

## Markov Logic による日本語述語項構造解析

吉川 克正<sup>†1</sup> 浅原 正幸<sup>†1</sup> 松本 裕治<sup>†1</sup>

日本語の述語項構造解析は、文章内にある述語に対して、主格、目的格などの格情報を同定し、局所的な文書構造を捉えるタスクである。多くの先行研究では格の種類毎に個別の分類器を用意し、独立して解析を行う手法が行われてきた。しかしながら、ある述語が複数の項を持つ場合その項の間には依存関係がある。さらには他の述語との関係も項を同定する上で大きな手がかりになると考えられる。本研究ではこのような述語と項を持つ複雑な依存関係を考慮した解析を行うため、Markov Logic という統計的関係学習の枠組みを導入し、従来手法との比較を行う。

### Japanese Predicate Argument Structure Analysis with Markov Logic

KATSUMASA YOSHIKAWA,<sup>†1</sup> MASAYUKI ASAHARA<sup>†1</sup>  
and YUJI MATSUMOTO<sup>†1</sup>

Japanese predicate argument structure analysis is the task that we attach arguments (cases) to predicates which we see in a document and find important local information for understanding the document. Most previous work built multiple classifiers for each case types and identified the arguments neglecting dependencies between the cases. However, arguments which belongs to a predicate are dependent each other. The relatedness with the other predicates can also provide classifiers useful information. Therefore, we propose a method which collectively analyzes predicate argument structure in a sentence with Markov Logic and compares it with previous work.

#### 1 はじめに

本研究で扱う述語項構造解析は、ある述語に対する項を同定し、その格情報を解析するタ

クである。述語とそれに対する格情報の組み合わせは、局所的ではあるものの、「誰が、何を、何に対して、どうした」という意味的な情報を与えることができる。そのため述語項構造解析は、形態素解析や構文解析などの統語論的解析と、文書要約や質問応答などの高度な意味解析をつなぐ技術と位置づけられている。

述語とその項のタグ付与については表層格から深層格レベルまで、近年様々なタグ付与の基準が議論され、それに基づくコーパスが構築されている。日本語述語項構造解析では、京都テキストコーパス<sup>20)</sup> 及び、NAIST テキストコーパス<sup>21)</sup> が研究対象として多く利用されている。英語では PropBank<sup>10)</sup> など、深層格レベルで項を捉えて意味役割 (Semantic Role) を付与したコーパスが構築されており、CoNLL Shared Task<sup>\*1</sup> などを通して多くの研究がなされている。

本研究では Markov Logic<sup>13)</sup> を日本語述語項構造解析に適用し、その集成的な解析手法の性能を評価する。これまでの日本語述語項構造解析では SVM のような分類学習器を利用して格ごとに独立して同定を行う手法が主に研究されてきた<sup>6),18)</sup>。しかしながら、現実の文書では同じ述語に属する項の間には依存関係があると考えられる。例えば、次の文 (1) を考えてみよう。

(1) ライオン<sub>i</sub> がシマウマ<sub>j</sub> を 食べた<sub>ガ:i, ヲ:j</sub>

この例文の“食べた”という述語に対し、ガ格とヲ格がともに“ライオン”になることは考えにくい。ガ格とヲ格を個別に扱う分類器で解析を行った場合、このような矛盾した結果を生んでしまうことがありうる。

さらには、ある述語とその項の関係を同定する際に、文内にある他の述語との関係が同定の手がかりになることがある。次の例文 (2) を見てみよう。

(2) ライオン<sub>i</sub> に 追いかけられた<sub>ガ:j, ニ:i</sub> シマウマ<sub>j</sub> が崖から 落ちた<sub>ガ:j</sub>

この例文 (2) において“ライオン”が項として同定され、述語“落ちた”の格は“シマウマ”だけであったと仮定すると、“ライオン”はもう一つの述語“追いかけられた”の格になることが保証される。

これらの例のように複雑な依存関係を捉えるのは従来研究のような独立した分類器による手法では難しい。一方、本研究で導入する Markov Logic は統計的関係学習の枠組みの一つで、確率付きの大域的な論理式により、容易に複雑な依存関係を記述することができる。これによって同一文内に存在する述語と項の候補、即ち文内のトークン全てを同時に考慮しながら集的に解析を行うのが本研究の手法である。本研究では NAIST テキストコーパスを対象に述語項構造解析を行い、大域的な論理式の効果を検証するとともに、他の研究との性能の違いも評価

