

Natural Logic と条件付確率場の融合による 構成的文間関係認識

渡邊 陽太郎^{†1,a)} 水野 淳太^{†1,b)} 岡崎 直観^{†1,†2,c)} 乾 健太郎^{†1,d)}

概要: 換言・含意・矛盾といった二文間の意味関係を推定する課題である文間関係認識においては、文間関係に影響を与える多様な言語現象を捉える必要がある。そのためには、個々の言語現象から導かれる意味関係から、文間の意味関係を構成的に導くことが必要不可欠である。本論文では、自然言語上での論理推論を実現する Natural Logic と、統計的識別学習手法である条件付確率場を融合した、構成的な文間関係認識手法を提案する。本手法は、二文間の要素のアライメントとそれらの意味関係を隠れ状態とし、文間の意味関係を弱教師情報として、Natural Logic の意味関係演算規則に整合する適切なアライメントを推定することを実現するものである。様々な言語現象を含む文間関係認識のためのデータセットを作成し、提案手法を評価した。その結果、提案手法にて文間関係から正しいアライメントの推定が可能であることを確認した。

キーワード: 含意関係認識, Natural Logic, 条件付確率場

Compositional Semantic Relation Recognition between Sentences by Combining Conditional Random Fields and Natural Logic

Abstract: In the task of recognizing semantic relations between sentences such as paraphrase, entailment and contradiction, RTE systems are required to consider various linguistic phenomena that affect semantic relations, and combine all of them appropriately to derive correct semantic relations. In order to do so, it would be effective to introduce compositionality to RTE models. In this paper, we propose a statistical compositional model for RTE that unifies discriminative learning framework and Natural Logic, logic over natural language. In the proposed model, alignment edits between sentences and its semantic relations are treated as hidden variables, and appropriate assignments of them are learned by semantic relations between sentences and compositional rules of Natural Logic. We evaluated the proposed model on a dataset which includes examples of various linguistic phenomena. The experimental results show that the proposed model has ability to estimate plausible alignments and its semantic relations from semantic relations between sentences.

Keywords: Recognizing Textual Entailment, Natural Logic, Conditional Random Fields

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

^{†1} 現在、東北大学大学院情報科学研究科

^{†2} 現在、科学技術振興機構 さきがけ

a) yotaro-w@ecei.tohoku.ac.jp

b) junta-m@ecei.tohoku.ac.jp

c) okazaki@ecei.tohoku.ac.jp

d) inui@ecei.tohoku.ac.jp

本語や中国語については、NTCIR-9 Recognizing Inference in TExt (RITE) [17] 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 [25]) 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], [19], [20], 重み付きアブダクション [16], 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 [10] に基づく文間関係認識手法を提案した [13]。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おり、分離することは適切ではなく、アライメントとその意味関係の双方を同時に扱うことが必要であると考えられる。

アライメントとその意味関係を同時に扱う文間関係認識のモデルを構築することを考えると、文の要素間に対して、アライメントとその意味関係の双方を付与したデータが必要となるが、あらゆる事例に対してそれらの情報を容易に

付与できるとは限らない。例えば、

(1) T 独身だからといって、必ずしも a 不幸ではない。

H 独身でも、不幸でない人も a いる b

上記の例は言い換えの例であるが、 T_a と H_a, H_b の間に明らかな意味関係は無いため、どのようなアライメントを選択すればよいかは自明ではない。そこで、人手で付与したアライメント情報を与えるのではなく、モデルによって正しい意味関係を導くようなアライメントを自動的に決定させることで、アノテーションの問題を解決することを考える。

本論文では、文間の意味関係を与えて、最適な文のアライメントとそれらの意味関係を学習する新たな文間関係認識手法を提案する。提案手法は、条件付確率場をベースとし、これに、構成的な意味関係の導出のために MacCartney ら [13] 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を導入する。モデルは、文間の意味関係から、Natural Logic の規則に整合するアライメントとそれらの意味関係を学習する。

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 節にて関連研究について述べ、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 Lakoff [10] 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 [22], [23] や Sánchez Valencia [21] 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 [13] により、排他的な関係が扱えるよう拡張された。例えば、 $\text{Stimpy is a cat} \models \text{Stimpy is not a poodle}$ のような関係である。ここでは、[12], [13] 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び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, \mid), 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

