

述語語義と意味役割の結合学習のための構造予測モデル

渡邊陽太郎 浅原正幸 松本裕治

奈良先端科学技術大学院大学 情報科学研究科

{yotaro-w, masayu-a, matsu}@is.naist.jp

1 はじめに

述語項構造解析とは、文章中に記述された出来事などの事態を表す述語と、その述語がとる項、およびそれらの持つ意味役割を同定するタスクである。近年では、述語項構造解析のタスクは、述語の同定および語義曖昧性解消と、述語の項に対する意味役割付与の双方をおこなう複合的なタスクとして扱われている。述語項構造解析は、文の深い意味解析のための重要な要素技術であり、既に、統計的機械翻訳 [16]、質問応答 [13]、含意関係認識 [15] といった自然言語処理の上位アプリケーションにおいて、述語項構造の情報を利用することの有効性が示されている。

述語項構造解析には統語情報の利用が不可欠である。以前は句構造木に基づく手法が主流であったが、近年の依存構造解析アルゴリズムの進展により、依存構造木に基づく述語項構造解析手法に研究者の関心が移ってきており、本研究でも後者を対象とする。

依存構造木に基づく英語の述語項構造の例を図 1 に示す。文の上部は依存構造を、下部は述語 *wore* の述語項構造を表している。この例において、述語 *wore* に対して意味役割を持つ項は、*His daughter* (動作主), *a small hat* (対象), *yesterday* (時間) である。英語の PropBank [12] や NomBank [9] の場合、動作主は A0、対象や被動作主は A1、その他述語ごとに異なる意味役割が A2 から A5 までのラベルに対応付けられている。また、述語が要求する必須の項以外に、時間 (AM-TMP)、場所 (AM-LOC) といった役割を持つ項についても、文中に出現した場合は同定する。依存構造木に基づく意味役割付与タスクでは、ある句が意味役割を持つ場合、その句全体の主辞に対してラベルを付与する問題として扱われる。例えば、図 1 の例では、句 *His daughter* の *His* は *daughter* を修飾しているため句の主辞は *daughter* である。よって、*daughter* に対して A0 を付与する。

これまでの先行研究により、述語項構造解析において以下の二種類の依存関係を考慮することの重要性が示されている。一つは、述語の項の間の大域的な依存関係である。述語項構造の性質として、複数の項が同じ意味役割を持つことは無く、また、述語には必須の項が存在し、これらは基本的には文中に現れる。異なる項が同じ意味役割を持っていないかどうか、また必須の項が構造中に存在しているかどうかは、全ての項を見なければ確認することはできない。これが、述語の項の間の依存関係である。この依存関係は、句構造木を手がかりとした手法では Toutanova ら [14] により、また、依存構造木に基づく手法では Johansson ら [6]、Björkelund ら [1] により考慮されている。具体的には、述語の語義と述語の必須の項によって構成される系列 (例: AGENT-buy.01/Active-PATIENT) を手がかりとして用いる。

もう一つは、述語の語義と項の意味役割の間の依存関係である。ここで、*She drives a car.* という文を考える。述語は *drives*、動作主は *She*、対象となるのは *car* である。PropBank では、動詞 *drive* の語義は 2 種類 (*drive.01* と *drive.02*) 定義されており、*drive.01* の対象となる項は *vehicle*、*drive.02* は *things in motion* となっている。例文では、*drives* の動作対




図 1: 依存構造木に基づく述語項構造の例。

象は *car* であり、これは *vehicle* であるため、*drives* の語義は *drive.01* と推測することができる。このように、述語の語義の決定に項の情報が寄与することから、述語の語義と項の間には依存関係があると言える。この依存関係は、Meza-Ruiz らの Markov Logic Network (MLNs) に基づく述語項構造解析 [11, 10] において考慮されている。彼らのアプローチでは、述語語義とある特定の項の意味役割に関する論理式をモデルに導入することにより、述語語義と項の意味役割の依存関係を考慮した上で双方が同時に推定される。

