

## 大規模格フレームを用いた識別モデルに基づく 日本語ゼロ照応解析

笹野 遼平<sup>†1</sup> 黒橋 禎夫<sup>†2</sup>

本稿では、大規模格フレームを用いた識別モデルに基づく日本語ゼロ照応解析モデルを提案する。提案モデルは、格ごとに個別にゼロ代名詞の検出、ゼロ代名詞とその先行詞の対応付けを行うのではなく、大規模格フレームを用い、その述語がとりうるすべての格とテキスト中に出現した談話要素の対応付けを全体で評価し、省略された項も含む述語項構造の解析を行う。対応付けの評価には対数線形モデルを用い、照応関係が付与された比較的小規模なコーパスから得られる構文的手がかりに加え、大規模テキストから自動構築した格フレームから得られる語彙の手がかりを素性として利用する。Web テキストを対象とした実験により、提案モデルの有効性を示し、また、格ごとにどのような素性が重要となるかの傾向を明らかにする。

### A Discriminative Approach to Japanese Zero Anaphora Resolution with Large-scale Case Frames

RYOHEI SASANO<sup>†1</sup> and SADA O KUROHASHI<sup>†2</sup>

We present a discriminative model for Japanese zero anaphora resolution that simultaneously determines an appropriate case frame for a given predicate and its predicate-argument structure. Our model is based on a log linear framework, and exploits lexical features obtained from a large raw corpus, as well as non-lexical features, which represent syntactic and discourse preferences, obtained from relatively small annotated corpus. We report results of zero anaphora resolution on Web text, and show the effectiveness of our approach. In addition, we also investigate the relative importance of each feature.

<sup>†1</sup> 東京工業大学精密工学研究所

Precision and Intelligence Laboratory, Tokyo Institute of Technology

<sup>†2</sup> 京都大学大学院情報学研究所

Graduate School of Informatics, Kyoto University

#### 1. はじめに

ゼロ照応解析とは、述語の省略された項を検出し、省略された格要素<sup>\*1</sup>が指し示す内容を同定する処理である。省略された格要素はゼロ代名詞と呼ばれる。日本語では、述語の項は頻繁に省略されることから、ゼロ照応解析は述語項構造解析を行ううえで重要な処理であるといえる。たとえば以下の文では、「焼く」の二格が省略されており、二格ゼロ代名詞の先行詞は文頭の「息子」となっている。

(i) 息子は悪戯が好きで私も (φ 二) 手を焼いている。

一般に照応解析を行うためには、構文的選好や語彙的選好など様々な知識が必要となる<sup>2),12)</sup>。このうち構文的選好は、述語の種類によらない一般的な知識であることから人手により照応関係の情報が付与された比較的小規模なコーパスから獲得することが可能である。一方、語彙的選好は、述語ごとに個別に必要な知識であり、小規模なデータから獲得することは困難である。特に、ゼロ照応解析を行う場合は、述語とその1つの項の関係に関する知識だけでは不十分な場合があり、非常に大規模な知識源が必要となる。たとえば、「焼く」という述語の二格だけに注目すると、「息子」などのような“人”を表す名詞よりも、「DVD」などのような“磁気ディスク”を表す名詞が入りやすいと考えられるが、(i)の例のようにヲ格が「手」である場合は、“人”を表す名詞が入りやすく、このような性質を考慮するために述語とその複数の項が関係する語彙的選好に関する知識が必要となると考えられる。

Sasano ら<sup>15)</sup>は、このような語彙的選好のための知識として自動獲得した大規模格フレームを用いたゼロ照応解析の確率モデルを提案している。Sasano らのモデルでは、共参照関係の認識を行いテキスト中に出現する談話要素を特定した後、解析対象の述語に対し考えられるすべての格フレームと談話要素の対応付けを確率的に評価し、最も確率が高いと判断された対応付けをその述語の解析結果としている。確率的評価を行う際は、独立性を仮定し、複数の語彙的選好を表す部分と構文的選好を表す部分に分解し、それらの確率の積をとることで最終的な確率的評価値を求めている。しかし、独立性を仮定し種々の選好を表す部分に分解しているため、Sasano らのモデルには、新たな素性、特に既存の素性と重複するような手がかりの導入が困難であるという問題点がある。また、ガ格の解析には構文的手がかりが重要であり、ヲ格の解析には語彙的手がかりが重要であるなど、格の種類によって各手がかりの重要性は異なると考えられるが、このような重要性の違いを考慮することもでき

\*1 本稿では、「体言 + 格助詞」のことを項と呼び、そこに含まれる体言のことを格要素と呼ぶ。

ない。

そこで本研究では、大規模格フレームに基づくゼロ照応解析を対数線形モデルを使ってモデル化することにより、Sasano らのモデルでは自然に導入できなかった互いに重なりを持つ素性を利用でき、また、素性ごとの重要性の違いを考慮可能なゼロ照応解析モデルの構築を行う。モデルの学習に使用するデータには、述語項構造に関する情報のみが付与され、格フレームに関する情報は付与されていないが、パラメータ推定時に適切な格フレームの推定も同時に行うことで、適切な格フレーム選択モデルも含むゼロ照応解析モデルを構築する。

構築したモデルの有効性は、主に Web テキストを対象とした実験により示す。Web テキストを主な対象とするのは、ニュース記事やブログなど多くのタイプのテキストを含み、より実用的な設定であると考えられるためである。また、素性ごとの学習された重みや、各素性を使用しなかった場合の解析精度の変化を調べることで、格ごとに有効となる素性の傾向を明らかにする。

## 2. 関連研究

日本語では項の省略が頻繁に起きることから、日本語ゼロ照応解析に関する研究は多く行われてきた。Seki ら<sup>17)</sup> は人手で作成した格フレームを用いたゼロ照応解析の確率モデルを提案している。Kawahara ら<sup>7)</sup> は人手で作成した格フレームの用例スパースネスを解消するため、大規模コーパスから自動構築した格フレームを省略格の検出、および、先行詞の同定に利用したゼロ照応解析モデルを提案している。Kawahara らのモデルは、先行詞同定における選択選好の手がかりとして各述語の格要素の用例を利用しているが、本稿で提案する手法とは異なり各用例の出現頻度は考慮していない。Iida ら<sup>3)</sup> はゼロ代名詞とその先行詞の間の統語的パターンを利用した機械学習に基づく手法を提案している。Iida らのモデルでは、先行詞の選択選好に関する知識として、述語と解析対象の格に関する情報は使用しているが、複数の格を考慮した知識は使用していない。