<sup>†1</sup> 奈良先端科学技術大学院大学 情報科学研究科

Nara Institute of Science and Technology, Graduate School of Information Science

\*1 <http://www.lsi.upc.edu/~srlconll/>

する。

## 2 関連研究

本研究で利用する NAIST テキストコーパス<sup>21)</sup> は京都テキストコーパス<sup>20)</sup> を元にしており、毎日新聞 38384 文に対し、共参照情報及びガ格、ヲ格、ニ格の 3 種類の格に関して述語項構造のタグが付与されている。この NAIST テキストコーパスを対象にした主な研究は照応解析<sup>5)</sup> と述語項構造解析だが、本研究の対象となる述語項構造解析では、まず平ら<sup>18)</sup> が SVM を利用して格毎に独立した分類器を構築し、決定リストを組み合わせて適切な項を選ぶ手法を提案した。平らは動詞だけでなく、事態性名詞についても解析を行っている。次に今村ら<sup>6)</sup> は最大エントロピーモデルと新聞記事 12 年分から構築した言語モデルを組み合わせることで、主に文内ゼロ照応関係にある述語項構造の同定において高い性能改善を実現した。しかしながら、ゼロ照応の場合の述語項関係は未だ文内文間ともに性能が低く、改善の余地があることが報告されている。平らの手法と今村らの手法はどちらも、格ごとに別々のモデルを用意して解析を行うもので、模式的に表すと図 1 のようになる。




図 1: 格個別モデル [平ら,2008][今村ら,2009]

これはガ、ヲ、ニ格を同時に考慮して最適な各要素の割り当てを選択する本研究の手法とは対照的である (図 2)。

CoNLL Shared Task 2009 では多言語の意味役割割付 (Semantic Dependency Parsing) のワークショップが行われ、日本語の意味役割割付もタスク対象となった。その中で本研究と同様の Markov Logic を用いた集成的解析手法を、Meza-Ruiz ら<sup>8)</sup> により提案されている。その後、彼らは同様のデータを用いた Markov Logic による英語意味役割割付について詳細な報告しており<sup>7)</sup>、その手法は述語同定、述語語義曖昧性解消、項同定、意味役割割付との 4 つを同時に行うことで性能の向上を実現している。しかし、NAIST テキストコーパスのような格フレーム

辞書を持たないデータに対してこの手法を適用した際の振る舞いについては詳細な報告がまだない。尚、CoNLL Shared Task 2009 では、文境界を越えるような述語項関係は解析対象から省かれている。

## 3 Markov Logic

述語項構造解析を含めて、我々が現実遭遇する問題の多くが、局所的な分類学習だけで挑んでも十分な解決を望めないことは古くから認識されてきた。局所的な分類学習に対して、統計的な変量の間にある全体的 (大域的) な相互関係の協調しながら学習する統計的關係学習 (Statistical Relational Learning) がある<sup>9)</sup>。

全体最適化を可能にする学習と推論のための統計的關係学習の枠組みとして、Markov Logic が近年急速に広まりつつある<sup>13)</sup>。これは一階述語論理と Markov Networks を組み合わせたもので、一階述語論理式に、ある程度の罰則をもって矛盾を許容する枠組みであると考えられる。また、それは Markov Networks を一階述語論理式によって表現するテンプレート言語であるとの解釈もできる。自然言語処理の分野においても、実体解析<sup>17)</sup>、情報抽出<sup>11)</sup>、共参照解析<sup>12)</sup> など、大域的な制約の利用が重要な分野において利用されてきている。

我々がこの Markov Logic を日本語述語項構造解析に適した枠組みであると考えられる理由は 3 つある。1 つ目は、二律背反の絶対的な制約をモデル化する *hard* と実数値で選好性が与えられる制約 *soft* の 2 種類の全体制約を利用できること、2 つ目は、識別学習を利用できること、3 つ目は、フリーで利用できるライブラリがあることである。

