

隠れ変数を持つ識別モデルによる文間意味関係の学習

渡邊 陽太郎[†] 水野 淳太[†] 岡崎 直観^{†‡} 乾 健太郎[†][†] 東北大学 大学院情報科学研究科 [‡] 科学技術振興機構 さきがけ

{yotaro-w, junta-m, okazaki, inui}@ecei.tohoku.ac.jp

1 はじめに

二文間の意味関係を認識する文間関係認識の問題は、情報検索、質問応答、機械翻訳、言い換え、文書要約などの自然言語処理の分野において共通に含まれる問題であり、英語については Recognizing Textual Entailment (RTE) [4]、日本語や中国語については、NTCIR-9 Recognizing Inference in TExt (RITE) [13] にて含意関係や矛盾関係を認識する評価型ワークショップが開催されるなど、広く問題の重要性が認識されている。

文間関係認識の手法は、単語や n-gram の単純なオーバーラップに基づく手法 (例えば [7])、構造的類似度に基づく手法 (例えば [23]) が数多く提案されてきた。しかし、文間関係認識の問題は、語彙レベルでの意味関係、量化詞、文脈に依存する含意関係の向きの変化、事態の事実性、事態間関係、数値表現など、様々な言語現象を捉える必要のある複合的な問題である。したがって、単純な類似度だけでは、これらの言語現象の影響を考慮し、文間の適切な意味関係を導くことは困難である。

一方、論理の枠組を利用した文間関係認識手法もこれまでに提案されてきており、定理証明によって関係を認識する手法 [2, 17, 18]、認識重み付きアブダクション [12]、Markov Logic Networks (MLN) [5] など、重み付きの論理の枠組を用いている手法が提案されてきた。論理の枠組での推論により、精緻な関係の認識が可能となるが、前者は推論規則が十分でないという意味関係の導出に失敗してしまうという問題があり、後者は、扱える現象が限定されている、扱える意味関係が含意関係に限定されているなどの課題が残されている。

MacCartney らは、論理形式への変換を経ずに自然言語上での意味関係の推論を実現する Natural Logic [8] に基づく文間関係認識手法を提案した [10]。この手法では、統語構造上で直接意味関係の推論をおこなうため、論理に基づく手法と比較すると頑健性において優れていると言える。また、様々な意味関係と、それらの意味関係の結合規則を定義することで、含意関係だけでなく矛盾関係や同値関係など多様な意味関係を扱うことを可能にしている。また、様々な言語現象による影響を考慮しながら、構成的に意味関係を導くことができる。しかし、彼らの手法は、入力に適切なアライメントが与えられていることが前提になっている。文の要素間に対してアライメントを付与するのは、その間に何らかの意味関係が認められる場合であり、その意味関係がアライメントの根拠となる。したがって、アライメントと意味関係は密に関連してあり、分離することは適切ではないと考えられる。

本論文では、構成的に意味関係を導き、アライメントと個々の要素の間の意味関係、導出過程で得られる意味関係、最終的な文間の意味関係の全てを同時に推定する識別モデルを提案する。構成的に意味関係を導くために、モデルには MacCartney らによって提案された Natural Logic に基づく意味関係とその結合規則 [10] を導入し、規則に整合するアライメントとそれらの意味関係を推定する。アライメントと、意味関係を同時に推定するために、それぞれを表す変数、およびそれらの依存関係を表現する因子を導入した Factor Graph

を構成し、条件付確率場 [16] を用いてモデル化することによって、双方を同時に推定することを実現する。

本論文の構成は以下の通りである。まず、提案手法の基礎となる理論である Natural Logic について 2 節にて述べ、次に 3 節にて、提案する文間関係認識モデルについて説明する。4 節にて評価実験、5 にて関連研究、特に、様々なアライメントの可能性を考慮しながら文間関係をおこなう手法について述べ、最後に 6 節にてまとめと今後の課題について述べる。