ゼロ照応解析は述語項構造解析と強い関連があることから、これらを同時に解決するモデルもいくつか提案されている。すでに述べたように Sasano ら<sup>15)</sup> は大規模格フレームを利用した述語項構造とゼロ照応解析の確率モデルを提案している。Taira ら<sup>18)</sup> は意味役割とゼロ照応関係を含む述語項構造を決定リストを用いて解析する手法を提案している。Imamura ら<sup>5)</sup> はゼロ照応解析も含む述語項構造解析の対数線形モデルを提案している。本稿で提案するモデルは、出現した述語に対し最適な格フレームの推定することで複数の項の評価を同時に行っているのに対し、Taira ら、Imamura らの手法ではいずれも格ごとに別々に評価を

行っている。また、吉川ら<sup>20)</sup> は Markov Logic Network<sup>14)</sup> を用い局所的な選好と大域的な選好を考慮した日本語述語項構造解析モデルを提案している。吉川らのモデルは大域的な選好を取り入れることで複数の項を同時に考慮したモデルとなっているが、計算量の点から文間のゼロ照応関係を扱うのが困難であり、また、Markov Logic Network の性質から本研究で使用している自己相互情報量 (PMI) のような実数素性を取り入れるのが困難であるという問題点がある。

日本語以外の言語に目を向けると、Ferrandez ら<sup>1)</sup> はスペイン語のゼロ照応を対象に、人手で記述したルールに用いて照応性判定と先行詞同定を行う手法を提案している。Zhao ら<sup>19)</sup> は、中国語におけるゼロ照応解析のための機械学習に基づく手法を提案している。Kong ら<sup>9)</sup> は、ゼロ照応解析を、ゼロ照応の検出、照応性の判定、先行詞同定の 3 つのサブタスクに分割し、これらを統合的に解析するカーネルベースの手法を提案している。

## 3. 大規模格フレームと用例の汎化

格フレームとは、用言とそれに関係する名詞を用言の用法ごと、格ごとに整理した知識であり、テキストから自動構築する手法が提案されている<sup>21)</sup>。表 1 に本研究で使用した「焼く」の格フレームの例を示す。「食べ物」を焼く、「手」を焼く、「データ」を焼く」という意味ごとに格フレームが構築されており、それぞれの用法においてとりうる格の種類と、その格の用例が記されている。

近年、Web から大量のテキストを容易に収集できるようになったことから大規模な格フレームの構築が可能となってきている。しかしながら、Web テキスト 16 億文から構築した格フレームであってもゼロ照応解析を行ううえで十分なカバレッジを持っているとはいえない<sup>16)</sup>。たとえば、「甥」や「太郎」などといった語は表 1 に示す格フレーム『焼く (1)』のガ格を埋めることができると考えられるが、これらの用例は『焼く (1)』のガ格には含まれていない。したがって、より高精度なゼロ照応解析の実現のためにはこれらの語と『焼く (1)』のガ格を対応付けられるようにする必要があると考えられる。

この問題に対処するため、Sasano ら<sup>15)</sup> は、形態素解析システム JUMAN6.0<sup>24)</sup> の辞書に付与されている 22 種類のカテゴリ情報 (CT)、および、IREX<sup>6)</sup> で定義された 8 種類の固有表現情報 (NE) を用い格フレームの用例を汎化し、ゼロ照応解析において利用している。具体的には、これらの属性を持つ用例がどのくらいの割合を占めるかの情報を各格スロットに付与し利用している。本研究ではさらに、より粒度の細かい汎化情報を考慮できるよう、Kazama らが導入した確率的クラスタリング法<sup>8)</sup> によりクラスタリングされた意味

表1 「焼く」の格フレーム  
Table 1 Example case frames of 'yaku (bake/have difficulty/burn)'.

格	用例(頻度)	汎化用例(割合)
焼く(1) ガ格	私:39, 主人:26, 娘:22, 母さん:19, ..., 麻子:2, ...	CT-人:0.620, NE-人:0.116, CL-887:0.070, ...
ヲ格	パン:9265, ケーキ:4495, 肉:4057, 魚:2002, ...	CT-食べ物:0.711, CL-883:0.221, CT-動物部位:0.105, CT-動物:0.077, ...
二格	おやつ:35, 朝食:33, 誕生日:29, 土産:21, ...	CT-抽象物:0.233, CT-食べ物:0.171, CL-624:0.076, ...
テ格	フライパン:894, 中火:425, ...	CT-人工物:0.356, CL-291:0.252, ...
焼く(2) ガ格	誰:7, 先生:7, 皆:5, 家族:4, 政府:3, 全員:3, ...	CT-人:0.372, NE-人:0.128, CT-組織・団体:0.128, ...
ヲ格	手:6864	CT-動物部位:1.000
二格	加減:70, 子供:52, 攻撃:43, 扱い:40, 対策:32, 娘:30, ...	CT-抽象物:0.432, CT-人:0.172, NE-人:0.060, ...
焼く(3) ガ格	俺:1, 夫:1	
ヲ格	ファイル:20, 曲:14, 音楽:9, ...	CT-抽象物:0.645, CT-人工物:0.273
二格	CD:3106, DVD:2066, ...	CL-70:0.829, ...
テ格	ライティングソフト:10, ...	CL-抽象物:0.294, CT-人工物:0.191, ...

表2 意味クラスと、それぞれのクラスへの帰属度上位の名詞の例  
Table 2 Examples of clusters, and nouns that have high probabilities of belonging to the clusters.

CL:32	子供 (0.974), 幼児 (0.738), こども (0.727), 乳幼児 (0.436), ...
CL-70	CD(0.896), DVD(0.837), CDROM(0.603), カセットテープ (0.512), ...
CL-291	中弱火 (0.720), とろ火 (0.715), 中火 (0.681), 遠火 (0.678), ...
CL-624	夕飯 (0.926), 夕食 (0.925), 昼食 (0.882), 朝食 (0.868), ...
CL-884	ラーメン (0.860), うどん (0.801), カレー (0.793), ケーキ (0.749), ...
CL-887	母 (0.909), 両親 (0.875), 母親 (0.838), 夫 (0.775), 父親 (0.774), ...