*1 これらの関係を表す記号は、MacCartney ら [13] とほぼ同一のものを用いている。

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 (\sqsupset) 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、 $r_i \bowtie r_j \Rightarrow r \subseteq \mathcal{R}$ である． $\equiv \sqsupset \sqsubset$ や、 $\sqsupset \wedge \Rightarrow$ のように、一つに関係が決定される場合もあれば、 $\bowtie \Rightarrow \cup \{\equiv, \sqsupset, \sqsubset, \# \}$ 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}．

3. Natural Logic と条件付確率場の融合による構成的文間関係認識モデル

文間関係認識の問題は通常、テキスト (T) と仮説 (H) が与えられた時に、この文対が持つ意味関係を認識する．それに対して、提案モデルでは文間の意味関係が与えられた時に、正しい文間関係が導かれるような適切なアライメントを学習することを主眼としている．これにより、未知の文対が与えられた時には、文の要素間のアライメントと文間関係の同時推定が可能となる．

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 [12], [13] により提案されている、Natural Logic に基づく意味関係および意味関係の演算規則を導入することによって、文の意味関係を認識する．提案する文間関係認識モデルは、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．編集操作は、置換 (Substitution)、削除 (Deletion)、挿入 (Insertion) の3種類からなり、文間の編集操作の集合によって文間のアライメントが表現される．それぞれの編集操作には、2節で述べた Natural Logic にて定義されている7種類の意味関係のいずれかが与えられる．文間の意味関係は、アライメントの局所的な意味関係から、文脈を考

慮した意味関係の射影規則、および意味関係の結合規則を用いて、構成的に導かれる．

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が推定される．ここで、アライメントとその意味関係、意味関係の導出過程で導かれる意味関係は隠れ変数として扱われるため、提案モデルは隠れ変数を持つことになる．隠れ変数を持つ対数線形識別モデルの最適化の一手法として、周辺尤度最大化がよく用いられる．提案モデルの学習にも、周辺尤度最大化を採用する．

文対が与えられた時に、文間関係を認識するためには最適なアライメントを求める必要があり、またパラメータを推定するためには可能なアライメントの候補を列挙する (正規化項の計算、周辺確率の計算) 問題を解く必要がある．そのために、提案モデルでは MacCartney ら [11] によって提案された MANLI アルゴリズムを、意味関係を含めた編集を扱え、N-best 解が得られるよう拡張したアルゴリズムを用いる．

3.1 モデル

提案する文間関係認識モデルにおいて、アライメントとその意味関係、および導出過程で得られる意味関係、最終的な文間意味関係の同時確率は以下の式により与えられる．

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

ここで、 $\mathbf{e} = \{e_i\}$ は編集を表現する変数であり、それぞれの編集 $e_i = \langle t, h \rangle$ は、 T の文節のインデックスの集合 t , H の文節のインデックスの集合から構成される． $t \neq \phi$ かつ $h \neq \phi$ の場合は置換、 $t \neq \phi$ かつ $h = \phi$ の場合は削除、 $t = \phi$ かつ $h \neq \phi$ の場合は挿入の操作に対応する． \mathbf{r}_e はアライメントの意味関係の集合を表し、要素 $r_{e_i} \in \mathbf{r}_e$ は、編集 e_i に対応する意味関係である． \mathbf{r}_e^P は、文脈を考慮した場合の各編集 e_i の意味関係を表現する変数の集合であり、downward-monotone、量化子のスコープ、条件文のスコープなどの特別な文脈において変化する意味関係の射影後の意味関係を表す．そして、 \mathbf{r}^C は、 \mathbf{r}_e^P の意味関係を結合する過程で得られる意味関係と最終的な文間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． $\mathbf{r}_e, \mathbf{r}_e^P, \mathbf{r}^C$ に含まれる各変数 r は、前述の7種類の意味関係を値にとる．

