動する方向	に へ
	source condition	動作・作用の生じる原因・契機	に より から にて
	place	存在する場所	に
	scene	動作の目標としての資格	に

対して、それに付き得る概念関係子を示し、その組み合わせの場合には最右欄の古語助詞に変換することを意味する。例えば、"goal に" は、古語用に変換されると "goal に" もしくは "goal へ" となる。

4. 評価方法

獲得された格フレームの正しさを調べる。正しさの評価には、係り受け情報を持つ古文コーパスを使用する。このコーパスについては後で説明する。係り受け情報から、動詞とその動詞に係る名詞文節を抽出し、これをコーパス格パターンと呼ぶ。この評価では、コーパス格パターンを、それに含まれる動詞の格フレームの1つの正しい実施例と考える。そこでコーパス格パターンと作成した格フレームを照合することで、評価を実現する。また同じ動詞のコーパス格パターンが複数存在する場合は、名詞文節の数が最も多いものを選択した。これは本来、すべてのコーパス格パターンを用いるべきだが、今回は簡略化のために、代表するコーパス格パターンのみで評価した。これにより動詞数に対する正解の割合を求める。また対象の古文コーパスとしては「伊勢物語」を用いる。以下に評価の過程を示す。

(1) 古文コーパスから、出現する動詞と、その係り側の名詞文節を取り出しコーパス格パターンとする。

(2) その古語動詞の格フレームを古文用格フレーム辞書から取り出す。ただし、動詞が複数の語義を持つ場合は、コーパス上にその動詞の概念が記述されていれば、その概念を含む語義の中から格フレームを取り出す。

(3) 取り出された格フレームと、コーパス格パターンを比較する。

獲得した古文用格フレームの正しさを評価する基準として以下の項目を挙げる。

- 動詞に係る名詞の概念に関して

コーパス格パターンに含まれる全ての名詞の概念が、その動詞の格フレームの名詞概念の範囲に含まれているとき正解（正しい格フレームである）とする。

- 表層格に関して

古語助詞と現代語助詞の変換規則に当てはまらない助詞が一つでも存在する場合は、正解でないとする。

- コーパス格パターンの名詞文節数と格フレーム要素数が異なる場合に関して

コーパス格パターンの名詞文節の数が格フレームの格要素より少ない場合はコーパス格パターンの全名詞文節を評価できるような格要素を、格フレームが持つとき正解とする。また逆の場合は正解でないとする。ただし、場所や時を表す名詞文節は、評価の対象としない。

図6に、評価の例を示す。古文コーパスからコーパス格パターンを取り出し、語義1の格フレームとの照合を行う。名詞の概念範囲等が一致したとき「住む」で正しい格フレームが得られたとする。

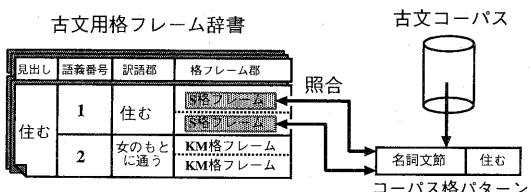


図6 評価方法

5. 結果および考察

5.1 動詞数に対する正解格フレームの獲得状況

伊勢物語で使われている動詞 296 個について評

価を行なった。この評価に使った古文コーパス(伊勢物語)は、古文研究のためにEDR日本語コーパスの形式で作成したものである。本コーパスは、各文例に単語の品詞情報と文節間の係り受け情報を含んでいる。しかし現在のところ単語の概念情報は持っていない。そこで今回は、コーパス上で使われている動詞の語義は、手作業で決定した。なぜなら、コーパス格パターンで使われている動詞の概念を含まない語義の格フレームと一致しても、意味がないからである。

表2に、評価結果を示す。伊勢物語の出現動詞296個のうち、評価可能および評価不可能な動詞はそれぞれ147個、149個である。また評価可能な動詞のうち、正解が90個、不正解が57個となっている。この表で、評価不可能な動詞とは、古文コーパスに出現する動詞のうち、下に述べる要因で評価対象外としたものである。また、評価可能な動詞のうち、コーパス格パターンと格フレーム間の照合に成功したものを正解数の欄に、失敗したものと不正解の欄に示した。

表2 評価結果

伊勢物語に出現する動詞296個(100.0%)			
評価可能147個(49.7%)		評価不可能	
正解	不正解		
90個 (30.4%)	57個 (12.2%)	格フレーム未登録 36個 (12.2%)	その他 21個 (7.1%)
			149個 (50.3%)

以上に対する考察

上記の結果を見ると評価の成功した動詞は90個あり、評価可能な全動詞数の61.2%が正解となった。

また、本評価の不可能な動詞が約半分あることが分かる。この主な原因は以下の2つである。

- 伊勢物語に出現する動詞の中に、作成した古文用格フレーム辞書の見出しとして登録されていない動詞が存在する。つまり獲得の際に使用した古語辞典に登録されていない動詞であり、格フレームの獲得対象となっていない。例えば「行幸す」は古語辞典の見出しとして登録されていない。
- 伊勢物語に出現する動詞の中に、係り得る名詞文節が存在しない動詞がある。これは評価の対象とできない動詞である。例えば、伊勢物語12段3文目「女をば草むらの中に置きて逃げにけり。」の「逃ぐ」には係り得る名詞文節が存在しない(「置きて」が唯一の係り元である)。