クラス (CL) を用いた格フレームの用例の汎化を行う。意味クラスを用いた用例の汎化には、100万個の名詞を2,000個の意味クラスに分類した結果を使用する。表2に意味クラスと、それぞれのクラスへの帰属度上位の名詞の例を示す。括弧内の数字はその名詞の意味クラスへの帰属度を表している。

格フレームに汎化情報として記述する際は、各クラスへの帰属度が0.001以上である名詞を対象とし、用例中の割合と帰属度の重み付け平均を計算し、意味クラスに関する情報とし

て記述する。たとえば、クラス 'CL-70' への帰属度が0.896であるCDを3,106個、0.837であるDVDを2,066個、帰属度が0.001以下である名詞を271個、用例として持つ格スロットがあった場合、次式により 'CL-70:0.829' という情報を意味クラスに関する情報として付与する。

$$(0.896 \times 3106 + 0.837 \times 2066) / (3106 + 2066 + 271) \approx 0.829$$

表1に示す格フレームの汎化用例において 'CT', 'NE', 'CL' で始まる情報がそれぞれカテゴリ、固有表現、意味クラスによる汎化情報を表している。

#### 4. 識別モデルに基づくゼロ照応解析

##### 4.1 提案モデルの概要

ゼロ照応解析は、候補ごとの確率的評価の方法を除き、Sasanoら<sup>15)</sup>と同様の手順で行う。以下に解析手順の概要を示す。

- (1) 形態素解析、固有表現認識、構文解析を行う。
- (2) 共参照解析を行い、テキスト中に出現した談話要素を認識する。本研究では、文節主辞となっている体言を共参照関係にあるものごとにとまとめたものを談話要素として扱う。
- (3) 入力テキスト1文ごとに、文末の述語\*1から順に、以下の手順で格フレームと談話要素の対応付け候補を生成し、最も確率的評価が高い対応付けを解析結果\*2として出力する。
  - (a) 解析対象述語の格フレームを1つ選ぶ。
  - (b) 解析対象述語と直接係り受け関係にある談話要素を、選ばれた格フレームの格スロットと対応付ける。談話要素が係助詞をともなって出現した場合や、被連体修飾節に出現した場合など、複数の格スロットとの対応付けが考えられる場合は、考えうるすべての対応付けを生成する。
  - (c) 上記の処理で生成された対応付け候補に対し、対応付けられなかったガ格、ヲ格、二格と、解析対象述語と係り受け関係にない談話要素の対応付けを行い、ゼロ照応も考慮した対応付け候補を生成する。

ただし、計算時間短縮のため、手順(3)において格フレームと談話要素の対応付け候補を

\*1 本稿の実験では動詞と形容詞を解析の対象とする。

\*2 出力結果に含まれる述語項の対応付けのうち、述語と項の間に係り受け関係がないものをゼロ照応解析の結果として扱う。

表 3 例文 (i) 中の「焼く」に対する格フレームと対応付けの例

Table 3 Examples of possible combinations of a case frame  $cf$  and predicate-argument structure  $a$  for the predicate 'yaku' in (i).

1	<格フレーム: 『焼く (1) <sub>a</sub> , ガ格:私, ヲ格:手, ニ格:息子>
2	<格フレーム: 『焼く (1) <sub>a</sub> , ガ格:私, ヲ格:手, ニ格:(対応なし)>
3	<格フレーム: 『焼く (1) <sub>a</sub> , ガ格:(対応なし), ヲ格:手, ニ格:私>
4	<格フレーム: 『焼く (1) <sub>a</sub> , ガ格:息子, ヲ格:手, ニ格:(対応なし)>
5	<格フレーム: 『焼く (2) <sub>a</sub> , ガ格:私, ヲ格:手, ニ格:息子>
6	<格フレーム: 『焼く (2) <sub>a</sub> , ガ格:私, ヲ格:手, ニ格:(対応なし)>
	⋮

生成する際, (b) の時点での対応付けの評価スコア<sup>\*1</sup>により足切りを行い, スコア上位<sup>\*2</sup>のものから生成される対応付けのみを候補として考慮する.

#### 4.2 識別モデルに基づく対応付けの評価

格フレームと談話要素の対応付けは格ごとに個別に評価するのではなく, 述語項構造全体で評価する. たとえば, 1章の例文 (i) 中の「焼く」の解析を考える場合, 表 3 にあげるような様々な対応付けを考え, その中で最も確率的評価の高い対応付けを最終的な述語項構造として出力する.

Sasano ら<sup>15)</sup> は独立性を仮定し分解した複数の語彙的選好を表す部分と構文的選好を表す部分の確率的評価値の積をとることにより各候補の確率的評価を行っている. これに対し本研究では入力テキスト  $t$ , 解析対象述語  $p$  が与えられたとき, 格フレーム  $cf$ , 格フレームと談話要素の対応付け  $a$  の条件付き確率を, 以下のような対数線形モデルで表現する.

$$P(cf, a|p, t; \Lambda) = \frac{1}{Z(p, t)} \exp\{\Lambda \cdot \mathbf{F}(cf, a, p, t)\} \quad (1)$$

$$Z(p, t) = \sum_{\{cf, a\} \in C(p, t)} \exp\{\Lambda \cdot \mathbf{F}(cf, a, p, t)\} \quad (2)$$

ここで,  $\mathbf{F}$  は 5 章で定義する素性関数で構成されるベクトル,  $\Lambda$  は素性関数に関する重みを表すパラメータ,  $C(p, t)$  は与えられた用言がとりうる格フレーム, および, 格フレームと談話要素の対応付けの集合を返す関数である.

\*1 5 章で導入する格解析スコアにより評価する.

\*2 本稿の実験では, 予備実験の結果を基にスコア上位 20 件のみを考慮した.

#### 4.3 パラメータ推定

パラメータ推定は,  $N$  インスタンスの学習セット  $\{(a^{(1)}, p^{(1)}, t^{(1)}), (a^{(2)}, p^{(2)}, t^{(2)}), \dots, (a^{(N)}, p^{(N)}, t^{(N)})\}$  が与えられたとき, 事後確率を最大化するような格フレーム  $cf$  とパラメータ  $\Lambda$  の組合せを求めることにより行う.

$$\max_{CF, \Lambda} \left\{ \sum_{n=1}^N \log P(cf^{(n)}, a^{(n)} | p^{(n)}, t^{(n)}; \Lambda) - \alpha \|\Lambda\|^2 \right\} \quad (3)$$

ここで,  $CF = (cf^{(1)}, cf^{(2)}, \dots, cf^{(N)})$  は, 各インスタンスのとりうる格フレームの組合せである. 一般にゼロ照応関係が付与されたデータは格と先行詞の対応付けのみが付与されており, どれが適切な格フレームかという情報は付与されていない. このため, 通常最大エントロピー法と異なり, 各インスタンスに対し事後確率が最大となるような格フレーム  $cf^{(n)}$  を求める必要がある. パラメータ推定の手順を以下に示す.