2 Natural Logic

Natural Logic の概念は Lako [8] により提唱され、monotonicity calculus に基づく含意関係に関する説明の理論が、van Benthem [20, 21] や Sánchez Valencia [19] により研究された。彼らの理論の対象は含意関係のみであったが、MacCartney [10] により、排他的な関係が扱えるよう拡張された。例えば、Stimpy is a cat \models Stimpy is not a poodle のような関係である。ここでは、[10, 9] の Natural Logic の理論について説明する。

基本的な考え方は、文間の意味関係は一方から他方への文の要素の編集操作(置き換え、挿入、削除)が持つ意味関係を結合することによって導かれるというものである。彼らは、それぞれの編集操作に対して、以下の意味関係を定義している。同値 (equivalence, \equiv)、前向き含意 (forward-entailment, \sqsubset)、後ろ向き含意 (backward-entailment, \sqsupset)、否定 (negation, \neg)、交代 (alternation, \oplus)、包含 (cover, \cup)、独立 (independent, $\#$) の 7 種類である*1。

個々の編集操作によって導かれる意味関係は、文脈に依存して変化する。例えば、〈サッカー、スポーツ〉の置き換え操作は、前向き含意 (\sqsubset) が導かれるが、否定のスコープをはじめとする downward-monotone の文脈では、〈彼はサッカーをしない \sqsupset 彼はスポーツをしない〉となり、含意関係の向きが逆転する。この文脈の影響を考慮した意味関係の変換を、ここでは意味関係の射影 (projection) と呼ぶ。文間意味関係は、この射影された意味関係を結合することによって求められる。射影が必要となるのは、量化詞や条件文、また動詞が出現した場合などである。

射影された個々の意味関係から、それらの意味関係の結合規則により、文間の意味関係が導かれる。これが最終的な文間の意味関係となる。意味関係の結合規則は、次のように 3 つ組として定義される。7 種類の意味関係の集合を \mathcal{R} 、 $r_i \in \mathcal{R}$ 、 $r_j \in \mathcal{R}$ とすると、結合規則は、 $r_i \bowtie r_j \Rightarrow r \in \mathcal{R}$ である。 $\sqsubset \sqsubset \Rightarrow \sqsubset$ や、 $\sqsubset \bowtie \wedge \Rightarrow |$ のように、一つに関係が決定される場合もあれば、 $|\bowtie \Rightarrow \cup\{ \sqsubset, \sqsupset, |, \# \}$ のように、一つの意味関係に決まらない、曖昧性が生じる場合もある。結合が繰り返されると、意味関係は次第に、関係としての情報が最も少ない $\#$ の方向に進んでいくことになる*2。

*1 これらの関係を表す記号は、MacCartney ら [10] とほぼ同一のものを用いている。

*2 スペースの関係上、結合規則の全てを掲載することはできない。詳細については [9] を参照されたい。




図 1: 提案モデルにおいて構成される Factor Graph

3 文間関係認識のための隠れ変数を持つ識別モデル

文間関係認識は通常、テキスト (T) と仮説 (H) が与えられた時に、これらの文対が持つ意味関係を認識する。それに対して、我々は、文間の意味関係に加えて、その文間関係の根拠となるアライメントも同時に推定するという問題を扱う。

我々は、文の意味関係は構成的に導かれるという仮定のもと、MacCartney ら [10, 9] により提案されている、Natural Logic に基づく意味関係の演算によって、文の意味関係を認識する。そして、アライメントと文間意味関係の認識を、グラフィカルモデル上での推論の問題へと帰着させ、識別モデルである条件付確率場を用いてモデル化する。

提案モデルでは、MacCartney らの手法と同様、 T から H への編集操作に対して意味関係を与える。 T 内の各文節 $t_i \in T$ に関して、 H 内の文節 $h_j \in H$ との対応する状態、およびどの文節とも対応しない (*null*) 状態をノードとして表現し、それぞれに対して *true* または *false* のどちらかを与えることでアライメントの問題を取り扱う。文節間の意味関係を表すノードは、それぞれのアライメントのノードと依存関係を持ち、2 節で述べた 7 種類の意味関係のうちいずれかの値をとる。文脈を考慮した意味関係の射影、および意味関係の結合の過程で得られる意味関係についても、それぞれが Factor Graph 上のノードとして表現され、そのグラフ上での推論によって、それぞれが影響を及ぼしあいながら、アライメント、導出過程で得られる意味関係、最終的な意味関係の全てを同時に導くことができる。

