

複数の格要素に依存した選択嗜好モデル

Selectional Preference Model with Multiple Case Fillers

谷塚太一 高村大也 奥村学
Taichi Yatsuka Hiroya Takamura Manabu Okumura

東京工業大学
Tokyo Institute of Technology

We propose a probabilistic model for selectional preference of verbs. We focus on the preference that depends on multiple case fillers. Our model is based on the probabilistic semantic indexing, and is enhanced with the parameter estimation scheme that makes good use of 2-term data in addition to 3-term data.

1. 序論

自然言語処理分野では、選択嗜好の知識は省略解析や曖昧性解消問題などに有効な情報として古くから研究されてきた。選択嗜好とは、ある述語の各格にどのような単語が出現しやすいかの嗜好である。例えば、動詞「読む」は主格(ガ格)に「彼」などの人間を、また目的格(ヲ格)には「本」などの読まれる対象をとる。ここで、ガ格の「彼」やヲ格の「本」を各格の格要素という。

初期の頃からよく研究されてきたものとして、語の共起の情報を用いた選択嗜好知識の獲得が挙げられる[1]。日本語を対象にした選択嗜好獲得の研究では、EDR辞書[2]や日本語語彙体系[3]のような資源に代表されるように、どの格にどのような意味クラスの表現が入りやすいかを人手で記述する試みがなされていた。しかし、例外的な現象に対して制約もしくは嗜好の知識を記述し尽くすことは困難なため、人手による記述は網羅性の点で問題がある。このような背景から、コーパス中に出現する共起用例を用いた選択嗜好の自動獲得の手法が宇津呂ら[4]や河原ら[5]などによって提案されてきた。これらの手法は、網羅性という点で優れているが、他の格が述語の意味を特殊化するような場合には対応できない。例えば、「鮭が証言をする」という不適切な表現について、述語「する」と1つの格の組合せ、つまり「鮭がする」や「証言をする」という組み合わせについてはコーパス中に出現する可能性が高いため、この表現の不適切さを認識できない。

本稿では、複数の格要素を確率モデルで表現することにより、この問題を解決する。具体的には、確率的潜在意味インデクシング(PLSI)[8]を拡張した確率モデルを用い、さらにパラメータ推定に工夫を加えた。提案手法の有用性を調査するために、日本語を対象とした選択嗜好の良さを見積る先行詞選択問題を用いた評価実験を行い、同時に従来手法との比較を行った。

2. 関連研究

動詞 v が与えられたとき名詞 n がその目的語として出現する確率を用いた手法が代表的である。Daganら[13]はその最尤推定値 $P(n|v)$ を用いて、次の指標を n の嗜好とした：

$$\sum_{v' \in SIMS(v)} Sim(v', v) P(n|v'). \quad (1)$$

$Sim(v', v)$ は2つの動詞 v と v' の類似度を表す関数で、分布類似度に基づき選択された v' を用いて動詞の確率分布をスムージングする意味を持つ。この $Sim(v', v)$ については、Erk[7]がどのような類似度の尺度を利用すべきかについて比較し、Jaccard係数と、情報理論に基づいた指標が最も良かったと報告した。また、Erk[7]は、相互情報量を用いた選択嗜好モデルを提案した。ただし、これらの手法は特定の1つの格要素と動詞の組み合わせだけ考慮しており、他の格要素が動詞の意味を制約する場合に対応できない。

谷塚ら[11]は、格要素間の依存関係を考慮した選択嗜好モデルを構築する研究を行った。彼らは共起した単語間の整合性を、共起確率を元にした共起尺度を用いて数値化している。共起行列が非常にスパースになるという問題を避けるため、PLSI[8]を利用して、参照格と動詞の2項共起確率、評価格と動詞の2項共起確率をそれぞれ計算し、それらを組み合わせることで3項共起確率を算出した。

高村ら[10]は2つの単語の共起事例の持つ意味がポジティブであるか、ネガティブであるかという極性を判定するため、PLSIを拡張した3PLSIを導入した。これは、単にPLSIを3項に拡張したものである。3項共起事例を学習に用い、3項+隠れ変数1項の関係をモデル化することができる。高村ら[10]の3項の内訳は、単語2つとその組み合わせの極性1つであった。