- (1) パラメータ  $\Lambda$  を初期化する<sup>\*3</sup>.
- (2) 各インスタンスごとに, 現在のパラメータ  $\Lambda$  で  $P(cf, a|p, t; \Lambda)$  が最大となるよう, すわなち, 以下の式を満たすように  $cf^{(n)}$  を更新する.

$$\hat{cf}^{(n)} = \operatorname{argmax}_{cf} P(cf^{(n)}, a^{(n)} | p^{(n)}, t^{(n)}; \Lambda) \quad (4)$$

すべてのインスタンスに対し,  $cf^{(n)}$  が更新されなかった場合, その時点のパラメータ  $\Lambda$  を最終的な推定値とする.

- (3) いずれかの  $cf^{(n)}$  が更新された場合は,  $N$  インスタンスの学習セット  $\{(cf^{(1)}, a^{(1)}, p^{(1)}, t^{(1)}), (cf^{(2)}, a^{(2)}, p^{(2)}, t^{(2)}), \dots, (cf^{(N)}, a^{(N)}, p^{(N)}, t^{(N)})\}$  に対し, 確率モデルの事後確率を最大化するように  $\Lambda$  を更新し, (2) に戻る. 本研究では過学習を防ぐため  $L_2$  正則化を行い, 以下の式を最大化するパラメータ  $\Lambda$  を求める<sup>\*4</sup>.

$$\mathcal{L}_\Lambda = \sum_{n=1}^N \log P(cf^{(n)}, a^{(n)} | p^{(n)}, t^{(n)}; \Lambda) - \alpha \|\Lambda\|^2 \quad (5)$$

式 (5) を最大化する  $\Lambda$  は L-BFGS 法<sup>13)</sup> により求める<sup>\*5</sup>. また, 上記の手順は, 手順 (2),

\*3 本稿の実験ではパラメータの各要素を  $[0, 1]$  の範囲の乱数により初期化した.

\*4 本稿の実験では  $\alpha = 10$  とした.

\*5 libLBFGS 1.9 (<http://www.chokkan.org/software/liblbfgs/>) を使用した.

手順 (3), いずれにおいても尤度は単調に増加することから収束は保証されるが, 式 (3) の中括弧の中身を最大化することは保証されない. そのため実験の際は, 複数の初期値を用いて推定を行い, 尤度が最大となったパラメータを最終的な推定値として使用する.

## 5. 使用する素性

本研究では, 格解析スコア, 用例 PMI, 意味クラス PMI, カテゴリ PMI, 固有表現 PMI, 対象格の埋まりやすさの 6 種類の素性を語彙的選好を反映する素性として, 先行詞の出現格と位置に関する素性, 先行詞の顕現性に関する素性の 2 種類の素性を構文的・談話的選好を反映する素性として利用する. これらの素性のうち, 格解析スコア, 各種 PMI, 対象格の埋まりやすさに関する素性は実数素性, それ以外の素性はバイナリ素性である.

格解析スコアを除く素性は, ガ格, ヲ格, 二格それぞれに対し別々に設定する. また, いずれの素性も対象の格が直接係り受け関係にある語によって埋められなかった場合にのみ考慮する. たとえば, 表 3 中の対応付け <格フレーム: 『焼く (2)』, ガ格:私, ヲ格:手, 二格:息子> であれば, ガ格, ヲ格は直接係り受け関係にある語により埋められており, これらの対応付けに関する情報は格解析スコアに含まれていると考えられることから, ガ格, ヲ格に関する素性はいずれも 0 とし, 二格に関する素性のみを考慮する.

### 格解析スコア

直接係り受け関係にある語と格スロットの対応付けの確からしさを考慮するため, 河原ら<sup>22)</sup> が提案した構文・格解析の統合的モデルに基づき, 以下の式で与えられる省略を考慮しない述語項構造解析のスコアを素性として使用する\*1. 格解析スコアは各述語に対し 1 つ設定する.

$$\text{score}(cf_i, CA_k, p) = \log P(cf_i, CA_k | p) = \log P(cf_i | p) + \log P(CA_k | cf_i) \quad (6)$$

$p$  が解析対象述語,  $cf_i$  が選択された格フレーム,  $CA_k$  が格の対応関係をそれぞれ表しており, 右辺の第 1 項はある述語  $p$  が与えられた場合に格フレーム  $cf_i$  が生成される確率 (格フレーム生成確率), 第 2 項は格フレーム  $cf_i$  が与えられた場合に格の対応関係  $CA_k$  が生成される確率 (格の対応関係生成確率) を表している. このうち格フレーム生成確率は大規模コーパスの格解析結果から推定する. また, 格の対応関係生成確率はさらに以下のように分

解される.

$$P(CA_k | cf_i) = \prod_{s_j: A(s_j)=1} \left\{ P(A(s_j) = 1 | cf_i, s_j) \times P(n_j, c_j | cf_i, s_j, A(s_j) = 1) \right\} \\ \times \prod_{s_j: A(s_j)=0} P(A(s_j) = 0 | cf_i, s_j) \quad (7)$$

ここで,  $s_j$  は格フレーム  $cf_i$  の格スロット,  $n_j$  は格スロット  $s_j$  に対応付けられた格要素,  $c_j$  は  $n_j$  の表層格を表し,  $A(s_j)$  は格スロット  $s_j$  が入力側格要素に対応付けられていれば 1, そうでなければ 0 となる関数である.  $P(n_j, c_j | cf_i, s_j, A(s_j) = 1)$  は格スロット  $s_j$  が入力格要素に対応付けられている場合にその格要素が  $n_j$ , 表層格が  $c_j$  となる確率であり, 以下により近似する.

$$P(n_j, c_j | cf_i, s_j, A(s_j) = 1) \approx P(n_j | cf_i, s_j, A(s_j) = 1) \times P(c_j | s_j) \quad (8)$$

$P(c_j | s_j)$  は表層格生成確率であり述語項構造が付与されたコーパスから,  $P(n_j | cf_i, s_j, A(s_j) = 1)$  は格フレームから計算する. また, 式 (7) 中の  $P(A(s_j) = \{0, 1\} | cf_i, s_j)$  は格スロット生成確率であり大規模コーパスの格解析結果から計算する.

### 用例 PMI

ある格スロットにどのくらい先行詞候補が入りやすいかを考慮するため, 対象の格スロットと, 先行詞候補の自己相互情報量 (PMI) を素性として使用する. 対象の格スロットの用例における先行詞候補の占める割合を, 一般のテキスト中における先行詞候補の占める割合で割ることにより計算する.

$$\text{e.g. } \log \{ P(\text{子供} | \text{格フレーム: 『焼く (2)』, 二格}) / P(\text{子供}) \}$$

対象の格スロットが対応付けられていない場合は 0, 対象の格スロットの用例に先行詞候補が含まれていない場合は一定の小さな値  $\gamma^{*2}$  を与える.