文間関係認識の問題において、文間の対応付けというのは、必ずしも正解が一つに決まるわけではない。提案モデルにおけるアライメントの基準は、Natural Logic の規則と整合するかどうかである。意味関係の結合規則に合致するかどうかは、Factor Graph 上の因子により判定され、合致しない割当は推論の段階で排除される。モデルの学習では、正解となる意味関係から、Natural Logic の意味関係と整合するアライメント、および編集の意味関係が推定される。ここで、アライメントと、導出過程で得られる意味関係は隠れ変数として扱われるため、提案する条件付確率場は隠れ変数を持つことになる。隠れ変数を持つ条件付確率場は、中川らの評価極性分類モデル [25] などに用いられている。

3.1 モデル

我々が提案する、アライメントと文間関係の双方を同時に認識する文間関係認識モデルは、以下の式により与えられる。

$$p(\mathbf{a}, \mathbf{r}^L, \mathbf{r}^P, \mathbf{r}^C | \mathbf{x}; \lambda) = \frac{1}{Z(\mathbf{x})} \exp \left(\sum_k \Psi_k(\mathbf{a}, \mathbf{r}^L, \mathbf{r}^P, \mathbf{r}^C, \mathbf{x}; \lambda) \right) \quad (1)$$

ここで、 $\mathbf{a} = \{a_{i,j}\}$ はアライメントを表現する変数であり、 i は T 内の文節のインデックス、 j は H 内の文節のインデックスを表している。それぞれの要素 $a_{i,j}$ は対応するかどうか、*true* または *false* の 2 値のどちらかをとる。各文節は必ずしも対応するとは限らないため、対応しない場合を表現する変数 $a_{i,null}$ を導入する。 \mathbf{r}^L は、文脈を考慮しない場合の文節間の意味関係を表現する変数である。つまり、編集操作単独での意味関係を表す変数である。 \mathbf{r}^P は、文脈を考慮した場合の文節間の意味関係を表現する変数であり、downward-monotone や条件などの特別な文脈において変化する意味関係の結果を表す。そして、 \mathbf{r}^C は、 \mathbf{r}^P の意味関係の一つずつ結合していく際に得られる意味関係を表す変数の集合であり、それぞれの変数は、一つの結合規則を適用した結果導かれる意味関係に対応する。以下、意味関係を結合した結果、最終的に得られる意味関係を表す変数を r_T^C と記述する。 $r_T^C \in \mathbf{r}^C$ である。また、記述の簡単化のため、意味関係を表現する変数 $\mathbf{r}^L, \mathbf{r}^P, \mathbf{r}^C$ をまとめて \mathbf{r} と記述する場合がある。意味関係を表すそれぞれの変数 $r \in \mathbf{r}$ は、前述の 7 種類の意味関係のいずれかをとる。

二文が与えられた時、文間の意味関係が l となる確率は、以下の式により与えられる。

$$p(r_T^C = l | \mathbf{x}; \lambda) = \sum_{\mathbf{a} \in \mathcal{A}} \sum_{\mathbf{r}^L, \mathbf{r}^P, \mathbf{r}^C: r_T^C = l} p(\mathbf{a}, \mathbf{r}^L, \mathbf{r}^P, \mathbf{r}^C | \mathbf{x}; \lambda) \quad (2)$$

式 (1) 中の Ψ_k は因子に対応し、各変数への値割当に対してスコアリングをおこなう。提案するモデルでは、以下の 4 種類の因子を用いる。

アライメント因子 Ψ_A : T と H 内の文節間が対応するかどうかをスコア付けする因子であり、 $\Psi_{A_{i,j}} = \lambda \cdot f(a_{i,j}, \mathbf{x})$ と定義する。この因子に与える情報には、表層の類似度や語彙知識を利用する。

