

結合価パターン対の意味的整合性に関する研究

市川 滋久 池原 悟 村上 仁一

鳥取大学大学院工学研究科

{itikawa,ikehara,murakami}@ike.tottori-u.ac.jp

1 はじめに

日本文の校正校閲技術として意味的な誤り検出技術の実現が期待されている。本論文では、結合価パターンが日本語の名詞と動詞の意味的関係の適切さをどれだけ正しく判定できるかを調べ、意味的な誤り検出への有効性を探る。

具体的には、格要素の省略がないものと仮定して、ランダムに選択した動詞と名詞を組み合わせることによって作成した単文を対象に格要素数と結合価パターンの制約能力の関係を調べる。

2 結合価パターンによる意味的制約

2.1 結合価パターンと名詞意味属性

結合価パターンは、用言と名詞の意味的関係を記述したものである。この制約により、結合価パターンは名詞と動詞の意味的な誤りを調べるのに有効と期待される。

(1) 結合価パターン

本研究では、日本語語彙大系 [1] に掲載されている「構文意味辞書」の結合価パターンを使用する。一般表現文型と慣用表現文型あわせて約 16,000 件の日本語文型パターンにまとめられている。表 1 に結合価パターンの例を示す。

表 1: 結合価パターンの例 (一般表現と慣用句表現)

	結合価パターン
一般表現文型	(4:人) が 働く
慣用句表現	(油) を 売る

一般表現文型は用言と一つ以上の格要素で規定される。格要素は名詞と格助詞から構成され、名詞には一般名詞意味属性が規定される。慣用句表現文型では、格要素が意味属性でなく直接単語の字面で規定される [1]。

(2) 一般名詞意味属性

一般名詞意味属性とは、単語の意味 (語義) により体系的に分類、整理した語彙集である。表 2 に一般名詞意味属性と属する名詞の例を示す。

表 2: 一般意味属性と属する名詞の例

一般名詞意味属性	名詞
5:人間	人物, 人類, 皆
362:組織	システム, 地下組織
367:公共機関	学校, 空港, 市場

(3) 一般名詞意味属性体系

本研究で使用する一般名詞意味属性体系 (図 1) は、約 40 万語の名詞を、最大 12 段の木構造を構成する 2,710 の意味属性に分類している。また、一般名詞意味属性体系は、木構造を基本構成としているため、上位の意味属性を持つ語の性質は、下位の意味属性を持つ語に伝搬できる [1] 性質がある。結合価パターンは、この上位下位の関係を利用して文の意味的整合性を判定する。

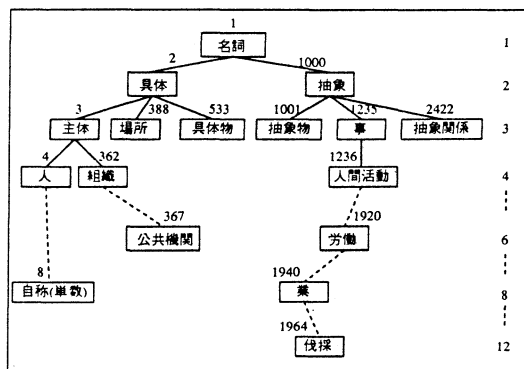


図 1: 一般名詞意味属性体系の一部

2.2 単文の意味的整合性の判定方法

結合価パターンと名詞意味属性体系の上位下位関係を利用して、文の意味的整合性を判定する方法を、具

体例をあげて説明する。

以下の結合価パターンの例について考える。

(4:人)が働く

上記の例に対して次の2文を考える。

例文1) (私)が働く

例文2) (学校)が働く

例文1は名詞が(私)で人以下の属性(8:自称(単数))であるので、結合価パターンにより意味的に合っていると判定され、例文2では名詞(学校)が人以外の属性(367:公共機関)なので誤りであると判定される。

3 実験の方法

ランダムに選んだ名詞と動詞からなる単文を対象に2.2節の方法を用いて結合価パターンによって意味的な整合性がどれだけ正しく判定されるかを実験的に調べる。

3.1 実験に用いる名詞及び動詞

実験に用いる動詞は日常良く使用される動詞とするため計算機用日本語基本動詞辞書IPALに収録されている動詞とする。その動詞を和語動詞と漢語動詞に分ける。使用する名詞は、良く使用される基本的な名詞として計算機用日本語基本名詞辞書IPALに収録されている名詞と、収録されている名詞の数が豊富なALT-J/Eの日本語単語辞書の中から一般名詞のみの2種類を用いる。使用する動詞と名詞の種類の組み合わせにより以下の4つに分けて実験する。