### 意味クラス PMI

格フレームの用例スパースネス問題を軽減するため, 対象の格スロットの意味クラス情報と, 先行詞候補の意味クラスの自己相互情報量も素性として使用する. 先行詞候補が帰属度 0.001 以上となる意味クラスを持っている場合にのみ使用する.

$$\text{e.g. } \log \{ P(\text{CL-32} | \text{格フレーム: 『焼く (2)』, 二格}) / P(\text{CL-32}) \}$$

\*1 河原ら<sup>22)</sup> のモデルでは解析対象述語の付属語列  $f_i$  を考慮しているが, 本研究では格スロット  $s_j$  と付属語列  $f_i$  が与えられた場合の格要素タイプ  $f_j$  の生成確率  $P(f_j | s_j, f_i)$  を, 付属語列  $f_i$  に依存しない表層格生成確率で近似し, 付属語列  $f_i$  は考慮しない.

\*2 本稿の実験では  $\gamma = \log(0.000001)$  とした.

カテゴリ PMI

対象の格スロットのカテゴリ情報と、先行詞候補のカテゴリの自己相互情報量。先行詞候補にカテゴリが付与されている場合のみ使用する。

$$\text{e.g. } \log\{P(\text{CT-人} \mid \text{格フレーム: 『焼く (2)』, 二格})/P(\text{CT-人})\}$$

固有表現 PMI

対象の格スロットの固有表現情報と、先行詞候補の自己相互情報量。先行詞候補が固有表現であると解析された場合のみ使用する。

$$\text{e.g. } \log\{P(\text{NE-人} \mid \text{格フレーム: 『焼く (2)』, 二格})/P(\text{NE-人})\}$$

以下では意味クラス PMI, カテゴリ PMI, 固有表現 PMI の 3 つの素性をまとめて汎化用例 PMI と呼ぶ。用例 PMI, 意味クラス PMI, カテゴリ PMI, 固有表現 PMI の 4 種の素性はいずれも先行詞がどのくらい対象の格スロットに対応付けられやすいかを表す素性であり, Sasano らのモデル<sup>15)</sup> では自然に導入できなかった互いに重なりを持つ素性である。これらの素性はいずれも自動構築した大規模格フレームから計算する。

対象格の埋まりやすさ

格フレームのそれぞれ格の埋まりやすさは、その格が明示されていない場合に、ゼロ代名詞として省略されているのか、単にその格が考慮されていないのかの判断の手がかりになると考えられる。たとえば、表 1 に示した格フレーム『焼く (3)』の二格が明示されていない場合、この二格は非常に埋まりやすい格であることから、二格はゼロ代名詞として省略されている可能性が高いと考えられるが、『焼く (1)』の二格が省略されている場合は単にその格が考慮されていない可能性が高いと考えられる。そこで、対象の格スロットが直接係り受け関係にある語によってどのくらい埋められやすいかという情報を素性として使用する。

対象の格がゼロ代名詞として先行詞と対応付けられた場合は対象の格スロットが直接係り受けに関係ある語によって埋められる確率、すなわち、格解析スコアを計算する際に使用した格スロット生成確率  $P(A(s_j) = 1 \mid c f_i, s_j)$  の自然対数を、対応付けられなかった場合は、1 から格スロット生成確率を引いた値、すなわち、対象の格スロットが直接係り受け関係にある語によって埋められない確率の自然対数を素性として使用する。

先行詞の出現格と位置

先行詞の構文的・談話的選好を反映させるため、先行詞の出現格と位置に関する素性を導入する。表 4 に示すような 85 個の出現格と出現位置に関するカテゴリを設定し、先行詞候補が、あるカテゴリに出現した場合、そのカテゴリに対応する素性の値を 1、そうでない場合は 0 とする。複数のカテゴリに該当する場合は該当するすべての素性の値を 1 とする。

表 4 先行詞候補の出現格・位置カテゴリの例  
Table 4 Examples of case/location categories.

文内 (Intra) の先行詞候補 (64 カテゴリ)	
Itopic:	副助詞「は」をともなって出現
IP-self:	解析対象述語の係り先 (Parent)
IC-self:	解析対象の述語に係る (Child)
IGP-self:	解析対象述語の係り先の係り先 (Grand-Parent)
IGC-self:	係り先が解析対象の述語に係る (Grand-Child)
⋮	⋮
IB-self:	上記以外で同一文の前方に出現 (Before)
IA-self:	上記以外で同一文の後方に出現 (After)
IP-ga-ov:	解析対象述語の係り先述語のガ格 (非省略)
IP-ga-om:	解析対象述語の係り先述語のガ格 (省略)
IP-wo-ov:	解析対象述語の係り先述語のヲ格 (非省略)
⋮	⋮
IGP-ga-ov:	解析対象述語の係り先の係り先述語のガ格 (非省略)
⋮	⋮
先行文中 (Before) の先行詞候補 (21 categories)	
B1:	直前の文に出現
B1-ga-ov:	直前の文の述語のガ格として出現 (非省略)
B1-ga-om:	直前の文の述語のガ格として出現 (省略)
B1-wo-ov:	直前の文の述語のヲ格として出現 (非省略)
⋮	⋮
B2:	2 文前に出現
B2-ga-ov:	2 文前の述語のガ格として出現 (非省略)
⋮	⋮
B3:	3 文以上前に出現
⋮	⋮

たとえば、表 3 中の対応付け <格フレーム: 『焼く (2)』, ガ格:私, ヲ格:手, 二格:息子> の場合、二格の先行詞候補の「息子」は解析対象述語と同一文かつ副助詞「は」をともなって出現しており、また、「息子」の係り先である「好き」が解析対象述語「焼いている」に係っているため、二格に対する表 4 中の Itopic や IGC-self などの素性の値が 1 となる。これらの出現格・位置のカテゴリは主に Web テキスト中のゼロ照応を高精度に解析することを目的に設定した。

先行詞の顕現性

談話要素の顕現性は照応関係を解くうえで有力な手がかりとなりうる<sup>10),11)</sup> ことから顕現性に関する素性を導入する。具体的には、以下のルールで談話要素の顕現性を近似的に計算し、先行詞候補の顕現性が 1 以上である場合、この素性を 1、そうでない場合 0 とする。

- +2.0: 文末、または、副助詞「は」をともなって出現

- +1.0: 読点, または, 格助詞「が」「を」をともなって出現
- ×0.5: 文区切りを通過

対象の格が対応付けられたかどうか

対象の格がゼロ代名詞として先行詞と対応付けられた場合に 1, それ以外の場合に 0 とする. この素性に対する重みが大きければ大きいほど, 対応する格が先行詞と対応付けられやすくなる. したがって, この素性に対する重みは各格がどのくらい埋まりやすいかを調整するパラメータと見なせる. 本稿ではゼロ照応解析の評価を主に F 値を用いて行うが, 4.3 節で説明したパラメータ推定法は F 値を最大化するようなパラメータを推定するわけではない. そこで, 4.3 節で説明したパラメータ推定を行った後, 訓練データ, または, 開発データに対して F 値が最大となるように, この素性に対する重みパラメータを再調整する.