二文が与えられた時、文間の意味関係が、Natural Logic

^{*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 [12] を参照されたい．

で定義されているある特定の意味関係ラベル l となる確率は、以下の式により与えられる。

$$p(r_T^C = l | \mathbf{x}; \lambda) = \sum_{\langle \mathbf{e}, \mathbf{r}_e \rangle \in \mathcal{E}} \sum_{\mathbf{r}_e^P, \mathbf{r}_e^C: r_T^C = l} p(\mathbf{e}, \mathbf{r}_e, \mathbf{r}_e^P, \mathbf{r}_e^C | \mathbf{x}; \lambda) \quad (2)$$

式 (1) 中の Ψ_k は、アライメントや意味関係の結合に対してスコアリングをおこなう関数 (因子) である。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, H のアライメントを表現する編集操作の集合 e の各要素 e に対してスコア付けをおこなう因子であり、 $\Psi_A = \lambda \cdot f_A(e, \mathbf{x}_T, \mathbf{x}_H)$ と定義する。この因子は、編集操作の意味関係は考慮せず、文の要素間の置換、挿入、削除の操作に対してスコアを与える。この因子に与える情報として、表層の類似度や語彙知識を利用する。

アライメント意味関係因子 Ψ_S : ある編集 e の意味関係を決定するための因子であり、 $\Psi_S = \lambda \cdot f_S(e, r_e, \mathbf{x}_T, \mathbf{x}_H)$ と定義する。この因子についても、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 : 編集 e が出現している文脈を考慮し、 r_e から適切な意味関係へと射影するために用いる因子であり、 $\Psi_P = \lambda \cdot f_P(r_e, r_e^P, \mathbf{x}_T, \mathbf{x}_H)$ と定義する。この因子は、monotonicity (upward, downward, non) や、量化詞および条件文のスコープを考慮して、 r_e 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、 $\Psi_C = \lambda \cdot f_C(r_{i-1}^C, r_e^P, r_i^C, \mathbf{x}_T, \mathbf{x}_H)$ 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。この因子には、基本的には [12] にて定義されている意味関係の結合規則を用いる。ただし、意味関係の組み合わせによっては、一意に意味関係が定まらない場合がある。提案モデルでは、複数の意味関係が導かれる意味関係の組みに合わせについては、独立 (#) となるよう規則を変更している。

3.2 モデルの学習

提案モデルの学習では、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ことにより、モデルパラメータ λ を学習する。

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

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。

$$\frac{\partial \mathcal{L}}{\partial \lambda_k} = \sum_n \left(\frac{\partial}{\partial \lambda_k} \log \sum_{\langle \mathbf{e}, \mathbf{r}_e \rangle \in \mathcal{E}} \sum_{\mathbf{r}_e^P: r_T^C = l} \exp \left(\sum_k \Psi_k(\mathbf{e}, \mathbf{r}_e, \mathbf{r}_e^P, \mathbf{r}_e^C, \mathbf{x}) \right) - \frac{\partial}{\partial \lambda_k} \log Z(\mathbf{x}) \right) \quad (4)$$

ここで、アライメント e 、アライメントの意味関係 r_e 、射影後の意味関係の集合 r_e^P 、最終的な文間意味関係を除く意味関係の結合結果 $r^C \setminus r_T^C$ 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。このうち、 r_e^P と r^C は、 r_e が与えられると、 Ψ_P および Ψ_C に組み込まれた意味関係の射影規則、意味関係の結合規則から一意に決定される。提案モデルは隠れ変数を持つことから、式 (3) は凸関数とはならないため、大域的な最適解が得られる保証は無い。

式 (3) の最適化においては、アライメント因子 Ψ_A およびアライメント意味関係因子 Ψ_S のパラメータを学習する。その際、正規化項の偏微分から導かれる、ある編集操作と意味関係のペア $\langle e_i, r_{e_i} \rangle$ の周辺確率を求める必要がある。しかし、系列や木構造などとは異なり、句アライメントの問題は全ての可能なアライメントを考慮することは困難であり、周辺確率の計算に工夫を要する。提案手法では、含意関係認識のための句アライメントアルゴリズムである MANLI アルゴリズム [11] を拡張することにより、意味関係を含めた句アライメントの候補を列挙し、列挙したアライメント集合から得られる周辺確率を用いてパラメータを更新する。