表 3: 実験に使用する動詞と名詞の組み合わせ

	動詞	名詞
実験1	和語動詞	一般名詞
実験2	和語動詞	IPAL名詞
実験3	漢語動詞	一般名詞
実験4	漢語動詞	IPAL名詞

3.2 実験の手順

単文での結合価パターンの制約能力を調べるために以下の手順で実験を繰り返す行う。

1. ある動詞固有の特性が現れないようにするため乱数を用いランダムに動詞を一つ選択する。
2. 選ばれた動詞の格要素数が等しい結合価パターンを全て列挙する。
3. 結合価パターンに、ランダムに選ばれた名詞を当てはめて単文を生成する。

4. 生成された単文が結合価パターンの制約条件を満たしているかどうかの判定を行う。
 5. 3、4の手順を繰り返し単文を5000文生成する。
 6. 結合価パターンの制約条件を満たした文と制約条件を満たさなかった文の両方を意味的に適切な文であるかどうかを人手により評価する。
- ただし、格要素数を統一するため慣用句表現文型は除き、使用するの是一般表現文型のみとする。

3.3 単文の評価方法

生成した文を、人手で意味的に適切な文であるかどうかを判断する。判断に用いる指標は以下のA,B,C,Dとする。

- A:日常的に用いられうる文
- B:想像すれば意味が合っている文
- C:意味的に通じない文
- D:判断不能文

4 実験結果

各実験の結果をそれぞれ動詞の格要素数が1、2、3のときに分けて評価を行った。

実験1～4の結果を図2～5に示す。図の中で制約条件を満たした文の結果を○、満たさなかった文の結果を×としている。




図 2: 実験1(和語動詞-一般名詞)の結果




図 3: 実験2(和語動詞-IPAL名詞)の結果




図 4: 実験 3(漢語動詞-一般名詞) の結果




図 5: 実験 4(漢語動詞-IPAL 名詞) の結果

図 2～5 より、格要素数が多いほど結合価パターンの制約条件を満たす文は少なくなることがわかった。また、結合価パターンの制約条件を満たした文でも意味的に誤っている文(評価 C)が存在し、制約条件を満たさなかった文でも意味的に適切な文(評価 A,B)とした文が存在することがわかった。

5 考察

5.1 単文の評価例

評価基準により、生成した文の評価を行った。以下に、動詞「しくじる」のときの、結合価パターンの制約条件を満たした文と、制約条件を満たさなかった文の評価 A、B、C、D のそれぞれの例を示す。

結合価パターン

(3:主体) が (1236:人間活動) を /に/ で しくじる

(4:人) が (372:団体・派) を しくじる

評価の例 (制約条件を満たした文)

A:医者が 会見を /に/ で しくじる

B:牧童が 購買請求を /に/ で しくじる

C:若主人が 惜敗を /に/ で しくじる

D:怨敵が シナゴークを /に/ で しくじる

評価の例 (制約条件を満たさなかった文)

A:大多数が 模擬試験を /に/ で しくじる

B:本因坊が FORTRAN を /に/ で しくじる

C:維持が 積分変数を /に/ で しくじる

D:ストレッチが プッシーを /に/ で しくじる

生成した文の評価を行った結果、結合価パターンが意味的に合っていると判定した文中でも評価 C や評価 D とした文があり、結合価パターンはまだ不備な点があるといえる。

5.2 単文の評価例の解析

(1) 結合価パターンの制約条件を満たした文

評価 C の例を以下に示す。

例 1) 若主人が 惜敗を /に/ で しくじる

例 2) 国語伝習所が 銅婚式を /に/ で しくじる

例 3) 人波が 新陳代謝を /に/ で しくじる

例 1 の文では、2 格の惜敗が意味的に誤っている。惜敗の意味属性は (1760:敗北) であるので、結合価パターンの制約条件から、1760:敗北 を除くことが不備の解消につながると考えられる。だが、(1760:敗北) には名詞「位負け」があり、「位負け」を例 1 に当てはめると以下に示す文となる。

若主人が 位負けを /に/ で しくじる

上記の文は意味的に適切な文である。例 2 や例 3 の単文でも同様のことがいえる。単純に意味的に誤っている名詞の意味属性を制約条件から除くことが、結合価パターンの不備の解消につながるわけではないことがわかった。