## 6. 実験

### 6.1 使用するデータと実験設定

照応タグ付きデータとして, 主に Web テキスト 186 記事に京都テキスト<sup>23)</sup>と同様の基準で照応関係タグを付与したデータ(以下では Web コーパスと呼ぶ)を使用する. 実験は 6 分割交差検定により行う. Web テキストを対象とした実験に加え, 先行研究<sup>5),18)</sup>との比較のため NAIST テキストコーパス 1.4 $\beta$ <sup>4)</sup>を用いた実験も行う. Taira ら<sup>18)</sup>と同様に 1 月 1 日から 11 日までの記事と 1 月から 8 月までの社説記事を訓練データに, 1 月 12 日, 13 日の記事および 9 月の社説記事をパラメータ再調整用データとして使用し, 1 月 14 日から 17 日および 10 月から 12 月の社説記事を評価用データとして利用する. ただし, 提案モデルでは受け身, および, 使役の場合であっても表層格の解析を行うのに対し, NAIST テキストコーパスでは原形に戻した場合の格が付与されていることから, NAIST テキストコーパスを用いた実験を行う際は, 受け身, および, 使役形である述語は評価から除く.

述語項構造解析以外の解析結果が原因となる解析誤りを除くため, 形態素情報, 固有表現情報, 係り受け情報, 共参照関係はコーパスに付与された正しい情報・関係を使用する. いずれの実験においても, 10 個の初期パラメータを用いてパラメータ推定を行い, その中で事後確率が最大となったパラメータを使用した. ただし, 異なる初期値を用いた場合であっても, ほぼ同じ値に収束したことから, 初期パラメータの値はほとんど結果に影響しないと考えられる.

ベースラインとして, Sasano らの手法<sup>15)</sup>を用いた実験, および, 各用言の格フレームを 1 つにまとめた格フレームを用いた実験を行った. 以下, 用言ごとに 1 つにまとめた格

表 5 Web コーパスに対するゼロ照応解析実験の結果  
Table 5 Experimental results on the Web corpus.

	再現率	適合率	F 値
Sasano らの手法 <sup>15)</sup>	0.341 (233/683)	0.306 (233/762)	0.322
提案手法 (マージ格フレーム使用)	0.334 (228/683)	<b>0.412</b> (228/553)	0.369
提案手法 (通常の格フレーム使用)	<b>0.379</b> (259/683)	0.403 (259/642)	<b>0.391</b>

フレームをマージ格フレームと呼ぶことにする. 表 1 に示した「焼く」の格フレームを例に考えると, 用法ごとに構築された通常の格フレームを用いた場合, ヲ格が「手」となる場合, 二格は「加減」や「子供」となることが多いという情報が得られるが, マージ格フレームを用いた場合は二格の全用例で頻度が大きいのは「CD」や「DVD」であることから, 二格は「CD」や「DVD」となることが多いと判断される. すなわち, マージ格フレームを用いた場合は, 複数の項を考慮したモデルではなく, 単純に各用例の頻度のみを考慮したモデルとなっており, このモデルとの比較を行うことで, 用言の用法ごとに構築された格フレームの有効性を調べることができると考えられる.

### 6.2 Web コーパスを用いた実験

Web コーパスを用いた実験の結果を表 5 に示す. 表 5 の結果から提案手法は Sasano らの手法より高い精度を実現していること<sup>\*1</sup>が分かる. また, 用例ごとに構築された格フレームを用いた実験の方がマージ格フレームを用いた場合より高い精度を実現していることから, 用法ごとに構築された格フレームの有効性が確認できる.

続いて, 表 6 に格の種類ごと, また, 先行詞が同一文中に出現した場合(文内ゼロ照応)と先行文中に出現した場合(文間ゼロ照応)に分けた精度を示す. ガ格の解析精度が最も高く, 次がヲ格, 最も解析精度が低いのが二格であり, 文間より文内ゼロ照応の方が高い精度で解析できていることが分かる.

### 6.3 各素性の有効性

各素性の有効性を確かめるため素性を 1 種類ずつ除いた場合のゼロ照応解析の精度を求めた. 結果を表 7 に示す. 先行詞の出現格と位置に関する素性を使用しなかった場合 (F 値 0.299), および, 用例 PMI を使用しなかった場合 (F 値 0.370) に精度が比較的大きく低下することから, これらの素性の重要性が確認できる. 一方, 意味クラス PMI, カテゴリ

\*1 Sasano ら<sup>15)</sup>らは Web コーパスのうち 20 記事を評価に使用し, 再現率 0.410 (50/122), 適合率 0.373 (50/134), F 値 0.391 を得ているが, 提案手法では同じ 20 記事に対し再現率 0.525 (64/122), 適合率 0.615 (64/104), F 値 0.566 が得られた.

表 6 Web コーパスを用いた実験の結果 (詳細)

Table 6 Experimental results of proposed model on the Web corpus in detail.

格	タイプ	再現率	適合率	F 値
ガ	文内	0.504 (120/238)	0.460 (120/261)	0.481
	文間	0.460 (104/226)	0.387 (104/269)	0.420
ヲ	文内	0.250 (17/68)	0.447 (17/38)	0.321
	文間	0.163 (7/43)	0.194 (7/36)	0.177
ニ	文内	0.105 (6/57)	0.316 (6/19)	0.158
	文間	0.098 (5/51)	0.263 (5/19)	0.143
計		0.379 (259/683)	0.403 (259/642)	0.391

表 7 タイプごとに素性を 1 つずつ除いた場合の精度

Table 7 Performance by removing one feature type at a time.