以下では Markov Logic について、例を使って説明する。まず、推定すべき問題に必要な述語 (predicate) を定義する。ここでは説明の簡略化のために、2 種類の推定だけを行うことを想定する。1 つ目はトークン  $a$  が何かの述語の項であるかどうかの推定、2 つ目はある述語のトークン  $p$  がトークン  $a$  を項として持つかどうかの推定である。前者を表現する述語として  $\text{isArg}(a)$  を、後者を表現する述語には  $\text{hasRole}(p, a)$  を定義する。この 2 つの述語は、推定を行う際にはその情報が与えられない引数を含むことから、潜在述語 (hidden predicate) として定義される。それに対するものとして、学習と推定の両方においてその情報が与えられる引数のみを含む、観測述語 (observed predicate) を定義する。ここでは、観測述語  $\text{word}(i, x)$  を定義し、これはトークン  $i$  が表層形  $w$  を持った単語であることを表す。

これらの述語を利用して、重み付きの一階述語論理式を構築する。例えば、次のような式を作ることができる。

$$\text{word}(a, \text{"首相"}) \Rightarrow \text{isArg}(a) \quad (1)$$

この式はトークン  $a$  が“首相”という単語表層形を持っている時、何らかの述語の項になるという素性を表現していることになる。これは真になる可能性が高いが、自然言語表現の曖昧性を鑑みれば、絶対とは言い難い。この式に残されている“不確かさ”は、式に対応した重み  $w$  によって表現される。一般に、大きな重みを持つ論理式ほど、そのモデルにおいてより高い確率で成立すると言える。しかしながら、この重みをルールベースのシステムのように、手動で設定する必要はなく、コーパスからの学習によって自動的に獲得される。式 (1) で表現されているのと同等の意味合いは局所的な分類学習器を利用しても学習することが可能である。しかし、Markov Logic は次のような表現も可能である。

$$\text{isArg}(a) \Rightarrow \exists p.\text{hasRole}(p, a) \quad (2)$$

この式はトークン  $a$  が項となる時、少なくとも一つの述語と結びついていることを表しており、局所的な分類学習器では捉えることができない種類の大域的な意味合いを持っている。このような大域的素性の利用は、我々の提案する全体最適化手法における骨子となる概念である。その詳細については次章で示す。

Markov Logic では、重み付きの論理式の集合を *Markov Logic Networks*(MLNs) と呼ぶ。1 つの MLN  $M$  は、 $(\phi, w)$  の組の集合であり、 $\phi$  が一階述語論理式、 $w$  が実数値の重みとなる。 $M$  は可能世界 (*possible worlds*) における確率分布を定義する。各可能世界とは、定義された述語に対する基底述語 (*ground atom*) の集合である。 $M$  に対応する確率分布は次の形で表現される。

$$p(\mathbf{y}) = \frac{1}{Z} \exp \left( \sum_{(\phi, w) \in M} w \sum_{c \in C^\phi} f_c^\phi(\mathbf{y}) \right) \quad (3)$$

ここで定義されている  $f_c^\phi$  はバイナリの素性関数であり、可能世界  $\mathbf{y}$  において、 $\phi$  が持つ変数を、 $c$  の中の定数で置き換えてできる基底論理式 (*ground formula*) が真になる場合に 1、そうでない場合には 0 となる。 $C^\phi$  は定数のタプルの集合であり、それによって  $\phi$  の中の変数は全て置き換えることができる。また、 $Z$  は正規化定数である。この確率分布は、1 つの Markov Network (*Ground Markov Network*) に対応しており、その中のノードが示すのは基底述語、要素が示すのは基底論理式である。

従来の機械学習器に対する素性設計と同様に、Markov Logic Networks のための論理式は人手で設計する必要がある。それとは別に、実用に際しては、学習の戦略と、尤もらしい基底述語を見つけ出す、推論手法を選ぶ必要がある。しかし、これらの実装については、*Alchemy*<sup>\*1</sup> や

*Markov thebeast*<sup>\*2</sup> のような既存のツールを利用することができる。本研究では Markov Logic の実装として *Markov thebeast* を利用しており、学習・推論には以下のような選択を行った。

まず、Markov Networks における重みの識別学習には条件付確率尤度の計算が必要だが、一般に直接の計算はコストが高いため、パーセプトロンをはじめとするオンライン学習を利用した重みの推定が実用的である<sup>2)</sup>。本研究では同様にオンラインのマージン最大化学習アルゴリズムである MIRA<sup>3)</sup> を利用する。