PLSIの共起確率は $P(x, y) = \sum_z P(x|z)P(y|z)P(z)$ と表されるのに対し、これを単に3項に拡張した3PLSIの共起確率は以下ようになる：

$$P(x, y, w) = \sum_z P(x|z)P(y|z)P(w|z)P(z).$$

しかし、3項共起事例は2項共起事例に比べて非常に数が少なく偏っている可能性があるため、自然なデータから学習できているとは言えないという問題がある。

本研究は、谷塚ら[11]の研究の延長線上にあると言える。谷塚ら[11]ではPLSIを用いて擬似的に3項共起事例の選択嗜好をモデル化した。本研究では高村ら[10]の3PLSIを利用して直接的に3項共起事例の選択嗜好をモデル化する。さらに、3PLSIでの学習の際に、より自然なデータから学習できるようにした手法を提案する。

なお、本稿においても便宜的に、谷塚ら[11]と同様に文脈となる格要素を「参照格」、直接的に選択嗜好の評価の対象となる格要素を「評価格」と呼ぶ。

3. 提案手法

3項共起事例(動詞 v , 参照格 n , 評価格 m)の生起確率を, 3PLSI に従って次のように定義する^{*1}:

$$P(vnm) = \sum_z P(v|z)P(n|z)P(m|z)P(z).$$

この確率値を算出するためのパラメータ値は, 3項共起事例から学習することができる. しかし, 実際のデータは省略などが非常に多く, 3項共起事例は2項共起事例と比較して非常に量が少ない. 特に日本語ではこの傾向が強い. また, 偏っている可能性もある. そこで, 2項共起事例と3項共起事例を合わせたデータを学習に用いることを提案する. そのために, ここでは2項共起事例を3項共起事例のうちの1項が偶然欠けて隠れ変数となってしまったものであるとみなす.

EM アルゴリズムの Q 関数は $Q(\phi|\theta)$ 以下のように表せる:

$$\begin{aligned} & \sum_{vnm} N_{vnm} \sum_z \bar{P}(z|vnm) \log P(v|z)P(n|z)P(m|z)P(z) \\ & + \sum_{vn} N_{vn} \sum_{mz} \bar{P}(mz|vn) \log P(v|z)P(n|z)P(m|z)P(z) \\ & + \sum_{vm} N_{vm} \sum_{nz} \bar{P}(nz|vm) \log P(v|z)P(n|z)P(m|z)P(z) \\ & + \sum_{nm} N_{nm} \sum_{vz} \bar{P}(vz|nm) \log P(v|z)P(n|z)P(m|z)P(z). \end{aligned}$$

ここで, N_{vnm} は, 3項事例 v, n, m のデータ中での出現回数であり, N_{vn} は, 2項事例 v, n のデータ中での出現回数である. 各2項事例について, v, n, m のうち2つは観測変数となり, 残りの1つと z が隠れ変数となる. つまり, この式の第一行は動詞, 参照格, 評価格の3項全てが観測された場合, 残りの行は3項のうちの2項だけ観測された場合に対応している. 更新式は, 表1のようになる. これにより, 2項共起事例と3項共起事例の両方を用いた学習を実現することができる.

また, 2項共起事例と3項共起事例の数の偏りによる影響を操作するために, 2つ学習データのどちらにどの程度重みをつけるかを決定する学習重みパラメータ $\rho (0 \leq \rho \leq 1)$ を導入する. これにより, 更新式は表2のようになる. ただし, Eステップは表1と同じなので省略した.

このようにして得られた共起確率を, 選択選好の望ましさを表した指標とみなす.

4. 評価実験

前節で導入した選択選好モデルの評価を行う. PLSI に基づいた谷塚ら [11] の手法をベースラインとし, これを PLSI とよぶことにする. このベースラインと, 3項データで推定した3PLSI モデル (3PLSI), 3項データと2項データで推定した3PLSI モデル (3PLSI+) を比較する. 以下に説明する先行詞選択問題によって評価実験を行った.