使用しない素性タイプ	再現率	適合率	F 値
(すべての素性を使用)	0.379 (259/683)	0.403 (259/642)	<b>0.391</b>
格解析スコア	0.411 (281/683)	0.350 (281/804)	0.378
用例 PMI	0.363 (248/683)	0.378 (248/656)	0.370
意味クラス PMI(CL)	0.375 (256/683)	0.401 (256/638)	0.387
カテゴリ PMI(CT)	0.367 (251/683)	0.423 (251/593)	<b>0.393</b>
固有表現 PMI(NE)	0.381 (260/683)	0.389 (260/668)	0.385
汎化用例 PMI(CL+CT+NE)	0.350 (239/683)	0.413 (239/579)	0.379
用例 PMI+汎化用例 PMI	0.325 (222/683)	0.391 (222/567)	0.355
先行詞の出現格と位置	0.264 (180/683)	0.346 (180/520)	0.299
顕現性	0.376 (257/683)	0.411 (257/626)	<b>0.393</b>
出現格・位置+顕現性	0.250 (171/683)	0.312 (171/545)	0.279
対象格の埋まりやすさ	0.365 (249/683)	0.404 (249/617)	0.383

\* F 値が 0.390 以上の場合は太字で, 0.380 未満の場合は斜体で表記している.

PMI, 固有表現 PMI の 3 つの汎化用例 PMI は, それぞれ除いても精度にあまり影響せず, 単独での効果は確認できなかった. しかしながら, これらの汎化用例 PMI をすべて使用しなかった場合 (F 値 0.379) は精度の低下が確認できることから, これらの汎化用例は一定の効果があるといえ, 重複する素性を導入することは有用であると考えられる.

構文的・談話的選好を反映する素性に注目すると, 顕現性素性はその効果が確認できない. 出現格・位置に関する素性を使用しなかった場合は, 顕現性を使用しなかった場合 (F 値 0.279) より, 使用した場合 (F 値 0.299) の方が高い精度が得られていることから, 顕現性素性によってとらえられる選好は, 出現格・位置に関する素性に含まれている可能性が考えられる.

表 8 各素性に対して学習された重み

Table 8 Weight of each feature.

素性	学習された重み		
	ガ	ヲ	ニ
対象格の埋まりやすさ	0.292	<b>0.531</b>	<b>0.723</b>
用例 PMI	0.154	<b>0.299</b>	0.211
意味クラス PMI	0.005	<b>0.347</b>	0.058
カテゴリ PMI	<b>0.844</b>	<b>0.617</b>	0.391
固有表現 PMI	<b>0.563</b>	-0.119	-0.444

\* 太字は同一行の平均値より大きいことを表す.

表 8 に対象格の埋まりやすさ, および, 用例 PMI, 汎化用例 PMI の各素性に対して学習された重みを示す. 各素性のタイプごとに一般的にとりうる値の大きさが異なるため, 異なるタイプの素性間の重みの大小にはあまり意味がないと考えられるが, ガ格, ヲ格, ニ格に対する重みを比較することで, 格ごとの傾向を知ることができる. まず, 対象格の埋まりやすさに関する素性の重みを見るとガ格が相対的に小さくなっていることが分かる. これは, ヲ格やニ格の場合, その格が埋まりやすい用言と埋まりにくい用言が存在し, そのような語彙的情報がゼロ照応解析においても重要な手がかりとなるのに対し, ガ格が埋まるかどうかはどのような用言であるかといった語彙的情報よりも先行詞の出現位置などの影響が強いという傾向を表していると考えられる.

用例 PMI・汎化用例 PMI に関する素性の重みに注目すると, ガ格はカテゴリ PMI や固有表現 PMI など粒度の大きい語彙素性に対する重みが相対的に大きくなっているのに対し, ヲ格は意味クラス PMI や用例 PMI に対する重みが相対的に大きくなっている. このことは, ガ格に関する語彙的選好の粒度は, ヲ格に比べて大きい, すなわち, “人” であるか “組織” であるかなどといった大きな意味クラスに関する情報が重要であるという性質を表していると考えられる.

#### 6.4 NAIST テキストコーパスを用いた実験と考察

NAIST テキストコーパスを用いた実験の結果を Taira ら<sup>18)</sup>, Imamura ら<sup>5)</sup> が報告している精度とともに表 9 に示す. 実験設定に違いがあることから単純な比較はできないものの, 提案手法はガ格, ヲ格, ニ格の文内, 文間いずれのタイプに対しても 1 番目か 2 番目に高い F 値を実現しており, 新聞記事を対象とした実験においても提案手法はこれらの先行研究と同程度の精度を達成しているといえる.

同じく NAIST テキストコーパスを用いて実験を行った Iida ら<sup>3)</sup> は, これらの精度より



表 9 NAIST テキストコーパスを用いた実験  
Table 9 Experimental results on the NAIST Text Corpus.

格	タイプ	平ら <sup>18)</sup>	今村ら <sup>5)</sup>			提案手法		
		F 値	再現率	適合率	F 値	再現率	適合率	F 値
ガ	文内	0.302	0.434	0.588	<b>0.500</b>	0.400	0.390	0.395
	文間	0.235	0.076	0.475	0.131	0.221	0.273	<b>0.244</b>
ラ	文内	0.114	0.216	0.537	<b>0.308</b>	0.169	0.181	0.175
	文間	<b>0.093</b>	0.004	0.250	0.007	0.050	0.101	0.066
ニ	文内	0.037	0.000	0.000	0.000	0.088	0.081	<b>0.089</b>
	文間	<b>0.118</b>	0.000	0.000	0.000	0.030	0.023	0.026

\* 太字と斜体はそれぞれ各行において最大・最小の F 値であることを示す。

高い精度を報告している\*<sup>1</sup>。ただし、飯田らの実験では比較的解析の難しい社説記事は対象となっておらず、また、複数のアノテータのタグ付けが一致した箇所のみを評価対象としていることから、本稿での実験より簡単な問題設定となっていると考えられる。しかしながら、新聞記事テキストの解析する際は、Iida らが導入した統語的パターンのような粒度の細かい構文に関する情報が有効であった可能性があり、提案手法においても統語パターンを導入することで新聞コーパスに対する解析精度が向上する可能性が考えられる。

## 7. おわりに

本稿では、比較的小規模の照応関係タグ付きコーパスから獲得した構文的な手がかり、および、大規模なタグなしコーパスから獲得した語彙的手がかりを素性として用いた対数線形モデルに基づく日本語ゼロ照応解析モデルを提案した。また、素性ごとの重みや、各素性を使用しなかった場合の解析精度の変化を調べることで、格ごとに有効となる素性の傾向を明らかにした。

Web コーパスを対象とした実験では 0.4 程度の F 値が得られ、また、NAIST テキストコーパスを用いた実験においても先行研究と同程度の精度を実現できることを示した。ただし、これらの精度は他のアプリケーションの前処理などに使うことを考えると十分に高い精度であるとはいえない難しい事実である。しかし、信頼度の高い解析結果のみを使用することで、現在の解析精度でも有用な情報となりうると考えられる。信頼度の高い解析結果の一

\*<sup>1</sup> NAIST テキストコーパスを対象とした場合、提案モデルによりガ格全体で再現率 0.327、適合率 0.349 が得られた。これに対し Iida らは解析精度を再現率・適合率グラフにより示しているため具体的な数値は報告していないものの、ガ格を対象とした実験において、再現率 0.327 に対して 0.65 程度の適合率を報告している。

表 10 先行詞が“人”であるガ格文内ゼロ照応に限定した場合の精度

Table 10 The performance of proposed model for intra-sentential and nominative zero anaphora resolution whose zero pronoun refers to *person*.