語彙的意味関係因子 Ψ_L : アライメントされた文節間の意味関係を決定するための因子であり、 $\Psi_{L_i} = \lambda \cdot f(r_i^L, a_{i,j}, \mathbf{x})$ と定義する。この因子にも、アライメント因子と同様、表層から得られる類似度や、語彙知識を利用する。

意味関係射影因子 Ψ_P : r_i^L 出現している文脈を考慮し、適切な意味関係へと射影するために用いる因子であり、 $\Psi_{P_i} = \lambda \cdot f(r_i^L, r_i^P, \mathbf{x})$ と定義する。この因子では、monotonicity (upward, downward, non) や、量化詞のスコープに含まれている文節の意味関係を射影するために利用する。

意味関係結合因子 Ψ_C : 結合される二つの意味関係から導かれる意味関係が適切であるかどうかをスコア付けする因子であり、 $\Psi_{C_i} = \lambda \cdot f(r_{i-1}^C, r_i^P, r_i^C, \mathbf{x})$ と定義する。この因子は、適切な意味関係の結合のみが選択される役割を果たす。これには、[9] にて定義されている意味関係の結合規則を用いる。

構成される Factor Graph 内に含まれる上記の因子の数は、 Ψ_A と Ψ_L は $|T| \cdot (|\mathcal{H}| + 1)$ 、 Ψ_P, Ψ_C は $|T|$ である。

3.2 モデルの学習・推論

モデルの学習では、入力が与えられた時に正解の文間意味関係が出力される確率が最大となるよう、周辺尤度を最大化する。

$$\mathcal{L}_\lambda = \sum_n \log p(r_T^C = l | \mathbf{x}^n; \lambda) \quad (3)$$

これをあるパラメータ λ_k で偏微分すると以下の式となる。

$$\frac{\partial L}{\partial \lambda_k} = \sum_n \left(\frac{\partial}{\partial \lambda_k} \log \sum_a \sum_{\mathbf{r}: r_T^C=l} \Psi_k(\mathbf{a}, \mathbf{r}, \mathbf{x}) \right) \frac{\partial}{\partial \lambda_k} \log Z(\mathbf{x}) \quad (4)$$

ここで、アライメント情報 \mathbf{a} 、語彙的意味関係の集合 \mathbf{r}^L 、射影後の意味関係の集合 \mathbf{r}^P 、最終的な文間意味関係を除く意味関係の結合結果 $\mathbf{r}^C \setminus r_T^C$ は与えられないため、これらは全て隠れ変数として扱われる。そのため、式 (3) は凸関数とはならず、大域的な最適解が得られる保証は無い。また、式 (3) の最適化においては、各因子の周辺確率を求める必要があるが、提案モデルで用いられる Factor Graph は閉路を含まないため、Belief Propagation アルゴリズム [24] を用いることで効率的に計算することが可能である。また、最も確率の高くなるグラフ上の変数割当てについては、Max Product アルゴリズムを用いて得ることができる。

3.3 素性

各因子にて用いている素性は以下の通りである。

3.3.1 アライメント因子

表層情報 T と H 内のある文節のペアの品詞系列、主辞の品詞、表層、またそれらが同じであるかどうか。形態素レベルの unigram, bigram が一定値以上であるかどうか。 $null$ との対応の場合は、主辞の表層、品詞。
構造情報 各文節が述語項構造の述語であるか、または項であるか。項であればその格情報。

3.3.2 語彙的意味関係因子

表層情報 格文節間の表層、品詞、それらが同一か否か。 $null$ との対応の場合は、主辞の表層、品詞。
極性情報 述語の事実性が否定されているか。また、肯否極性が逆であるか。 $null$ との対応の場合は、否定表現があるか。
語彙知識 Japanese WordNet [1], Wikipedia から獲得された上位下位関係 [15], 動詞含意関係辞書 [6] 動詞の意味関係辞書 [11] にエントリがあるか。