上記の二種類の依存関係を同時に考慮することにより、頑健な述語項構造解析がおこなえと考えられるが、これまでに提案されている既存研究のアプローチは、これらの依存関係を同時に考慮することが困難である。Johansson ら、Björkelund らの手法では、述語語義と項の意味役割の依存関係を考慮するための手がかりを明示的に与えることはできない。また、Meza-Ruiz らの MLN に基づく手法では、上記の述語の語義と述語の必須の項によって構成される系列を手がかりとして導入することが困難である。なぜなら、必須の項の数は意味役割の割当によって変化するため、単一の論理式で表現することが難しいからである。

本稿では、述語語義と項の意味役割の依存関係を考慮しながら、双方の依存関係を同時に学習、解析をおこなう構造予測モデルを提案する。この手法では、述語の語義曖昧性解消および項に対する意味役割付与とそれぞれの手がかりに加え、述語の語義と項の意味役割の依存関係を捉えるための手がかりと、構造の大域的な情報を捉えるための手がかり (大域的素性) を導入する。これにより、述語の語義と項の意味役割が相互に影響を及ぼしながら最適な述語項構造を得ることが可能になる。また、提案する構造予測モデルのための推論アルゴリズムと、大域的素性を用いた場合の新たなオンライン最大マージン学習アルゴリズムについても述べる。

本稿の構成は以下の通りである。2 節にて、述語の語義と項の意味役割の間の依存関係を捉えた新たな構造予測モデルを提案し、推論および学習手法について述べる。3 節にて、評価実験により提案手法の有効性を検証する。最後に 4 節でまとめと今後の課題について述べる。

2 述語語義と意味役割の結合学習のための構造予測モデル

本節では、述語語義と項の意味役割の依存関係を考慮した構造予測モデルについて述べる。

図 2 は、述語語義と意味役割の結合学習のための構造予測モデルを、無向グラフィカルモデルを用いて表現したものである。図中のノード p は述語に対応し、ここで語義を推定す




図 2: 結合モデルの無向グラフィカルモデル表現。

る。また、ノード a_1, \dots, a_N は述語の項に対応し、ここで意味役割を推定する。黒の四角は、各ノードのラベルを推定するためのスコアに影響を与える因子である。このモデルでは、項に対応するノードは述語の語義と依存し、述語語義のラベルと意味役割のラベルが相互に影響を及ぼし合いながら、全体のラベルが推定される。

このような無向グラフィカルモデルを扱う手法としては、条件付確率場 [7] などの対数線形モデルと、線形モデル (例えば [2, 8]) がある。本研究では、線形モデルを用いて図 2 の無向グラフィカルモデルを表現する。

x を入力単語列、 l を述語、 P_l を述語 l がとりうる語義の集合、 $p \in P_l$ を述語 l のある特定の語義、 $A = \{a_1, a_2, \dots, a_N\}$ を入力単語列 x に対する意味役割ラベルの割当とする。述語語義 p と意味役割の割当 A のペアによってある特定の述語項構造が表現される。

述語語義 p と意味役割の割当 A が与えられた時の述語項構造のスコアを $s(p, A) = \sum_{F_k \in \mathcal{F}} F_k(x, p, A)$ と定義する。 \mathcal{F} はスコアに関与する全ての因子の集合である。 F_k は図 2 に示されているある特定の因子に対応し、述語または意味役割のラベルに対してスコア付けをおこなう。モデルは、このスコアが最大となるような述語語義 p と項に対する意味役割の割当 A を出力とする。因子 F_k は、以下のように線形モデルのパラメータベクトル w と素性ベクトル Φ_k の内積 $F_k(x, p, A) = w \cdot \Phi_k(x, p, A)$ によって定義される。

2.1 結合モデルに用いる因子

本研究で提案する結合モデルでは、以下の 4 種類の因子を用いる。

述語の局所的因子 F_P : 項の意味役割とは独立に、述語 p に対して語義のスコアを与える因子であり、 $F_P(x, p) = w \cdot \Phi_P(x, p)$ と定義される。

項の局所的因子 F_A : 述語の語義とは独立に、各項候補 $a \in A$ に対して意味役割の割当に関するスコアを与える因子であり、 $F_A(x, a) = w \cdot \Phi_A(x, a)$ と定義される。