3.3 アライメントの推論・正規化項の計算

提案モデルにおけるアライメントの推論は、二文 $\langle \mathbf{x}_T, \mathbf{x}_H \rangle$ およびモデルパラメータ λ が与えられた時に、最適なアライメントとその意味関係 $\langle e, \hat{r}_e \rangle$ を求める問題である。

$$\langle e, \hat{r}_e \rangle = \arg \max_{\langle \mathbf{e}, \mathbf{r}_e \rangle \in \mathcal{E}} \sum_{\langle e_i, r_{e_i} \rangle \in \langle \mathbf{e}, \mathbf{r}_e \rangle} \Psi_A(e_i, \mathbf{x}; \lambda) + \sum_{\langle e_i, r_{e_i} \rangle \in \langle \mathbf{e}, \mathbf{r}_e \rangle} \Psi_S(e_i, r_{e_i}, \mathbf{x}; \lambda) \quad (5)$$

ここで、 \mathcal{E} は、意味関係を含めた二文間の可能な編集の集合である。最適な句アライメントを求めるアルゴリズムとして、MacCartney らにより提案された MANLI アルゴリズム [11] がある。しかし、MANLI アルゴリズムは個々の編集に対して意味関係を与えることは想定されていない。そこで、MANLI アルゴリズムを拡張することにより、個々の編集に対して意味関係を与えた上で、可能なアライメントの中から最適なアライメントとその意味関係 $\langle e, \hat{r}_e \rangle$

Algorithm 1 アライメントの推論アルゴリズム

```

input
an example  $(\mathbf{x}_T, \mathbf{x}_H)$ 
number of iterations  $I$ 
max size of edits  $M$ 
number of N-bests  $N$ 
score difference  $\delta$ 
score function  $s(e)$ 
initialize
 $e_0 \leftarrow \phi$ 
 $\forall x_T \in \mathbf{x}_T \ e_0 \leftarrow e_0 \cup e(x_T, DEL, \square)$ 
 $\forall x_H \in \mathbf{x}_H \ e_0 \leftarrow e_0 \cup e(x_H, INS, \square)$ 
all alignments  $\mathcal{E} \leftarrow e_0$ 
while ( $iter < I$ ) do
  top alignments  $\mathcal{E}_{top}$ 
  max score  $score_{argmax}$ 
  repeat
    get top alignment  $e_{top}$  from  $\mathcal{E}$ 
    if  $s(e_{top}) > score_{argmax}$  then
       $score_{argmax} \leftarrow s(e_{top})$ 
    end if
     $\mathcal{E}_{top} \leftarrow \mathcal{E}_{top} \cup e_{top}$ 
  until  $s(score_{argmax}) - s(e_{top}) \geq \delta$ 
  get successors  $\mathcal{S}_i = \{e_i^s\}_i$  for  $e_i \in \mathcal{E}_{top}$ 
   $\mathcal{E} \leftarrow \mathcal{E} \cup_i \mathcal{S}_i$ 
end while
return  $\mathcal{E}$ 

```

を求める。

パラメータの最適化では、前述の通りアライメントの周辺確率を計算する必要がある。そのために可能な句アライメントを列挙する必要がある。提案手法では、可能なアライメントの N-best 解を求めることにより、正規化項の近似とする。

提案手法で用いるアライメントアルゴリズムを Algorithm 1 に示す。このアルゴリズムはまず、与えられた文対に対して、初期のアライメント e_0 を与え、可能な編集の変更を繰り返していくことによってアライメントを列挙する。ここで、可能な編集の変更とは、隣接する挿入および削除操作の結合、ある挿入・削除の編集のペアから置換の編集への置き換え、各編集の意味関係の変更のことを指す。

3.4 文間意味関係の推論

文間意味関係の推論では、アライメントの意味関係 r_e が与えられると、 Ψ_P と Ψ_C を用いて意味関係の射影および結合をおこなうことで残りの r_e^P および r_e^C を得る。これは、ハードな規則に相当し、意味関係の射影および意味関係の結合規則に合致する意味関係のみが、最終的な意味関