3.3.3 意味関係射影因子

語彙的意味関係 r_i^L と射影後の意味関係 r_i^P の双方に依存する素性 $f_k^P(r_i^L, r_i^P, \mathbf{x})$ をここで用いる。
量子素性 量子子がとる二つの項 (修飾される名詞句と、動詞句) に対して、量子子のタイプと何番目の項のスコープであるかという情報を与える。^{*3}
monotonicity 素性 文節が、upward-monotone であるか、downward-monotone であるか。^{*4}

3.3.4 意味関係結合因子

意味関係結合素性 7 種類の意味関係のうち、3 つの意味関係の可能な組み合わせに対して、それぞれ $f_k^C(r_{i-1}^C, r_i^P, r_i^C)$ という素性を定義する。 r_{i-1}^C は、これまでの意味関係の結合によって得られた意味関係、 r_i^P は次に結合される射影後の意味関係、 r_i^C はこれらを結合した結果得られる意味

関係である。この素性は、観測には依存せず、関係ラベルのみに依存する。

4 評価実験

提案モデルの評価には、Textual Entailment 評価データ [26] の中から、Natural Logic に基づく推論が意味関係の分類に寄与すると考えられるカテゴリの事例 (全 1198 事例) を選択し、利用した。このデータに付与されている関係は含意関係のみであるため、同値 (B)、前向き含意 (F)、後ろ向き含意 (R)、矛盾 (C)、その他 (I) の関係を新たに付与した。結果、それぞれの関係に該当する事例数は B:181, F:531, R:76, C:120, I:290 となった。評価は、5 分割交差検定によりおこなった。

モデルで扱う意味関係は 7 種類であるのに対し、付与したラベルは 5 種類である。学習では、矛盾 (C) の関係の場合は $\{\wedge, \}$ 、その他 (I) の場合は $\{\cup, \#\}$ の複数のラベルを正解とみなして学習をおこなった。^{*5}

パラメータの初期値は、意味関係射影因子と意味関係結合因子に含まれる素性のパラメータについてはそれぞれ、[9] に定義されている場合は +1、定義されていない場合は -5 に設定した。その他の因子については、それぞれ相関があると考えられる素性には正の、相関が無いと考えられる素性には負の値を初期値として設定した。

学習では、アライメント因子と語彙的意味関係因子に定義されている素性のパラメータのみを更新し、意味関係射影因子と意味関係結合因子のパラメータは初期値のままとした。パラメータの最適化には確率的勾配降下法を採用し、1 事例ごとに更新をおこなった。また、イテレーション回数は 40 に設定した。

5 分割交差検定の結果、得られた正解率は 40.32 であった。これは、最も多い前向き含意の関係 (F) を全て付与した場合の正解率 44.32 を下回っており、十分な数字であるとは言えない。アライメントについては、正解を付与していないため、定量的な評価はできないが、出力を確認したところ、妥当なアライメントが得られた事例が存在していた。しかし、現状のモデルでは、 T 側への対応が一つ以上ある場合は、 $null$ と対応してはならないという制約が導入されていないため、 T 側の文節への対応があり、なおかつ $null$ とも対応しているという状況も生じていた。この問題の解決方法としては、制約に違反する値割当てを排除するような因子を導入することが考えられる。このような因子を値割当ての制約として導入する方法は、例えば、Belief Propagation による依存構造解析 [14] にて採用されている。

次に文間の意味関係に関して、同値 (B) が F 値で 55.62 と最も高く、一方で、矛盾の関係については F 値で 9.95 と最も低い性能であった。誤った事例としては、例えば、“ T : 太郎は次郎の兄だ H : 次郎は太郎の兄だ” のように、二つの要素間の関係を捉えなければ正しく意味関係を認識できない事例があった。この例は矛盾 (C) の関係にあるが、モデルは同値 (B) を出力した。これに関連して、比較構文、事態の因果関係なども要素間関係を捉える必要が出てくる事例となる。提案モデルでは現状、文節間のみ編集を扱っているため、要素間関係を考慮した編集を導入する必要がある。