述語と項のペアワイズ因子 F_{PA} : 述語の語義と項の意味役割の依存関係を捉える目的で導入される因子であり、 $F_{PA}(x, p, a) = w \cdot \Phi_{PA}(x, p, a)$ と定義される。この因子の導入により、述語の語義に影響されて項の意味役割が、また逆に項の意味役割に影響を受けて述語の語義が変更されるという柔軟性がモデルに組み込まれる。

大域的因子 F_G : 述語項構造の大域的な情報を扱うための因子であり、 $F_G(x, p, A) = w \cdot \Phi_G(x, p, A)$ と定義される。これは述語項構造の、構造としての尤もらしさを捉える目的で導入する。これにより、ある述語に関して複数の項が同じ意味役割を持つなど、通常ではあり得ないような意味役割の割当を除外することが可能となる一方、必須の項の欠落を抑制する効果も期待できる。

提案モデルにおける各因子の数は、 F_P と F_G が 1、 F_A と F_{PA} が $|A|$ である。これら全ての因子を統合したスコア関数

は以下ようになる。

$$s(p, A) = w \cdot \Phi_P(x, p) + w \cdot \Phi_G(x, p, A) + w \cdot \sum_{a \in A} \{\Phi_A(x, a) + \Phi_{PA}(x, p, a)\} \quad (1)$$

2.2 結合モデルの推論と学習

提案する結合モデルの推論において問題となるのは、大域的素性を扱う大域的因子 F_G をどのように扱うかである。一般に、大域的素性を用いる場合、モデルの最適解 (argmax) の効率的な計算が困難となる。単純なアプローチでは、全ての可能な割当を列挙した上で大域的素性のスコアを足し、その中で最もスコアの高い割当を選択するという処理が必要となるが、それは非効率的であり現実的な選択肢とは言えない。線形モデルに大域的素性を導入する手法に関する先行研究としては、Daumé らによる探索の最適化に基づく学習 (LaSO) [4] と、風間らによる N-best ベースの手法 [18] がある。LaSO は履歴ベースの手法で、得られている構造に関する特徴を随時使いながら探索をおこなっていく。一方、風間の手法は、大域的素性を除いた素性を用いて N-best 解を求め、大域的素性をそれぞれの解から得て、最終的に双方の特徴から最適解を求める。モデルの学習には、大域的素性を扱うためのマージンパーセプトロン学習が提案されている。

本研究では、構造全体の特徴を用いることができる風間らの手法に基づき、大域的素性を扱うことにする。まず、述語 l がとりうる語義 $p \in P_l$ ごとに項の意味役割の N-best 解を F_P, F_A, F_{PA} を用いて生成する。次に、それぞれの解のスコアに大域的因子のスコアを加え、最後にその中から最もスコアの高い割当を選択する。結合モデルの推論アルゴリズムを Algorithm 1 に示す。

Algorithm 1 結合モデルの推論アルゴリズム

```

input sentence  $x$ 
 $\hat{p} = \hat{A} = null$ 
for  $p_i \in P_l$  do
   $\{A\}^n = \text{generate N-best assignments using } F_P, F_A \text{ and } F_{PA}$ 
  for  $A_j \in \{A\}^n$  do
     $s(p_i, A_j) = w \cdot \Phi_G(x, p_i, A_j) + w \cdot \Phi_P(x, p_i) + w \cdot \sum_{a \in A_j} \{\Phi_A(x, a) + \Phi_{PA}(x, p_i, a)\}$ 
    if  $s(p_i, A_j) > s(\hat{p}, \hat{A})$  then
       $\hat{p} = p_i, \hat{A} = A_j$ 
    end if
  end for
end for
return  $\hat{p}$  and  $\hat{A}$ 

```

結合モデルの学習についても、推論アルゴリズムと同様に風間らの手法をベースとするが、適用する学習アルゴリズムは、文献 [19] にて用いられている、Passive-Aggressive アルゴリズム [3] を大域的素性を扱えるよう拡張したアルゴリズムを用いる。アルゴリズムの詳細は、文献 [19] を参照されたい。