4.1 先行詞選択問題

4.1.1 問題設定

ある動詞の格要素が1つだけ省略されており, そのゼロ代名詞の先行詞の候補が複数提示されている状況で正しい先行詞を選択選好の評価値のみを用いて選択する問題を考える. 本来な

*1 紙面の節約のため, 以降の数式で変数の間のカンマを省略する.

らば, 先行詞の選択には選択選好に加えて, 出現箇所やその語の顕現性など他の要因が関与するため, 選択選好だけでは適切に先行詞を選択することはできない. そのため, ここでは先行詞を候補集合の中でどのくらい上位にランク付けできるかで選択選好モデルの評価を行う. 例として次の問題を考える.

問題: 「(ϕ が) 休戦を 提案した」

選択肢: 「大統領が」「防空壕が」「空爆が」, ...

この場合, 述語が「提案した」, 参照格が「休戦を」, 評価格が各選択肢となる3項共起事例を考える. これら3項の共起確率 ($P(\text{大統領が, 休戦を, 提案した})$, $P(\text{防空壕が, 休戦を, 提案した})$, $P(\text{空爆が, 休戦を, 提案した})$, ...) を算出して降順にランキングを行い, その1位に正解である選択肢を含む3項共起確率が位置していれば正解であるとする. この例題での正解は「大統領」なので, $P(\text{大統領が, 休戦を, 提案した})$ の値が最も高い場合に正解となる. 正解でない場合でも, 上位に位置していることが望ましい.

また, 谷塚ら [11] は, ガ格的格要素を選択するためにヲ格や二格を参照格として用いることが有効であるのは直感的であり, PLSI を用いた手法でのモデル化の結果はそれを支持するものであったと報告している. また, ヲ格を参照格として二格的格要素を選択することも有効であったとも報告している. そこで, 今回我々が提案する手法においても同様であると仮定し, 評価格がガ格かつ参照格がヲ格と二格, および, 評価格が二格かつ参照格がヲ格である場合を扱う.

4.1.2 選択肢の作成

NAIST コーパス中のある動詞に省略された格要素 (ゼロ代名詞) が存在するとき, その動詞以前の同記事中出现している名詞句を選択肢とする. この選択肢の中でゼロ代名詞と照応関係にある名詞句を正解, それ以外の名詞句を不正解としている. 照応関係は NAIST コーパスのものを用いた. なお, 本実験ではゼロ代名詞の部分の評価格としている.

例えば, 以下のような記事があったとする.

大統領が防空壕に避難した.

空爆の後 連合側に使者を派遣し, (ϕ) 休戦を提案した.

「(ϕ) 休戦を 提案した」というガ格的ゼロ代名詞 ϕ を含んだ事例がある. このゼロ代名詞を含む事例より以前の文書中に「大統領が 防空壕に 避難した」という事例があったので, 名詞句である「大統領」と「防空壕」を選択肢とする. 同様に「空爆」「連合側」「使者」も選択肢とする. さらに, コーパスの情報から, ゼロ代名詞 ϕ と「大統領」が照応関係にあったため「大統領」は正解の選択肢とする. 正解の選択肢は1つとは限らない. また, 同じ表現が記事中に複数出現しており, そのうちの1つがゼロ代名詞と照応関係となっている場合がある. この場合, 同じ表現が正解と不正解になるという問題が生じる. 選択選好を評価するという観点からは正解となり得る表現を選択することができれば良いため, 同じ表現が複数出現する場合はそのいずれかが正解の場合は正解とし, それ以外の場合は不正解とする. これにより, 実際の照応解析タスクの状況より簡単な問題となることに注意されたい.

さらに, このように作成した選択肢のうち, 学習データに用いた3項共起事例に出現しなかった名詞は除外した. これは, 2項共起事例にのみ出現する名詞は3項共起事例の省略部分の照応詞として不適切である可能性が高いからである.