次に、Markov Networks における推論は最大事後確率 (MAP) 推定問題となるが、この MAP 推定を正確かつ効率的に行うために、Cutting Plane Inference (CPI)<sup>15)</sup> を利用する。CPI はまず、*base solver* を用意しておき、考慮すべき Ground Markov Networks における一部の論理式の集合に対して、その *base solver* を適用して MAP 推定問題を解く。その上で、まだ考慮していない論理式のうち、考慮すべき論理式を選択的に追加しながら MAP 推定を繰り返すことで、効率よく全体の Ground Markov Networks の最適解を得る推論アルゴリズムである。また、*base solver* が正確なものであれば、CPI の得る解も正確であることが保証されているため、本研究では整数線形計画法 (ILP) を利用する。MAP 推定問題に ILP を利用する研究はいくつかあるが<sup>1), 14), 16)</sup>、本研究でもこれらの先行研究と同様に MAP 推定問題を ILP 問題へと変換することで、人手では書き尽くすことが困難な ILP の制約を自動的に作成する手法を選択している。この点で、本研究の Markov Logic による手法は、ILP ベースの手法に対する自然な拡張と捉えることができる。

また、オンライン学習でも各イテレーションでの最適解を計算するために MAP 推定を行う必要があり、この MAP 推定にも CPI を利用することで効率よい学習を行えるようになる。なお、学習と推論に関して本研究が採用する設定は Meza-Ruiz らによる英語意味役割付与に関する研究<sup>7)</sup> と同様である。

#### 4 日本語述語項構造解析のための Markov Logic モデル

本節では本研究の集成的な述語項構造解析モデルについて、提案する Markov Logic Network を中心に詳細な説明を行う。まず推定すべき対象に合わせて潜在述語の定義を行うことから始めよう。一般に述語項構造解析で解決が求められる部分問題は述語同定、述語語義曖昧性解消、項同定、意味役割付与の 4 つだが、本研究の実験では述語同定を行わず NAIST テキストコーパスのアノテーションを利用する。これは平らの研究<sup>18)</sup> に従った実験設定である。また NAIST テキストコーパスは格フレーム辞書を持たないため、述語語義曖昧性解消についても

\*1 <http://alchemy.cs.washington.edu/>

\*2 <http://code.google.com/p/thebeast/>

明示的に行うことはできない。ゆえに、本研究で対象とする問題は項同定及び意味役割付与となり、日本語の述語項構造解析では意味役割付与の代わりとして格分類を行うことになる。以上のことから我々が定義した潜在述語は次の表 1 の 3 つである。

表 1: 潜在述語 (hidden predicate)

述語	定義
$isArg(i)$	トークン $i$ は項である
$hasRole(i, j)$	トークン $i$ はトークン $j$ を項に持つ
$role(i, j, r)$	トークン $i$ はトークン $j$ を項に持ち、その意味役割は $r$ である

本研究の提案する Markov Logic Network (以下 MLN) は Meza-Ruiz らの定義する MLN<sup>7)</sup> を元にして構築しているが、彼らが 5 つの潜在述語を定義したのに対し、我々は 3 つだけを定義している。これは述語同定と述語語義曖昧性解消を行わないためである。尚、本研究で  $hasRole$  と  $role$  を分けたのはラベルなし述語項同定の性能と、そのラベルあり述語項同定の性能を分けて評価するためで、基本的に両者が推定に利用する素性には違いがない\*1。以下ではこの 3 つの潜在述語を推定するための素性を局所論理式 (*local formula*) と大域論理式 (*global formula*) に分けて説明する。

#### 4.1 局所論理式 (Local Formula)

Markov Logic の定義では、ただ一つの潜在述語を持つ論理式を局所論理式 (*local formula*) と呼び、局所的素性を表現するのに用いられる。局所論理式で表現する素性は Meza-Ruiz らの研究を参考にして、統語的な素性を中心に利用する。また意味的な素性として、平らの研究<sup>18)</sup> や飯田らの研究<sup>4)</sup> を参考に、日本語語彙大系の選択制限を利用する。これらの素性を与えるための観測述語を表 2 に列挙した。