係として導かれる。提案モデルでは、前述の通り、 r_e が与えられれば、全ての変数の値が一意に定まるよう設計している。

4. 評価実験

4.1 データ

提案モデルの評価のために、様々な言語現象を含む文間関係認識のためのデータセットを新たに作成した。このデータセットは、同義語・反義語、上位下位関係、形容詞、量子子、言い換え、関係節、並列、否定など、様々な言語現象を含むように作成され、計 270 事例である。それぞれの事例に対して、同値 (B)、前向き含意 (F)、矛盾 (C)、その他 (I) のいずれかの関係、そして、Natural Logic の意味関係を含むアライメント情報を付与した。意味関係とアライメントの付与は一人の作業者によりおこなわれ、アライメントの意味関係から、文間の意味関係が導けるかどうかは、作業者確認していない。本実験では、現状の Natural Logic の規則で文間関係が正しく説明できる事例のみを対象として実験をおこなった (計 135 事例)。

4.2 実験設定

本実験の目的は、文間の意味関係から適切なアライメントが推定できるかどうかを検証することである。そこで、実験では学習とテストで同一のデータ (前述の 135 事例) を用いる。モデルで扱う Natural Logic の意味関係は 7 種類であるのに対し、データに対して付与されているラベルは 4 種類であり、意味関係の変換が必要となる。モデルの学習の際、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た。

提案手法の有効性を検証するため、以下の 3 種類の設定で比較実験をおこなった。

Initial Weight パラメータの初期値で解析を行った場合の性能を評価。

Alignment Supervised Natural Logic の意味関係付きのアライメントを直接教師あり学習する設定。文間の意味関係は直接は考慮しない。モデルの学習は、提案モデルと同じく対数線形識別モデルを適用し、文間関係の周辺尤度最大化の代わりに、意味関係付きのアライメントを予測する構造予測問題として学習をおこなう。本設定において最適化に用いる目的関数は、 $\mathcal{L}_\lambda = \sum_n \log p(e, r_e | x^n; \lambda)$ とした。

Weakly Supervised 提案手法。文間の意味関係から、周辺尤度最大化によりモデルを学習する。

学習時のパラメータの初期値は、 Ψ_P と Ψ_C に含まれる

表 1 提案モデルに用いた素性

因子	編集タイプ	素性名	Description
Ψ_A	DEL, INS	TYPE SIZE SAME_GA_IN_{T,H} SAME_CASE_IN_{T,H} {T,H}_CONTAINS_{H,T}_LEMMA POS_SEQ HEADPOS	編集タイプ 編集に含まれる文節数 DEL,INS 対象の文節がある述語のガ格であり, 他方の文に同一の表層でガ格になっている文節が存在するか DEL,INS 対象の文節が述語の項であり, 同一の格を持つ述語が他方の文に存在するか 原形が同一の形態素が他方の文節に存在するか DEL, INS 対象の文節の品詞列 DEL, INS 対象の文節の主辞の品詞
Ψ_A	SUB	TYPE SIZE NUM_SHARED_ARGS PARTICLE_SAME RESOURCE PARENT_NUM_SHARED_ARGS BOTH_HAVE_A_ROLE BOTH_HAVE_THE_SAME_ROLE HEAD_POS_SAME POS_SEQ_SAME EXACT_MATCH UNIGRAM_COSINE	編集タイプ 編集に含まれる文節数 述語間の対応である場合, 同一の表層をもつ項をいくつ共有しているか 助詞が同一であるか Japanese WordNet [1], Wikipedia から獲得された上位下位関係 [18], 動詞含意関係辞書 [6] 動詞の意味関係辞書 [15] にエントリがあるか 項間の対応である場合, それぞれを項を持つ述語が共有している項の数 項間の対応である場合, それぞれが述語の項になっているか 項間の対応である場合, 同一の格を持っているか T,H それぞれの主辞の品詞が一致しているか T,H それぞれの文節内にある形態素の品詞の系列が一致しているか T,H それぞれの文節内にある形態素の系列が一致しているか T,H それぞれの文節内にある形態素の Unigram レベルのコサイン距離が閾値以上か
Ψ_S	DEL, INS	SIZE HEAD_LEMMA HEAD_WORD_CLASS NEGATION	編集に含まれる文節数 編集に含まれる文節の主辞の原形 主辞の単語クラス 否定を表す単語が含まれているか
Ψ_S	SUB	SIZE HEAD_POS_PAIR HEAD_LEMMA_SAME POS_SEQ_SAME RESOURCE	編集に含まれる文節数 主辞の品詞対 主辞の原形が一致しているか T,H それぞれの文節内にある形態素の品詞の系列が一致しているか Japanese WordNet, Wikipedia から獲得された上位下位関係, 動詞含意関係辞書, 動詞の意味関係辞書にエントリがあるか
Ψ_P	-	MONOTONE_PROJ QUANTIFIER_PROJ CONDITION_PROJ	文節対が, upward-monotone であるか, downward-monotone であるか 量子子のスコープ内であれば, 量子子の種類, および対象の操作が量子子の番号の項であるか 条件文のスコープ内であれば, 対象の操作が条件内であるか, 帰結内であるか
Ψ_C	-	COMPOSITION_RULE	3 つの意味関係の組み合わせが, [12] にて定義されている意味関係結合規則に含まれているか