4.1.3 評価方法

問題ごとに全ての選択肢に対して指標 (共起確率) を求め, その指標の降順にランク付けを行う. 評価は MRR と正解率で

表 1: EM アルゴリズムの更新式 (重み付きでない Q 関数)

$$\begin{aligned}
 \text{E ステップ} \quad & \bar{P}(z|vnm) = \frac{P(z)P(v|z)P(n|z)P(m|z)}{\sum_{z'} P(z')P(v|z')P(n|z')P(m|z')}, \quad \bar{P}(zv|nm) = \frac{P(z)P(v|z)P(n|z)P(m|z)}{\sum_{zv} P(z)P(v|z)P(n|z)P(m|z)}, \\
 & \bar{P}(zn|vm) = \frac{\bar{P}(z)P(v|z)P(n|z)P(m|z)}{\sum_{zn} P(z)P(v|z)P(n|z)P(m|z)}, \quad \bar{P}(zm|vn) = \frac{P(z)P(v|z)P(n|z)P(m|z)}{\sum_{zm} P(z)P(v|z)P(n|z)P(m|z)} \\
 \text{M ステップ} \quad & P(z) = \frac{\sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm)}{\sum_z \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}} \\
 & P(v|z) = \frac{\sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm)}{\sum_v \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}} \\
 & P(n|z) = \frac{\sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm)}{\sum_n \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}} \\
 & P(m|z) = \frac{\sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm)}{\sum_m \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) + \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}}
 \end{aligned}$$

表 2: EM アルゴリズムの更新式 (重み付き Q 関数) . E ステップは上と同じなので省略

$$\begin{aligned}
 \text{M ステップ} \quad & P(z) = \frac{\rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}}{\sum_z \left\{ \rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\} \right\}} \\
 & P(v|z) = \frac{\rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}}{\sum_v \left\{ \rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\} \right\}} \\
 & P(n|z) = \frac{\rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}}{\sum_n \left\{ \rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\} \right\}} \\
 & P(m|z) = \frac{\rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\}}{\sum_m \left\{ \rho \left\{ \sum_{vnm} N_{vnm} \bar{P}(z|vnm) \right\} + (1-\rho) \left\{ \sum_{vn} N_{vn} \bar{P}(z|vn) + \sum_{nm} N_{nm} \bar{P}(z|nm) + \sum_{vm} N_{vm} \bar{P}(z|vm) \right\} \right\}}
 \end{aligned}$$

行う。MRR は、正解選択枝の最高順位の逆数の平均である。正解率は、正解選択枝が 1 位である問題の割合である。

4.2 実験設定

実験は、評価格と参照格の組み合わせが“ガ格とヲ格”，“ガ格とニ格”，“ニ格とヲ格”の 3 つの場合、およびそのそれぞれで動詞数 100,200,500 の 3 つの場合 (動詞は頻度が多いものから順に選んだ)、合計 9 つの場合に分けて行った。

提案手法については事前に学習データの 5 分の 1 の量の開発データを用いて学習重みパラメータの決定を行った。開発データと学習データは動詞によって分割し、データの重複は無いものとする。パラメータ ρ は 0.1 から 0.9 までの 0.1 刻みの 9 つの値から選んだ。ただし、ニ格とヲ格の場合は、テストデータが非常に少なかったため、すべてのパラメータで差がなく、適切な値が求められなかった。このときは、 $\rho = 0.5$ とした。

テストデータ中には、学習データ中出现しない単語が出現する可能性がある。本実験では、そのような単語を一括で未知語として扱う。確率の正規性を保つため、学習結果の確率分布中の最小値の半分を未知語の確率として与え、同時に分布全体に最小値を足し、その分布を正規化し直した。これは、言語モデルにおける Back-off スムージングに類似した方法である。

今回は、各事例中に動詞は必ず存在するという設定でデータを収集したので、 $N_{nm} = 0$ である。

4.3 実験データ

4.3.1 学習に用いる共起事例

毎日新聞 1996 年と 1997 年の 2 年分の記事から抽出した 2 項および 3 項の共起事例を用いる。CaboCha[12] を利用して係り受け解析を行い、動詞 1 項とそれに係る格要素 1 もしくは 2 項を抽出した。また、格は頻度の高いガ格、ヲ格、ニ格の