ここで定義された観測述語はただ一つの潜在述語とともに 3 節の式 (1) や、次の式 (4) のように複数の観測述語を組み合わせる形式で利用される。

$$ne(a, n) \wedge isPred(p) \wedge path(p, a, l) \Rightarrow role(p, a, r) \quad (4)$$

一階述語論理で記述されたこの式 4 は素性のテンプレートであるから、変数には具体的な値が割り当てられ、個々の素性として展開 (ground) される。例えば次の式 5 は式 4 から展開された基底論理式 (*ground formula*) である。

\*1 ここでいう素性とは局所的素性のことであり、大域的な素性については格分類に特有の素性が存在する。

表 2: 局所論理式のための観測述語

述語	説明	例
$word(i, w)$	表層形	表明した, 民主党
$stem(i, s)$	主辞基本形	表明する
$pos(i, p)$	品詞 coarse-grained	名詞
$dpos(i, d)$	品詞 fine-grained	固有名詞
$ne(i, n)$	固有表現タグ	PERSON, LOCATION
$kana(i, k)$	仮名表層形	ミンシュトウ
$isPred(i)$	トークン $i$ は述語である	BINARY
$numeric(i)$	数字を持っている	BINARY
$definite(i)$	ソ系の代名詞である (“それ”, “その”, “そんな” など)	BINARY
$demonstrative(i)$	コ系もしくはア系の代名詞である (“これ”, “あれ” など)	BINARY
$particle(i)$	“は”, “が”, “を”, “に” 名詞句に続く助詞を	BINARY
$goiCate(i, g)$	日本語語彙大系における語彙カテゴリーラベル	BINARY
$goiMatch(i, j)$	日本語語彙大系の選択制限を満たしている	BINARY
$dep(i, j, d)$	係り受けラベル (基本的に D)	D or None
$path(i, j, l)$	依存構造木上での最短パス	↑↓

$$ne(2, PERSON) \wedge isPred(6) \wedge path(6, 2, “\uparrow\uparrow”) \Rightarrow role(6, 2, ガ) \quad (5)$$

これは即ち、固有表現タグが PERSON になるトークン 2 が、述語のトークン 6 と依存構造パス “↑↑” を持つとき\*2、トークン 2 は述語のガ格となる、という素性を表現し、この基底論理式に対して学習により重みが付与されることになる。

また述語に対する項の妥当性を与える手がかりとして、大規模データから抽出した選択選好 (共起) のスコアは非常に有効と考えられるが、本研究では利用していない。これは大規模データから構築した言語モデルのスコアを利用している今村らの研究<sup>6)</sup> との大きな差異である。

#### 4.2 大域論理式 (Global Formula)

局所論理式に対し、2 つ以上の潜在述語を含めることで大域的 (global) かつ集合的 (collective) な推定を可能にするのが大域論理式 (*global formula*) である。大域論理式は表 3 にまとめて示した。

この表 3 に示した論理式のうち Hard Constraint は主に潜在述語間の一貫性を保つために定義されており、重みが無限大に設定される論理式であるため、必ず満たさなければならない制約となる。一方 Soft Constraint は解析の性能を向上させるために定義されており、その重みの

\*2 ↑ が係り元から係り先、↓ が係り先から係り元を表現し、この組み合わせにより依存構造木上での最短パスを示す。

表 3: 大域論理式

論理式の種類	論理式
Hard Constraint	$\text{isArg}(a) \Rightarrow \exists p.\text{hasRole}(p, a)$
	$\text{hasRole}(p, a) \Rightarrow \exists r.\text{role}(p, a, r)$
	$\text{hasRole}(p, a) \Rightarrow \text{isArg}(a)$
	$\text{role}(p, a, r) \Rightarrow \text{hasRole}(p, a)$
Soft Constraint	$\text{role}(p, a, r_1) \wedge r_1 \neq r_2 \Rightarrow \neg \text{role}(p, a, r_2)$
	$\text{dep}(p, a, d) \wedge \text{hasRole}(p, a) \Rightarrow \text{role}(p, a, r)$
	$\text{path}(p, a, l) \wedge \text{hasRole}(p, a) \Rightarrow \text{role}(p, a, r)$