2.3 述語と項のペアワイズ因子の扱い

前述の通り、 F_{PA} は述語の語義の選択と項の意味役割の選択の双方に影響を及ぼす。意味役割のラベルには、意味役割無しを意味するラベル “NONE” が含まれているが、ある項が意味役割を持たないという情報が、述語の語義曖昧性の解消に寄与するとは考えにくい。しかし、 F_{PA} をそのまま導入すると、 $a = \text{NONE}$ であっても、ある特定の述語語義のスコアを高くするようなパラメータが学習されてしまう可能性がある。そこで、 $a = \text{NONE}$ の場合には、それぞれの述語語義に

表 1: 結合モデルの各因子に用いた素性

| | |
|----------|--|
| F_P | 述語および述語の主辞の原形, 述語の品詞, またそれらの組み合わせ. 述語と述語の主辞の間の依存構造ラベル. 述語に支配されている子ノードの依存構造ラベルを, 単語の出現順に結合した系列. |
| F_A | 述語, 述語の親, 項候補, 項候補の親の原形と品詞 項候補の最左, 最右の子, 最左, 最右の兄弟の原形と品詞 述語, 項候補, 項候補の子の依存構造ラベル 述語と項の間の親子関係 (例: 子 or 兄弟 or etc.) 述語と項の前後関係 (例: arg-pred or pred-arg) 述語の子の依存構造ラベルを出現順序順に並べた系列 依存構造上の述語と項の間のパス (原形, 品詞, 依存構造ラベル) 述語と項の間にある依存構造の辺の数 |
| F_{PA} | 項の原形, 項の原形と品詞の組み合わせ 述語と項の間の依存構造パス |
| F_G | 意味役割を, 対応する単語の出現順序順に並べた系列 (例: A0-PRED-A1) フレームに定義されている意味役割が含まれているか (例: CONTAINS:A1 or MISSING:A1) 述語語義とフレーム情報の組み合わせ (例: wear.01&CONTAINS:A1 or wear.01&MISSING:A1) |

依存しない共通のダミー語義 p_{dummy} を導入し, $a = \text{NONE}$ の場合の因子を $F_{PA}(x, p_{dummy}, a = \text{NONE})$ として, 対応するパラメータの値が語義によって変化しないようにすることで, このような事態を避ける.

3 評価実験

3.1 データと実験設定

多言語の述語項構造解析のためのデータセットである CoNLL-2009 Shared Task データ [5] を用いて評価実験をおこなう. CoNLL-2009 Shared Task は, 指定された述語の項構造のみを同定するタスクであり, どの単語が述語であるかの判別 (述語同定) はタスクには含まれていない. したがって, 扱う問題は述語の語義曖昧性解消と項に対する意味役割付与の二つとなる^{*1}. 日本語については, 述語語義の情報が付与されていないため, タスクは述語の項に対する意味役割付与のみである. 評価指標は, 述語項構造解析タスクにおいて一般的に用いられている Semantic Labeled F1 を用いる.

結合モデルの学習および解析に用いた素性を表 1 に示す. 実験では, 各言語ごとに最適な素性集合を得るための素性選択は特におこなっておらず. 全ての言語で共通の素性を用いた. また, F_G を扱うための N-best 解の数は $N = 64$ とし, Passive-Aggressive アルゴリズムの学習におけるマージンの値は, 述語語義と項の意味役割の誤りの総数とした.

項候補の枝刈りは, カタロニア語とスペイン語については述語の直接の子となっている単語のみを項候補とした. それ以外の言語については [19] と同様の処理をおこなった.

3.2 実験結果

提案モデルの結果および CoNLL-2009 Shared Task の述語項構造解析タスク (SRL-only)^{*2}における上位 3 システムの結果を表 2 に示す.

まず, $F_P + F_A$ と $F_P + F_A + F_{PA}$ の結果を比較すると, F_{PA} の導入によりほぼ全ての言語において性能が向上していることがわかる. 特にドイツ語では F 値で +1.55 の向上が得られ

ており, 述語と項の間の依存関係を捉えることが有効であることがわかる. 日本語の解析では語義曖昧性解消をおこなわないため, F_{PA} の導入はそれほど意味が無いように思われるが, F_{PA} の追加によって F 値で +0.45 の向上が得られた. これは, F_{PA} の素性空間が完全には F_A に含まれていないことが理由として考えられる. 例えば, 依存構造パスと単語の原形の組み合わせ素性は F_A には含まれていない.