コーパス	再現率	適合率	F 値
Web コーパス	0.648 (70/108)	0.614 (70/114)	0.631
NAIST テキストコーパス	0.538 (519/964)	0.522 (519/994)	0.530

例として、先行詞が“人”であるようなガ格文内ゼロ照応に限定した場合の精度を表 10 に示す。

今後の課題としては、述語対の項共有情報や、述語間の解析結果の整合性など、現在考慮していない素性をモデルに取り込むことでさらなる精度の向上を目指すこと、原形と受身・使役の格フレームの対応を考慮することにより原形述語項構造を出力できるようにすることなどが考えられる。

## 参 考 文 献

- 1) Ferrandez, A. and Peral, J.: A computational approach to zero-pronouns in Spanish, *Proc. ACL'00*, pp.166–172 (2000).
- 2) Haghighi, A. and Klein, D.: Coreference Resolution in a Modular, Entity-Centered Model, *Proc. NAACL-HLT'10*, pp.385–393 (2010).
- 3) Iida, R., Inui, K. and Matsumoto, Y.: Zero-Anaphora Resolution by Learning Rich Syntactic Pattern Features, *ACM Trans. Asian Language Information Processing (TALIP)*, Vol.6, p.Article 12 (2007).
- 4) Iida, R., Komachi, M., Inui, K. and Matsumoto, Y.: Annotating a Japanese Text Corpus with Predicate-Argument and Coreference Relations, *Proc. ACL'07 Workshop: Linguistic Annotation Workshop*, pp.132–139 (2007).
- 5) Imamura, K., Saito, K. and Izumi, T.: Discriminative Approach to Predicate-Argument Structure Analysis with Zero-Anaphora Resolution, *Proc. ACL-IJCNLP'09*, pp.85–88 (2009).
- 6) IREX 実行委員会 (編): IREX ワークショップ予稿集 (1999).
- 7) Kawahara, D. and Kurohashi, S.: Zero Pronoun Resolution based on Automatically Constructed Case Frames and Structural Preference of Antecedents, *Proc. IJCNLP'04*, pp.334–341 (2004).
- 8) Kazama, J. and Torisawa, K.: Inducing Gazetteers for Named Entity Recognition by Large-Scale Clustering of Dependency Relations, *Proc. ACL-HLT'08*, pp.407–415 (2008).
- 9) Kong, F. and Zhou, G.: A Tree Kernel-Based Unified Framework for Chinese Zero

- Anaphora Resolution, *Proc. EMNLP-2010*, pp.882–891 (2010).
- 10) Lappin, S. and Leass, H.J.: An Algorithm for Pronominal Anaphora Resolution, *Computational Linguistics*, Vol.20, No.4, pp.535–562 (1994).
  - 11) Mitkov, R., Evans, R. and Orăsan, C.: A new, fully automatic version of Mitkov's knowledge-poor pronoun resolution method, *Proc. CICLing'02* (2002).
  - 12) Ng, V. and Cardie, C.: Improving Machine Learning Approaches to Coreference Resolution, *Proc. ACL'02*, pp.104–111 (2002).
  - 13) Nocedal, J.: Updating Quasi-Newton Matrices with Limited Storage, *Mathematics of Computation*, Vol.35, No.151, pp.773–782 (1980).
  - 14) Richardson, M. and Domingos, P.: Markov Logic Networks, *Machine Learning*, Vol.62, pp.107–136 (2006).
  - 15) Sasano, R., Kawahara, D. and Kurohashi, S.: A Fully-Lexicalized Probabilistic Model for Japanese Zero Anaphora Resolution, *Proc. COLING'08*, pp.769–776 (2008).
  - 16) Sasano, R., Kawahara, D. and Kurohashi, S.: The Effect of Corpus Size on Case Frame Acquisition for Discourse Analysis, *Proc. NAACL-HLT'09*, pp.521–529 (2009).
  - 17) Seki, K., Fujii, A. and Ishikawa, T.: A Probabilistic Method for Analyzing Japanese Anaphora Integrating Zero Pronoun Detection and Resolution, *Proc. COLING'02*, pp.911–917 (2002).
  - 18) Taira, H., Fujita, S. and Nagata, M.: A Japanese Predicate Argument Structure Analysis using Decision Lists, *Proc. EMNLP'08*, pp.523–532 (2008).
  - 19) Zhao, S. and Ng, H.T.: Identification and Resolution of Chinese Zero Pronouns: A Machine Learning Approach, *Proc. EMNLP-CoNLL'07*, pp.541–550 (2007).
  - 20) 吉川克正, 浅原正幸, 松本裕治: Markov Logic による日本語述語項構造解析, 情報処理学会自然言語処理研究会 2010-NL-199, pp.1–7 (2010).
  - 21) 河原大輔, 黒橋禎夫: 格フレーム辞書の漸次的自動構築, 自然言語処理, Vol.12, No.2,

pp.109–131 (2005).

- 22) 河原大輔, 黒橋禎夫: 自動構築した大規模格フレームに基づく構文・格解析の統合的  
確率モデル, 自然言語処理, Vol.14, No.4, pp.67–81 (2007).
- 23) 河原大輔, 黒橋禎夫, 橋田浩一: 「関係」タグ付きコーパスの作成, 言語処理学会第8  
回年次大会発表論文集, pp.495–498 (2002).
- 24) 黒橋禎夫, 河原大輔: 日本語形態素解析システム JUMAN version 6.0 使用説明書,  
京都大学大学院情報学研究科 (2009).

(平成 23 年 4 月 11 日受付)

(平成 23 年 9 月 12 日採録)



笹野 遼平

1981 年生。2009 年東京大学大学院情報理工学系研究科博士課程修了。  
博士(情報理工学)。2010 年 12 月より東京工業大学精密工学研究所助教。  
省略解析, 照応解析の研究に従事。



黒橋 禎夫(正会員)

1966 年生。1994 年京都大学大学院工学系研究科電気工学第二専攻博士  
課程修了。博士(工学)。2006 年 4 月より京都大学大学院情報学研究科教  
授。自然言語処理, 知識情報処理の研究に従事。