割り当ては学習に委ねられている。

本研究では局所論理式だけを利用する局所モデルと、大域論理式も利用する大域モデルの2つで実験を行い、日本語の述語項構造解析においても Markov Logic の大域的制約が有効に働くことを検証する。

## 5 実験と評価

### 5.1 実験設定

実験設定は NAIST テキストコーパスで実験評価を行った平らの研究<sup>18)</sup> の設定を基にしている。まず、本研究の実験で利用したデータ及びツールに関して説明する。データは NAIST テキストコーパス 1.4β を利用しており、社説記事 1月-8月までと記事 1月 1日-11日までを学習用の訓練データに、9月の社説記事及び記事 1月 12日、1月 13日をパラメータチューニング用の開発セットに、社説記事 10月から 12月及び記事 1月 14日-17日を評価用のテストセットとして利用する。

品詞情報及び文節間係り受けについては京都テキストコーパスのアノテーションをそのまま使用する。さらに固有表現タグは CaboCha<sup>\*1</sup> を利用して付与した。学習素性のための外部リソースとして利用するのは 4節で述べた通り、日本語語彙大系のみだけである。

学習と推論に関してはフリーの Markov Logic エンジンである Markov thebeast<sup>\*2</sup> を利用した。Markov thebeast は自然言語処理のために調整されており、学習と推論ともに強力なアルゴリズムを実装したパッケージである。

尚、本研究で解析対象とする述語項は、文内のトークンに限定している。これは Markov thebeast のように効率的な学習及び推論のアルゴリズムをもってしても、大域的、集散的な解

\*1 <http://chasen.org/~taku/software/cabocho/>

\*2 <http://code.google.com/p/thebeast/>

析が計算量の点で困難だからである。ゼロ照応解析を利用することによって、文外の項を同定する手法については??節で述べる。

### 5.2 実験結果

まず文内の述語項構造解析の結果を局所論理式のみを利用した局所モデルと、大域論理式も利用した大域モデルに分けて表 4 に示す。

表 4: 局所モデル vs 大域モデル

	局所モデル			大域モデル		
	P	R	F	P	R	F
isArg	69.0	68.5	68.8	90.9	85.3	88.0 (+19.2)
hasRole	87.4	77.6	82.2	86.6	82.3	84.4 (+2.2)
role	79.5	63.8	70.8	78.1	74.2	76.1 (+5.3)

表 4 に示した結果は Markov Logic の潜在述語 (isArg, hasRole, role) 毎の数値になっており、それぞれ、精度 (P)、再現率 (R)、F 値 (F) を示してある。いずれの潜在述語についても大域モデルが局所モデルを大幅に上回っている。本研究で主な評価対象となる述語項関係 (role) についても、F 値で 5.3 ポイントの大域論理式による性能向上が確認できた。

次の表 5 では述語項関係 (role) のみに着目して、その種類毎の結果を示している。同時に平ら<sup>18)</sup> と今村ら<sup>6)</sup> との比較も行う。

表 5: 述語項関係同定の性能比較 (F 値)

	MLN(大域モデル)			[平ら,2008]			[今村ら,2009]		
	ガ	ヲ	ニ	ガ	ヲ	ニ	ガ	ヲ	ニ
dependency relations	<b>91.4</b>	82.0	66.6	75.6	88.2	<b>89.5</b>	87.0	<b>93.9</b>	80.8
zero-anaphoric (intra-sentential)	<b>68.4</b>	8.0	2.4	30.2	11.4	<b>3.7</b>	50.0	<b>30.8</b>	0.0

表 5 の結果から、本研究で構築した大域モデルはガ格で高い性能を達成し、二格が他の 2 つの先行研究よりも低いことが分かる。これは先行研究がガ、ヲ、ニの 3 つの格それぞれについて、個別のモデルを構築して推定していたのに対し、本研究の手法は、同じ文内にある全ての述語について 3 つの格を同時に推定するモデルであるため、数の多いガ格が多く推定されているのである。その結果、特に問題であった文内ゼロ照応の場合については今村らのモデルと比較して 18.4pt 向上し、ガ格の同定は文内の述語項全体でも 79.1pt という高いパフォーマンス