^{*3} スコープの取り扱いは現状、十分ではない。現在は、第一の項は量子子と隣接する名詞句、第二の項は依存構造の親を辿っていき最初に到達する動詞とされている。

^{*4} 単純な規則を用いており、否定表現の“ない”が出現した場合に、依存構造上の主語以外の子に対して、downward-monotone のスコープであるという情報を付与している。また、non-monotone は現状では考慮していない。

^{*5} 実際は、これらの事例だけで学習した場合に、パラメータの学習が意図とは異なる方向に進んだため、それぞれの事例の T と H から同一の文対で同値関係となる事例を作成し、それらも学習時に用いている。

5 関連研究

様々なアライメントを考慮しながら、文間の意味関係を学習・認識する手法はこれまでにいくつか提案されている。Changら[3]は、アライメントを隠れ状態として、線形識別モデルと整数線形計画法に基づいて、アライメントと文間意味関係の同時学習を実現している。整数線形計画法は、アライメントの制約を導入するために用いられており、統語構造の係り受けの対応に関する制約を与えている。文間関係は、アライメントの制約を満たした上で、そのアライメントから得られるスコアの総和により、含意関係かどうかが判定される。また、Wangら[22]は、テキストから仮説への書き換え操作の系列に対して確率分布を与える条件付確率場のモデルを提案している。このモデルでは、編集操作が隠れ状態となり、各編集に対応する状態は正例集合と負例集合それぞれの中に含まれる。編集の状態は、正例集合、負例集合それぞれの中で遷移し、文間の意味関係は、正例、負例それぞれの編集の遷移系列の総和に基づいて決定される。双方の手法は、意味関係が2値であることが前提になっているため、多くの意味関係が扱えない点、また個々の状態の意味が明確でなく、構成的に意味関係を導いていない点において、提案モデルと異なる。

6 まとめ

本論文では、アライメントと文間の意味関係を同時に推定する文間関係認識モデルを提案した。具体的には、アライメントの有無、アライメントの間の意味関係、導出過程において得られる意味関係を表現するノードと、それらのノードに対して依存関係を与える因子から Factor Graph を構成し、条件付確率場によるモデル化をおこなうことで、アライメントと文間の意味関係の双方を学習・推定することを実現した。

提案モデルには、いくつかの課題が残されており、改善する必要がある。まず、現状では素性選択が十分ではないため、分析を進めることによって有用な手がかりを発見していきたい。また、現状のモデルでは、一方の文の要素を基準に文内の要素の対応関係および意味関係を導いているが、これは、編集操作のうち、挿入の操作がモデル化できていない。これを解決するためには、テキスト側からのアライメントと、仮説側からのアライメントの双方からの編集を考慮したモデルを設計する必要がある。また、アライメントに関する制約についても現状では導入できていないため、これらの問題を解決するモデルについて、今後検討していきたい。

謝辞

本研究は、文部科学省科研費(23240018)、文部科学省科研費(23700159)、文部科学省科研費(23700157)、およびJST戦略的創造研究推進事業さきがけの一環として行われた。

参考文献

- [1] Bond, F., Isahara, H., Fujita, S., Uchimoto, K., Kuribayashi, T. and Kanzaki, K.: Enhancing the Japanese WordNet, *Proc. of ACL-IJCNLP* (2009).
- [2] Bos, J. and Markert, K.: Recognising Textual Entailment with Logical Inference, *Proc. of EMNLP 2005*, pp. 628–635 (2005).
- [3] Chang, M., Goldwasser, D., Roth, D. and Srikumar, V.: Discriminative learning over constrained latent representations, *Human Language Technologies: The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics*, pp. 429–437 (2010).
- [4] Dagan, I. and Glickman, O.: The pascal recognising textual entailment challenge, *In Proceedings of the PASCAL Challenges Workshop on Recognising Textual Entailment* (2005).