また評価可能であり、正しい格フレームが未獲得の動詞に関しては、

- 訳語に対する古文用格フレームが獲得されていない。つまり獲得段階で獲得失敗とみなされた動詞が存在する。例えば、「合はす」の訳語に対しては格フレームが獲得できなかった。
- 動詞の取り得る名詞文節の概念が一致しないことがある。例えば伊勢物語12段2文目の「人のむすめを盗みて、...」において、EDR日本語動詞共起パターン副辞書では「娘を盗む」という言い方は記載されていない。従って現代文用格フレームから作成した古文用格フレームには、このような概念範囲を持っていないため、不正解となる。
- 文法書を用いて作成した助詞変換セットに登録されていない変換対がある。

実際に評価を行う段階で、助詞変換セットに登録されていない、出現回数の多い変換規則を発見した。以下の3つを規則に加えることにした。

- objectを→objectに
- goalを→goalに
- sourceを→sourceに

このように文献に対して評価を行うことで、新たな変換規則が得られることがある。しかし一般性に欠ける規則(特定の文献に依存する規則)でないかを、十分に検討する必要がある。

5.2 正解に対する各段階の割合

表2で示した正解の格フレームが、獲得のどの段階で得られたものであるかを調べ、表3にまとめた。獲得段階の判断には、獲得時に定義した格フレームの文頭の英文字を用いる。

表3 正解の獲得状況

獲得段階	M	S	G	KM	KS	KG
全正解90個 の内訳	46個 51.1%	32個 35.6%	4個 4.4%	8個 8.9%	0個 0.0%	0個 0.0%

M:訳語の格フレーム

S:概念説明文により獲得された類似語の格フレーム

G:概念識別子により獲得された類似語の格フレーム

KM:訳語最小動詞の格フレーム

KS:概念説明文により獲得された訳語最小動詞の類似語の格フレーム

KG:概念識別子により獲得された訳語最小

動詞の類似語の格フレーム

以上に対する考察

この結果は、獲得段階に対する信頼度の与え方に依存するが、形態素解析を用いた獲得方法では、正しいとみなせる格フレームが少ないことがわかる。形態素解析により得られる最小動詞が、もとの動詞とかけ離れた意味を持つ場合、正しい格フレームは獲得できない。またMやSといった信頼度を高く設定したものに関しては、正しいとみなせる格フレームが非常に多くとれていることがわかる。例えば、M(概念および見出し表記での一致を条件に獲得した格フレーム)が、全体の51.1%を占めている。

6. おわりに

古文の文法解析においても格文法が有効であると考え、古文用格フレームの獲得方法について検討した。本研究では、同じ概念の動詞であればそれぞれの格の使われ方が現代文でも古文でも同じであると考え、既存の現代文用格フレームを利用することで古文の格フレーム獲得を目指した。古語辞典を用いることで現代語と古語の対応関係を調べ、その訳語を用いてEDR日本語動詞共起パターン副辞書から古文用として使用できる格フレームを選択する。次に獲得段階に優先順位を与え、しづり込処理をする。また現代文と古文では特に格助詞に違いがあることから、現代文と古文間における助詞変換セットを作成した。以上の手法により獲得した格フレームの評価を、文献「伊勢物語」に基づくEDR形式のコーパスを用いて行った。その結果、以下の結論が得られた。

- 評価可能な147個の動詞に対して、古文用格フレーム辞書には90個の動詞が正しいとみなせる格フレームを獲得できていることが分った。
- 正しいとみなされる格フレームは、概念および見出し表記での一致を条件に獲得したものが全体の51.1%であった。
- 形態素解析を行った訳語により獲得された格フレームは、誤ったものを含む可能性が高かった。
- 評価を行う際に、新たな助詞変換規則を発見できた。

また現在は、考察を踏まえた上で以下の問題点の解決方法を検討中である。

- コーパスに現れない動詞の格フレームの評価方法を検討する。
- 現在は、最も多くの名詞文節を持つコーパス格パターンを評価に用いているが、それ以外の

コーパス格パターンの名詞文節をすべて含んでいるとは限らないという問題がある。

- 上の評価で「正しい」と判断した格フレームの中にも、実際にはそうでないものがありうる。そこで、計算機による評価を行った後、人間が評価を行なう必要がある。
- コーパスに出現する格パターンを用いて、格フレームを自動的に作成し、評価で不正解になった格フレーム、および古語辞典に登録されていない訳語の格フレーム候補として、古語用格フレーム辞書を改良する。

謝辞

「全訳用例古語辞典」をコンピュータ可読形式で提供して頂いた学習研究社のご好意に謝意を表す。なお、本研究の一部は文部省科学研究費基盤研究「コンピュータによる日本語古典文の解析」(11680422)によって行なったものである。

参考文献

- 1) 日本電子化辞書研究所:EDR電子化辞書仕様説明書、日本電子化辞書研究所(1996).
- 2) 金田一春彦:全訳用例古語辞典、学研(1998).
- 3) 黒橋禎夫、長尾真:日本語形態素解析システムJUMANversion3.5 使用説明書、京都大学工学部長尾研究室(1998).
- 4) 清水文雄、松村明、真下三郎:新訂版対訳古典文法、第一学習社(1988).
- 5) 堀口和吉、阪倉篤義:新修文語文法、京都書房(1989).
- 6) 長尾真:自然言語処理、岩波書店(1996).
- 7) 徳田昌晃、奥村学:日本語から手話への機械翻訳における手話単語辞書の補完方法について、情報処理学会論文誌、Vol.39, No.3, pp.542-550(1998).