次に, $F_P + F_A$ と F_G を加えた結果を比較すると, チェコ語以外の言語においては大幅に性能が向上し, 特にドイツ語では, F 値で +1.88 の向上が得られている.

CoNLL-2009 Shared Task の上位チームの結果と比較すると, F_{PA} と F_G の双方を組み合わせることで, Björkelund ら, Zhao らのシステムに匹敵する性能を達成し, Meza-Ruiz らのシステムと比較して優位な差が得られた^{*3}. Björkelund ら, Zhao らは多くの素性テンプレートの中で, 各言語で最適な素性集合を素性選択アルゴリズムによって選択し, それらを適用することによって大幅な性能の向上が得られている^{*4}. 一方, 本研究では素性選択は一切おこなっておらず, 全ての言語で同一の素性集合を用いて学習, テストをおこなっているため, 素性選択の適用によりさらなる性能の向上が期待できる. Meza-Ruiz らの Markov Logic Networks (MLN) による手法は, 述語語義と意味役割を同時に学習・解析している点で提案手法と共通しているが, 性能の面では開きがある. この理由としては, [11] では提案手法の F_G で用いている大域的素性 (必須の項を要素とした構造を表す素性や, フレームに関する素性) が用いられていないことが考えられる. これらの素性は, 表 2 の結果が示しているように, 解析性能に大きく寄与するものであるが, 前述したように, MLN の枠組みでは少なくとも必須の項を要素とした構造を表す素性を扱うことは困難である.

次に, 述語の語義曖昧性解消と意味役割付与を個別に評価した結果を表 3 に示す. 表中の SENSE は述語の語義曖昧性解消の精度, ARG は意味役割付与の F 値を示している. 日本語については語義曖昧性解消の問題は含まれないため, 結果は掲載していない^{*5}.

^{*1} 一部の述語にしか項構造の情報が付与されていない不完全なデータが含まれているため. 例えば, ドイツ語のデータ (SALSA Corpus) は, 一部の動詞のみ述語項構造が付与されている. 英語の依存構造木に基づく述語項構造解析タスクである CoNLL-2008 Shared Task では, 述語同定もタスクに含まれる.

^{*2} CoNLL-2009 Shared Task には, 依存構造解析もタスクに含まれる Joint と, 意味役割付与のみをおこなう SRL-only の 2 種類のタスクがある.

^{*3} Meza-Ruiz らの結果のうち, チェコ語に関しては述語語義の処理の問題により他のシステムと比較して著しく性能が劣っている. チェコ語を除いた平均性能を比較すると, Meza-Ruiz らのシステムが F 値で 77.75 であるのに対し, 提案手法は F 値で 79.89 である.

^{*4} しかし, 素性選択の適用は時間的なコストが大きく, Björkelund らは 1 ヶ月, Zhao らは 2 ヶ月を素性選択に費やしている.

^{*5} 日本語の Semantic Labeled F1 と ARG の数字が異なるのは, 実際

表 2: CoNLL-2009 Shared Task データを用いた実験結果 (Semantic Labeled F1)

| | Average | Catalan | Chinese | Czech | English | German | Japanese | Spanish |
|------------------|---------|---------|---------|-------|---------|--------|----------|---------|
| F_P+F_A | 79.17 | 78.00 | 76.02 | 85.24 | 83.09 | 76.76 | 77.27 | 77.83 |
| $F_P+F_A+F_{PA}$ | 79.58 | 78.38 | 76.23 | 85.14 | 83.36 | 78.31 | 77.72 | 77.92 |
| $F_P+F_A+F_G$ | 80.42 | 79.50 | 76.96 | 85.88 | 84.49 | 78.64 | 78.32 | 79.21 |
| ALL | 80.75 | 79.55 | 77.20 | 85.94 | 84.97 | 79.62 | 78.69 | 79.29 |
| Björkelund [1] | 80.80 | 80.01 | 78.60 | 85.41 | 85.63 | 79.71 | 76.30 | 79.91 |
| Zhao [17] | 80.47 | 80.32 | 77.72 | 85.19 | 85.44 | 75.99 | 78.15 | 80.46 |
| Meza-Ruiz [11] | 77.46 | 78.00 | 77.73 | 75.75 | 83.34 | 73.52 | 76.00 | 77.91 |