3 種類に限定した。また、学習の際には、頻度が少ない共起事例はノイズになる可能性が高いと判断し、頻度が 10 以下の事例は除去した。各動詞数の場合の訓練事例数を表 3 に示す。な

表 3: 訓練事例数

動詞数	評価格/参照格	3 項共起	2 項共起	2 項共起
			(参照格)	(評価格)
100	ガ格/ヲ格	1017	341069	207451
	ガ格/ニ格	3266	290800	293586
	ニ格/ヲ格	2465	416418	265938
200	ガ格/ヲ格	1455	373171	215728
	ガ格/ニ格	4377	319236	315446
	ニ格/ヲ格	3237	492902	297084
500	ガ格/ヲ格	2037	378177	217102
	ガ格/ニ格	7302	335362	332559
	ニ格/ヲ格	4515	542573	317855

お、3 項共起事例に比べて 2 項共起事例が極端に多いという事例数の偏りによる影響を抑えるため、各事例の頻度を各データの全体の事例数で割ることにより正規化した。

4.3.2 テストデータ

述語項構造の情報が付加された NAIST テキストコーパス [9] のタグ付け事例を用いる。事例は全て選択選好として正しいものである。NAIST コーパス中の事例は、述語の基本形と格要素 (ガ格、ヲ格、ニ格) からなる。省略されている場合は、照応先が明記されている。

5. 実験結果と考察

実験の結果は、以下の表 4 から表 8 にまとめた。

表 4: 選択問題実験結果 (MRR):ガ格/ヲ格

手法	動詞数 100	動詞数 200	動詞数 500
PLSI	.076	.013	.089
3PLSI	.187	.190	.171
3PLSI+	.210	.225	.206

表 5: 選択問題実験結果 (MRR):ガ格/二格

手法	動詞数 100	動詞数 200	動詞数 500
PLSI	.078	.089	.095
3PLSI	.182	.187	.185
3PLSI+	.142	.161	.159

表 6: 選択問題実験結果 (MRR):二格/ヲ格

手法	動詞数 100	動詞数 200	動詞数 500
PLSI	.060	.056	.099
3PLSI	.043	.027	.055
3PLSI+	.122	.110	.112

表 7: 選択問題実験結果 (正解率):ガ格/ヲ格

手法	動詞数 100	動詞数 200	動詞数 500
PLSI	.013	.041	.026
3PLSI	.102	.107	.084
3PLSI+	.126	.144	.116

表 8: 選択問題実験結果 (正解率):ガ格/二格

手法	動詞数 100	動詞数 200	動詞数 500
PLSI	.023	.027	.032
3PLSI	.099	.101	.096
3PLSI+	.026	.069	.068

評価格がガ格かつ参照格がヲ格である場合(表 4, 7)は,多くの部分で 3PLSI+ が良い結果だった. カイ二乗検定を行った結果, 有意水準 5% で有意であった. この結果から, 2 項共起データを学習したことによる効果が顕著に現れたといえる. 開発データを用いて決定したパラメータは, 最良ではないが適切な値であった.

評価格がガ格かつ参照格が二格である場合(表 5, 8), 3PLSI+ が 3PLSI を上回ることはなかった. これは, 二格の曖昧性によると考えられる. 二格は目的格以外にも, 副詞句を導くなど(例「大胆に」), その役割に高い曖昧性を持つ. よってヲ格などと比べるとノイズになりやすい. そのため, より多くの二格を学習に用いた提案手法の結果が悪くなったと考えられる. なお, ヲ格は明確に目的格として使用される場合がほとんどであるため, 参照格として利用するのに有用である. もし目的格である二格のみを用いることができた場合, ノイズになることは少なく, より良い結果を得られると考えられる. なお, このことは谷塚ら [11] の考察を支持する結果である.

評価格が二格かつ参照格がヲ格である場合(表 6), MRR の比較においては全体的に提案手法が良い結果を示した. 正解率については, ほとんどの場合で 0 であったので省略する.