を示した。

平らの報告によれば、テストセットにおける項の数は、ガ格が 15996、ヲ格 8348、二格 4871 とガ格が半分以上を占めている。ゆえに、ガ格を優先的に同定できる本研究の手法も相対的に有用性が高いものと考えられる。またヲ格、二格については先行研究に比べて再現率の低いことが確認できているため、今村らの手法を参考に、大規模データから抽出した共起のスコアを利用することで選択選好の素性を導入し、日本語語彙大系が網羅する選択制限を補うことで改善できると考えている。

## 6 おわりに

本研究では Markov Logic を利用して集散的に文内の日本語述語項構造解析を行う手法を提案した。日本語の述語項構造解析においても Markov Logic の大域的な制約は効果的に働き、大幅に解析精度を改善した。また平ら<sup>18)</sup> や今村ら<sup>6)</sup> の結果と比較することで、ガ格において高い性能を実現した。

本研究の解析手法は文内の述語項構造解析で高い性能を達成したが、文間ゼロ照応にある述語項関係については全く考慮していない。そこで次なるステップとして、文間ゼロ照応解析を組み合わせ文境界を越えた述語項を同定する手法を考える。参考になるのは医学生物学文書において共参照関係を利用した事象項構造解析を行った吉川らの研究<sup>19)</sup> である。彼らの手法は共参照関係を利用した推移律により文外の項を同定している。日本語ゼロ照応の場合には明示的な照応詞がないため、まずは文外項を持つか否かに関わらず、全ての述語に対して先行詞同定を行う。次にその文外項候補を文内の項候補に付け加える形で述語項構造解析を行い、文内外の項候補の中で最適な項をそれぞれの格に対して選ぶようにする。これは、ゼロ照応解析のうち、照応性の決定を Markov Logic に行わせていることになる(図 3)。尚、文外先行詞同定モデルには飯田らのゼロ照応解析モデル<sup>5)</sup> を参考にした。このゼロ照応解析を組み込んだ述語項構造解析モデルを利用して文間ゼロ照応にある述語項関係を同定することを試みたところ、期待に反して文内の項候補ばかりが選ばれてしまい、殆どの文外項を同定することができなかった。今後の研究では最終的に文書全体の述語・項の最適化を行うことを目標とし、照応解析と述語項構造解析を融合させる方法により精度を向上させたいと考えている。

## 参 考 文 献

1) James Clarke and Mirella Lapata. Modelling compression with discourse constraints. In *Proceedings of the 2007 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning (EMNLP-CoNLL)*, pp. 1–11, Prague, Czech

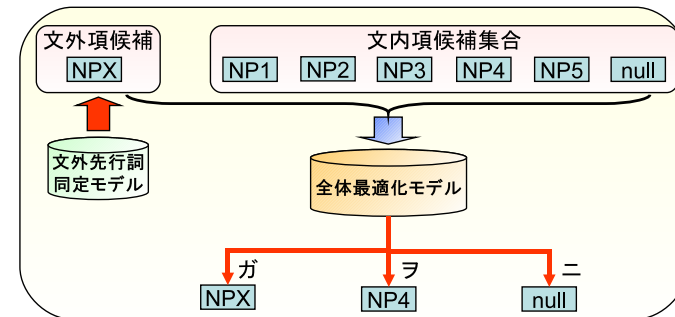


図 3: 文間ゼロ照応解析を利用した述語項構造解析モデル

Republic, June 2007. Association for Computational Linguistics.

2) Michael Collins. Discriminative training methods for hidden markov models: theory and experiments with perceptron algorithms. In *EMNLP '02: Proceedings of the ACL-02 conference on Empirical methods in natural language processing*, pp. 1–8, Morristown, NJ, USA, 2002. Association for Computational Linguistics.

3) Koby Crammer and Yoram Singer. Ultraconservative online algorithms for multiclass problems. *Journal of Machine Learning Research*, Vol.3, pp. 951–991, 2003.

4) Ryu Iida, Kentaro Inui, and Yuji Matsumoto. Zero-anaphora resolution by learning rich syntactic pattern features. *ACM Transactions on Asian Language Information Processing (TALIP)*, Vol.6, No.4, pp. 1–22, 2007.