表 3: CoNLL-2009 Shared Task データを用いた実験結果 (述語の語義曖昧性解消精度, 意味役割付与 F1)

| | | Average | Catalan | Chinese | Czech | English | German | Japanese | Spanish |
|-------|------------------|---------|---------|---------|-------|---------|--------|----------|---------|
| SENSE | F_P+F_A | 89.65 | 85.86 | 94.86 | 94.09 | 95.14 | 83.81 | - | 84.17 |
| | $F_P+F_A+F_{PA}$ | 89.78 | 85.98 | 94.94 | 94.10 | 95.30 | 84.00 | - | 84.36 |
| | $F_P+F_A+F_G$ | 89.83 | 86.66 | 95.00 | 94.23 | 95.24 | 83.09 | - | 84.79 |
| | ALL | 90.15 | 86.68 | 95.09 | 94.31 | 95.56 | 84.18 | - | 85.10 |
| ARG | F_P+F_A | 72.20 | 74.52 | 67.43 | 74.89 | 77.47 | 73.08 | 63.00 | 75.05 |
| | $F_P+F_A+F_{PA}$ | 72.74 | 75.01 | 67.69 | 74.64 | 77.77 | 75.35 | 63.67 | 75.10 |
| | $F_P+F_A+F_G$ | 74.11 | 76.33 | 68.75 | 76.11 | 79.50 | 76.34 | 65.03 | 76.77 |
| | ALL | 74.46 | 76.39 | 69.05 | 76.16 | 80.05 | 77.26 | 65.58 | 76.74 |

まず, SENSE の結果について見ると, F_{PA} と F_G の双方を導入することにより全ての言語において精度が向上している. 特に, スペイン語とカタロニア語では比較的高い精度向上の幅 (それぞれ +0.93, +0.86) が得られている. 因子別に見ると, F_{PA} を加えた場合の精度の変化は平均で +0.13, F_G を加えた場合の精度の変化は平均で +0.18 程度であるが, 双方の因子を加えた場合は +0.50 の改善が得られ, 双方の因子の組み合わせが有効であると言える.

次に, ARG の結果について見ると, F_{PA} と F_G の導入により, SENSE の結果同様, 全ての言語で性能の向上が得られた. 特に, ドイツ語での性能の向上が顕著である (+4.18). 因子別に見ると, F_{PA} を加えた場合では, 意味役割付与の F 値は平均で +0.54 の改善が得られている. これは, 述語と項の間の依存関係を捉えることが, 項の意味役割同定に寄与していることを示している. F_G を加えた場合は, F 値の向上は +1.91 となっており, 大域的な構造を捉えることの重要性を示している.

双方のタスクの結果を見ると, 全ての因子を導入した場合では, 述語語義と項の意味役割を個別に学習・解析した場合 (F_P+F_A) と比較し, 述語語義曖昧性解消の精度が平均で +0.50, 意味役割付与では F 値の平均で +2.26 と双方の性能が向上しており, 提案手法による結合学習が成功していると言える.

4 まとめ

本稿では, 述語語義と項の意味役割を同時に学習するための構造予測モデルについて述べた. 具体的には, 4 種類の因子 (述語の局所的因子, 項の局所的因子, 述語と項のペアワイズ因子, 大域的因子) を導入した線形モデルを用いて, 述語語義と項の意味役割を同時に推定する構造予測モデルを設計した.

評価実験により, 提案手法による述語の語義曖昧性解消と項に対する意味役割付与の結合学習により, 双方のタスクの性能が向上することを示した. また, 素性選択を一切おこなわずに, これまでに報告されている多言語の依存構造解析の結果の中で, 最良のシステムの性能と遜色の無い結果が得られた.