素性のパラメータについてはそれぞれ, 導かれる関係として正しい場合は 0.0, そうでない場合は -10.0 に設定した. アライメント因子 Ψ_A およびアライメント意味関係因子 Ψ_S に含まれる素性の重みについても, 一部に対しては初期値を設定している*3.

パラメータの更新は, アライメント因子 Ψ_A とアライメントの意味関係因子 Ψ_S に関係する素性のパラメータのみに対しておこない, 意味関係射影因子 Ψ_P と意味関係結合

因子 Ψ_C 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, イテレーション回数は 10 とした. なお, 最適化の際, 正則化は適用していない.

アライメントアルゴリズムに関して, イテレーション回数は 40, 周辺確率の計算のための N-best 数は 10 とした. また, 各編集に対して与える意味関係を制限した. 具体的には, 置換の操作に対しては同値 (\equiv), 前向き含意 (\sqsubset), 後ろ向き含意 (\sqsupset), 否定 (\wedge), 交代 (\imath) の 5 種類, 削除は前向き含意のみ, 挿入は後ろ向き含意のみをとるよう探索空間を限定した.

本評価実験に用いた素性を表 1 に示す.

*3 紙面の都合上, 本実験で設定した全ての素性の初期値を掲載することは困難である. 例を挙げると, Ψ_A の PARTICLE_SAME 素性に対応する重みに 0.2, Ψ_S の RESOURCE に関して, 反義語であれば \imath, \wedge の意味関係に対応する素性の重みを 1.0 などとしている.

表 2 Closed Test の結果

	Alignment (Unlabeled)			Alignment (Labeled)			Sem. Rel.
	Prec.	Rec.	F1	Prec.	Rec.	F1	Acc.
Initial Weight	62.9	77.5	69.5	59.8	73.7	66.0	34.8
Alignment Supervised	73.3	70.8	72.0	66.8	64.5	65.6	53.3
Weakly Supervised	71.8	69.2	70.5	64.1	61.9	63.0	76.3

表 3 文間関係ラベルごとの性能

	B			F		
	Prec.	Rec.	F1	Prec.	Rec.	F1
Initial Weight	66.7 (8/12)	28.6 (8/28)	40.0	56.4 (22/39)	42.3 (22/52)	48.3
Alignment Supervised	76.5 (13/17)	46.4 (13/28)	57.8	50.0 (45/90)	86.5 (45/52)	63.4
Weakly Supervised	100.0 (14/14)	50.0 (14/28)	66.7	74.2 (49/66)	94.2 (49/52)	83.5
	C			I		
	Prec.	Rec.	F1	Prec.	Rec.	F1
Initial Weight	80.0 (4/5)	9.8 (4/41)	17.4	16.5 (13/79)	92.9 (13/14)	28.0
Alignment Supervised	75.0 (9/12)	22.0 (9/41)	34.0	21.4 (3/14)	21.4 (3/14)	21.4
Weakly Supervised	73.3 (33/45)	80.5 (33/41)	76.7	77.8 (7/9)	50.0 (7/14)	60.9