(2) 結合価パターンの制約条件を満たさなかった文

評価 A と B の例を示す。

A:大多数が 模擬試験を /に/ で しくじる

B:本因坊が FORTRAN を /に/ で しくじる

評価 A,B の文は結合価パターンが意味的に適切な文を見逃した例である。評価 A の文について考えてみる。人手によって評価するとき「大多数」を意味属性・人・として考え、評価 A の文を意味的に適切な文であると判断する。しかし、結合価パターンでは名詞「大多数」は意味属性 (2600:部分) のみに属していることから意味的に誤っていると判定された。評価 B の文についても、同様である。

人間が文章の意味的整合性を判断するとき、名詞の本来の意味とともに比喩的な意味まで考えて判断し情

報を補っている。しかし、結合価パターンでは名詞の属する意味属性のみで判定を行うため、結合価パターンの制約条件を満たさなかった文中でも評価 A,B とした文があると考えられる。

5.3 実験結果の解析

結合価パターンの制約条件を満たさなかった文中の意味的に誤っている文(評価 C+D)を生成された全単文中の意味的に誤っている文で割った値を意味的不整合性を見逃さない割合として表4に示す。

結合価パターンの制約条件を満たした文中の意味的に適切な文(評価 A+B)を生成された全単文中の意味的に適切な文で割った値を意味の整合性を見逃さない割合として表5に示す。表5の意味的に適切な文とする範囲を評価 A のみとした値を表6に示す。また、表4～6の結果を図6のグラフで示す。なお表中の数値は実験1～4の平均値である。

表 4: 意味的不整合性を見逃さない割合(評価 C+D)

格要素数	1	2	3
文の割合 (%)	68.8	97.7	99.2

表 5: 意味の整合性を見逃さない割合(評価 A+B)

格要素数	1	2	3
文の割合 (%)	68.4	13.8	6.2

表 6: 意味の整合性を見逃さない割合(評価 A)

格要素数	1	2	3
文の割合 (%)	80.1	18.0	16.3

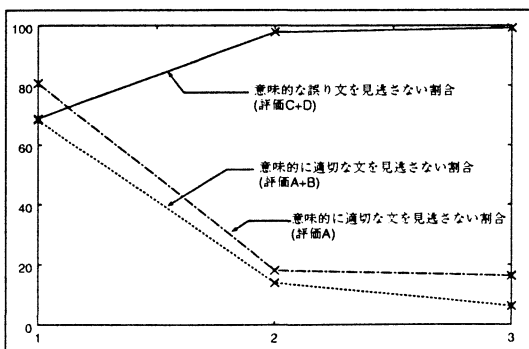


図 6: 格要素数による意味の整合性と意味的不整合性を見逃さない割合

この結果以下のことが示された。

1. 表4より、意味的に誤っている文を見逃さない割合は最大で99%あった。また、格要素数が多いほど意味的に誤っている文を見逃さない割合は多くなる。
2. 表5,6より、意味的に適切な文とする範囲によって違いはあるが格要素数が多いほど意味的に適切な文を多く見逃している。格要素数が3の場合では6～16%しか見逃さずに正解としていない。

格要素数が多くなると意味的に誤っている文を見逃さない割合が多くなるのは、格要素が1つだけのときより意味的な整合性を判断する情報が多くなり、より厳密な判断を行った結果だと考えられる。また、結合価パターンが、意味的に正しい文の比較の多くを誤りと判定しているのは、結合価パターンでは、換喩、提喩などに相当する表現は正しい文とみなされないことによるものと考えられる。なお、格要素数が多くなると意味的に適切な文を多く見逃しているのは、格要素のいずれかが誤っている文又は両方の格要素が誤っている文の割合が増大するためと考えられる。

6 おわりに

本研究では、格要素の省略がないと仮定して、動詞の格要素数と結合価パターンの制約能力の関係を調べた。

格要素数が多いほど、結合価パターンが意味的な誤り文を見逃さない割合は多くなり、格要素数が3の場合で99%となった。

格要素数が多いほど、結合価パターンの制約条件を満たす文は少ない結果になったが、意味的に適切な文を見逃さない割合は減少した。

また、今回の実験ではサンプリングデータが少なかったため、一般名詞とIPAL名詞、和語動詞と漢語動詞の実験結果の差異は見られなかった。

今後は、格要素の省略も考慮にいった制約能力についての検証が考えられる。

参考文献

- [1] 池原, 宮崎, 白井, 横尾, 中岩, 小倉, 大山, 林 (1997): 日本語語彙大系, 岩波書店
- [2] 市川, 池原, 村上: 結合価パターン対の意味的整合性に関する研究, 言語処理学会第6回年次大会 (予定)