5) Ryu Iida, Kentaro Inui, and Yuji Matsumoto. Capturing salience with a trainable cache model for zero-anaphora resolution. In *Proceedings of the Joint Conference of the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP*, pp. 647–655, Suntec, Singapore, August 2009. Association for Computational Linguistics.

6) Makoto Imamura, Yasuhiro Takayama, Nobuhiro Kaji, Masashi Toyoda, and Masaru Kitsuregawa. A combination of active learning and semi-supervised learning starting with positive and unlabeled examples for word sense disambiguation: An empirical study on japanese web search query. In *Proceedings of the ACL-IJCNLP 2009 Conference Short Papers*, pp. 61–64, Suntec, Singapore, August 2009. Association for Computational Linguistics.

7) Ivan Meza-Ruiz and Sebastian Riedel. Jointly identifying predicates, arguments and senses using markov logic. In *Proceedings of Human Language Technologies: The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics*, pp. 155–163, Boulder, CO, USA, June 2009. Association for Computational Linguistics.

- 8) Ivan Meza-Ruiz and Sebastian Riedel. Multilingual semantic role labelling with markov logic. In *Proceedings of the Thirteenth Conference on Computational Natural Language Learning (CoNLL 2009): Shared Task*, pp. 85–90, Boulder, Colorado, June 2009. Association for Computational Linguistics.
- 9) Raymond Ng and V.S. Subrahmanian. Probabilistic logic programming. *Inf. Comput.*, Vol. 101, No.2, pp. 150–201, 1992.
- 10) Martha Palmer, Paul Kingsbury, and Daniel Gildea. The proposition bank: An annotated corpus of semantic roles. *Computational Linguistics*, Vol.31, , 2005.
- 11) Hoifung Poon and Pedro Domingos. Joint inference in information extraction. In *Proceedings of the Twenty-Second National Conference on Artificial Intelligence*, pp. 913–918, Vancouver, Canada, 2007. AAAI Press.
- 12) Hoifung Poon and Pedro Domingos. Joint unsupervised coreference resolution with Markov Logic. In *Proceedings of the 2008 Conference on Empirical Methods in Natural Language Processing*, pp. 650–659, Honolulu, Hawaii, October 2008. Association for Computational Linguistics.
- 13) Matthew Richardson and Pedro Domingos. Markov logic networks. *Machine Learning*, Vol.62, No. 1-2, pp. 107–136, 2006.
- 14) S.Riedel and J.Clarke. Incremental integer linear programming for non-projective dependency parsing. In *EMNLP*, pp. 129–137, Sydney, Australia, July 2006. Association for Computational Linguistics.
- 15) Sebastian Riedel. Improving the accuracy and efficiency of map inference for markov logic. In *Proceedings of UAI 2008*, 2008.
- 16) D.Roth and W.Yih. Integer linear programming inference for conditional random fields. In *Proc. of the International Conference on Machine Learning (ICML)*, pp. 737–744, 2005.
- 17) Parag Singla and Pedro Domingos. Entity resolution with markov logic. In *ICDM '06: Proceedings of the Sixth International Conference on Data Mining*, pp. 572–582, Washington, DC, USA, 2006. IEEE Computer Society.
- 18) Hirotoishi Taira, Sanae Fujita, and Masaaki Nagata. A japanese predicate argument structure analysis using decision lists. In *EMNLP '08: Proceedings of the Conference on Empirical Methods in Natural Language Processing*, pp. 523–532, Honolulu, HI, USA, 2008. Association for Computational Linguistics.
- 19) Katsumasa Yoshikawa, Sebastian Riedel, Tsutomu Hirao, Masayuki Asahara, and Yuji Matsumoto. Coreference based event-argument relation extraction on biomedical text. In *Proceedings of the Fourth Symposium on Semantic Mining in Biomedicine (SMBM 2010)*, European Bioinformatics Institute, Hinxton, Cambridgeshire, UK, October 2010.
- 20) 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.
- 21) 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ンノテーション. 情報処理学会自然言語処理研究会予稿集, 第 NL-177-10 巻, pp. 71–78, 2007.
- 22) 飯田龍, 徳永健伸. 述語対の項共有情報を利用した文間ゼロ照応解析. 言語処理学会第 16 回年次大会発表論文集, pp. 804–807, 2010.