6. 結論

本研究では, 述語 1 項と格要素 2 項の 3 項からなる事例の選択選好をモデル化するため, 拡張した PLSI を用いる手法を提案した. 提案手法では, 高村ら [10] が拡張した 3PLSI を利用し, さらに学習に用いるデータの種類を増やすことによって, モデル化の精度を高めるといふ試みを行った. 今回, 学習には従来の 3PLSI が用いている 3 項共起事例に加え, 2 項共起事例も用いた. これは, 本来ならば 3 項で構成されるべき

表現において何らかの理由により格要素の省略が発生し, 表層的に 2 項だけで構成されているような事例を学習に用いることを可能にするものである.

評価実験においては, 3PLSI+ の学習重みを適切に設定した上で学習を行い, 先行詞選択問題の結果による MRR および正解率で比較を行ったところ, 評価格がガ格かつ参照格がヲ格の場合は 3PLSI+ が有効であることが確認できた. 評価格がガ格かつ参照格が二格の場合は 3PLSI+ が有効でないことがわかった. これは二格の曖昧性によるものであると推測される. 評価格が二格かつ参照格がヲ格の場合は 3PLSI+ が有効である可能性があることがわかった.

以上のことから, 適切な格の組み合わせかつ学習重みパラメータを適切に設定した場合, 3PLSI+ により 3 項共起事例に加えて 2 項共起事例を学習に用いたことで, 3 項共起事例の選択選好をより正確にモデル化できると言える.

今後の課題としては, まず他手法 [6,7] との比較実験が挙げられる. また, 今回の実験では, 特に評価格が二格, 参照格がヲ格の場合にテストデータの不足によって, 厳密な比較ができなかった. より包括的な実験も期待される. また, 計算の高速化も必要である.

参考文献

- [1] Phillip Resnik. Selectional Preference and Sense Disambiguation. *Workshop in Association for Computational Linguistics*, pp.52-57. 1997.
- [2] EDR 電子化辞書. 1995.
http://www2.nict.go.jp/r/r312/EDR/J_index.html
- [3] 池原悟, 宮崎正弘, 白井諭, 横尾昭男, 中岩浩巳, 小倉健太郎, 大山芳史, 林良彦. 日本語語彙大系 CD-ROM 版. 岩波書店. 1999.
- [4] 宇津呂武仁, 宮田高志, 松本裕治. 最大エントロピー法による下位範疇化の確率モデル学習および統語的曖昧性解消による評価. *IPSJ-SIGNL-119*, pp.69-76, 1997.
- [5] 河原大輔, 黒橋禎夫. 用言と直前の格要素の組を単位とする格フレームの自動構築, *自然言語処理*, Vol.9, No.1, pp.3-19, 2002.
- [6] Shane Bergsma, Dekang Lin, Randy Goebel. Discriminative Learning of Selectional Preference from Unlabeled Text. *EMNLP*, pp.59-68, 2008.
- [7] Katrin Erk, A simple, similarity-based model for selectional preferences. *ACL*, pp.216-223, 2007.
- [8] Thomas Hofmann. Probabilistic Latent Semantic Indexing. *SIGIR*, pp.50-57, 1999.
- [9] 飯田龍, 小町守, 乾健太郎, 松本裕治. NAIST テキストコーパス: 述語項構造と共参照関係のアノテーション. *IPSJ-SIGNL-177*, pp.71-78, 2007.
- [10] 高村大也, 乾孝司, 奥村学. 隠れ変数モデルによる複数語表現の感情極性分類, *情報処理学会論文誌ジャーナル*, Vol.47, No.11, pp.3021-3031, 2006.
- [11] 谷塚太一, 飯田龍, 徳永健伸, 格要素間の依存関係を考慮した選択選好モデル, *IPSJ-SIGNL-193*, 2009.
- [12] CaboCha/南瓜: Yet Another Japanese Dependency Structure Analyzer.
<http://chasen.org/~taku/software/cabocho/>
- [13] Ido Dagan, Lillian Lee, Fernando Pereira. Similarity-based models of cooccurrence probabilities. *Machine Learning*, pp.43-69, 1999.