- [5] Garrette, D., Erk, K. and Mooney, R.: Integrating Logical Representations with Probabilistic Information using Markov Logic, *Proc. of IWCS 2010*, pp. 1–10 (2010).
- [6] Hashimoto, C., Torisawa, K., Kuroda, K., Murata, M. and Kazama, J.: Large-Scale Verb Entailment Acquisition from the Web, *Proc. of EMNLP*, pp. 1172–1181 (2009).
- [7] Jijkoun, V. and de Rijke, M.: Recognizing Textual Entailment Using Lexical Similarity, *Proc. of the PASCAL Challenges Workshop on RTE* (2005).
- [8] Lakoff, G.: George Lakoff - Linguistics and Natural Logic, *Synthese*, Vol. 22, pp. 151–271 (1970).
- [9] MacCartney, B.: *Natural Language Inference*, PhD Thesis (2009).
- [10] MacCartney, B. and Manning, C. D.: Modeling semantic containment and exclusion in natural language inference.
- [11] Matsuyoshi, S., Murakami, K., Matsumoto, Y. and Inui, K.: A Database of Relations between Predicate Argument Structures for Recognizing Textual Entailment and Contradiction, *Proc. of ISUC*, pp. 366–373 (2008).
- [12] Ovchinnikova, E., Montazeri, N., Alexandrov, T., Hobbs, J. R., McCord, M. C. and Mulkar-Mehta, R.: Abductive Reasoning with a Large Knowledge Base for Discourse Processing, pp. 1–10 (2011).
- [13] Shima, H., Kanayama, H., Lee, C.-W., Lin, C.-J., Mitamura, T., Miyao, Y., Shi, S. and Takeda, K.: Overview of NTCIR-9 RITE: Recognizing Inference in TExt, *NTCIR-9 Proceedings* (2011).
- [14] Smith, D. A. and Eisner, J.: Dependency parsing by belief propagation, *In Proc. of EMNLP* (2008).
- [15] Sumida, A., Yoshinaga, N. and Torisawa, K.: Boosting Precision and Recall of Hyponymy Relation Acquisition from Hierarchical Layouts in Wikipedia, *Proc. of LREC* (2008).
- [16] Sutton, C. and McCallum, A.: An Introduction to Conditional Random Fields for Relational Learning, *Introduction to Statistical Relational Learning* (Getoor, L. and Taskar, B.(eds.)), MIT Press (2006).
- [17] Tatu, M., Iles, B., Slavick, J., Novischi, A. and Moldovan, D.: Cogex at the second recognizing textual entailment challenge, *Proceedings of the Second PASCAL Challenges Workshop on Recognising Textual Entailment*, pp. 104–109 (2006).
- [18] Tatu, M. and Moldovan, D.: COGEX at RTE3, *Proceedings of the ACL-PASCAL Workshop on Textual Entailment and Paraphrasing*, pp. 1–6 (2007).
- [19] Valencia, V. S.: *Studies on Natural Logic and Categorical Grammar*, PhD Thesis (1991).
- [20] van Benthem, J.: The Semantics of Variety in Categorical Grammars, pp. 33–55 (1988).
- [21] van Benthem, J.: Language in Action: Categories, Lambdas and Dynamic Logic (1991).
- [22] Wang, M. and Manning, C.: Probabilistic tree-edit models with structured latent variables for textual entailment and question answering, pp. 1164–1172 (2010).
- [23] Wang, R., Zhang, Y. and Neumann, G.: A Joint Syntactic-Semantic Representation for Recognizing Textual Entailment, *Text Analysis Conference TAC 2009 Workshop Notebook Papers and Results* (2009).
- [24] Yedidia, J., Freeman, W. and Weiss, Y.: Constructing free energy approximations and generalized belief propagation algorithms (2004).
- [25] 中川哲治: 隠れ変数を持つ条件付き確率場による依存構造木の評価極性分類, 情報処理学会研究報告, 自然言語処理研究会, 2009-NL-192.
- [26] 小谷通隆, 柴田知秀, 中田貴之, 黒橋禎夫: 日本語 Textual Entailment のデータ構築と自動獲得した類義表現に基づく推論関係の認識, 言語処理学会 第 14 回年次大会予稿集, pp. 1140–1143 (2008).