は語義曖昧性解消が評価に含まれているからである. 日本語における正解の語義は, 述語の原形そのものである.

今後の課題としては, 述語の選択選好を考慮した手法, またラベル無しデータを活用した半教師あり述語項構造解析の手法について検討していきたいと考えている.

参考文献

- [1] Björkelund, A., Hafdel, L. and Nugues, P.: Multilingual Semantic Role Labeling, *CoNLL-2009* (2009).
- [2] Collins, M.: Discriminative Training Methods for Hidden Markov Models: Theory and Experiments with Perceptron Algorithms, *EMNLP-2002* (2002).
- [3] Crammer, K., Dekel, O., Keshet, J., Shalev-Shwartz, S. and Singer, Y.: Online Passive-Aggressive Algorithms, *JMLR*, Vol. 7 (2006).
- [4] Daumé III, H. and Marcu, D.: Learning as Search Optimization: Approximate Large Margin Methods for Structured Prediction, *ICML-2005* (2005).
- [5] Hajič, J., Ciaramita, M., Johansson, R., Kawahara, D., Martí, M. A., Márquez, L., Meyers, A., Nivre, J., Padó, S., Štěpánek, J., Straňák, P., Surdeanu, M., Xue, N. and Zhang, Y.: The CoNLL-2009 Shared Task: Syntactic and Semantic Dependencies in Multiple Languages, *CoNLL-2009*, Boulder, Colorado, USA (2009).
- [6] Johansson, R. and Nugues, P.: Dependency-based Syntactic-Semantic Analysis with PropBank and NomBank, *CoNLL-2008* (2008).
- [7] Lafferty, J., McCallum, A. and Pereira, F.: Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data, *ICML-2001* (2001).
- [8] McDonald, R., Hannan, K., Neylon, T., Wells, M. and Reynar, J.: Structured Models for Fine-to-Coarse Sentiment Analysis, *ACL-2007* (2007).
- [9] Meyers, A., Reeves, R., Macleod, C., Szekely, R., Zielinska, V., Young, B. and Grishman, R.: The NomBank Project: An Interim Report, *HLT-NAACL 2004 Workshop on Frontiers in Corpus Annotation* (2004).
- [10] Meza-Ruiz, I. and Riedel, S.: Jointly Identifying Predicates, Arguments and Senses using Markov Logic, *NAACL-2009* (2009).
- [11] Meza-Ruiz, I. and Riedel, S.: Multilingual Semantic Role Labelling with Markov Logic, *CoNLL-2009* (2009).
- [12] Palmer, M., Gildea, D. and Kingsbury, P.: The Proposition Bank: An Annotated Corpus of Semantic Roles, *Computational Linguistics*, Vol. 31 (2005).
- [13] Shen, D. and Lapata, M.: Using Semantic Roles to Improve Question Answering, *EMNLP-CoNLL 2007* (2007).
- [14] Toutanova, K., Haghghi, A. and Manning, C. D.: A Global Joint Model for Semantic Role Labeling, *Computational Linguistics*, Vol. 34, No. 2 (2008).
- [15] Wang, R. and Zhang, Y.: Recognizing Textual Relatedness with Predicate-Argument Structures, *EMNLP-2009* (2009).
- [16] Wu, D. and Fung, P.: Can Semantic Role Labeling Improve SMT?, *EAMT-2009* (2009).
- [17] Zhao, H., Chen, W., Kit, C. and Zhou, G.: Multilingual Dependency Learning: A Huge Feature Engineering Method to Semantic Dependency Parsing, *CoNLL-2009* (2009).
- [18] 風間淳一, 鳥澤健太郎: 大域的素性を用いたタグ付けのためのパーセプトロン学習, 言語処理学会第 13 回年次大会発表論文集 (2007).
- [19] 渡邊陽太郎, 浅原正幸, 松本裕治: オンライン最大マージン学習アルゴリズムに基づく多言語依存構造-述語項構造解析, 情報処理学会第 192 回自然言語処理研究会予稿集, NL-192, No.2 (2009).