4.3 評価尺度

提案手法を、以下の3つの評価尺度を用いて評価する。

Alignment (Unlabeled) システムの各アライメントの出力が、正解データと同じ範囲に付与されている場合に正解とする。ただし、アライメントの意味関係は一致していなくてもよい。Precision, Recall, F 値で評価する。

Alignment (Labeled) システムの各アライメントの出力が、正解データと同じ範囲に付与され、アライメントの意味関係も一致している場合に正解とする。同じく、Precision, Recall, F 値で評価する。

Sem. Rel. 文間関係認識の性能。正解率で評価する。

4.4 前処理

各文には、形態素解析 (MeCab [9]), 係り受け解析 (CaboCha [8]), 述語項構造解析 [29], 事実性解析 [14], 用言および名詞の評価極性辞書 [26], [28] を用いた評価極性解析を適用している。

4.5 実験結果

アライメントと文間関係の認識結果を表2に、文間関係ごとの性能を表3に示す。表2からわかるように、初期値を用いて解析をおこなっても、ある程度のアライメントの性能が得られていることがわかる。これは、同一の表現になっている文節対がデータ内に多く存在するためであり、これらは容易に意味関係を導ける (同値:≡) からである。しかし、文間関係の認識については十分な性能が得られていない。その理由としては、表3からわかるように、その他 (I) を特に多く出力していることがわかる。これは、初期

値を用いた場合、置換の操作を選択しにくい傾向があり、結果として挿入と削除の双方の操作が含まれる事例が多く出力される。これらはそれぞれ、前向き含意、後ろ向き含意の意味関係を導くが、これらの意味関係を結合すると関係が一意に定まらないため、独立 (#) の意味関係が導かれることになる。一方で、提案手法は、初期値を用いた場合と比較すると、アライメントの性能については大幅な改善は見られないが、文間関係の認識性能については大幅に向上している。この理由として、表層の違いがあっても対応付けるように学習が進んだこと、矛盾関係になっているアライメントを正しく学習できたことが挙げられる。

事前に付与したアライメント情報を用いて教師あり学習をおこなった場合、提案手法と比較してアライメントの性能は若干優れているものの、文間の意味関係の推定性能では、提案手法に劣る結果となった。特に矛盾の推定性能が悪く、Recall に関して大幅な差がみられる。Natural Logic の規則から文間関係を導く場合、正しいアライメントは複数存在することが多々ある (例えば、複数文節の挿入、削除を分解しても、これらは正しい意味関係を導くことが多い)。しかし、アライメントの教師あり学習の設定では、付与されているアライメントのみを正解とみなすため、正解の意味関係を導く (尤もらしい) 他のアライメントが不正解とされて、学習がおこなわれる。この影響が、アライメントの推定性能に影響しているものと考えられる。

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 [24] 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。

日本語の含意関係認識に関する既存研究では、増田ら [30] が Natural Logic に基づく日本語の含意関係認識手法を提案している。増田らの手法は、文節単位での意味関係を EDR 電子化辞書の上位下位関係を用いて導出し、単調性を考慮して文全体の意味関係を導出している。Natural Logic と機械学習手法を組み合わせた先行研究としては、渡邊ら [27] が Natural Logic と条件付確率場を統合した文間関係認識モデルを提案している。この手法は、アライメントとそれらの意味関係、および意味関係の結合過程を一つの Factor Graph を用いて表現し、文間関係を導くものであるが、アライメントのモデル化が適切におこなわれていないため、妥当でないアライメントが選択される可能性があるという問題が残されている。

6. まとめ

本論文では、Natural Logic と条件付確率場を融合することにより、文間の意味関係から二文の要素間のアライメントを学習可能な、新たな文間関係認識モデルを提案した。提案手法では、アライメントとその意味関係を隠れ状態とし、文間の意味関係を弱教師情報として、周辺尤度最大化によりアライメントの学習を実現した。また、最適な句アライメントを求めるため、そして学習時に利用する周辺確率の計算に利用するアライメントの候補集合を得るために、含意関係認識のための句アライメントである MANLI アルゴリズムリズムを拡張することで、意味関係を含めたアライメントの列挙、および N-best 解の導出を実現した。評価実験では、提案モデルによって Natural Logic の規則

と正しい文間の意味関係から、アライメントが推定できることを確認した。

今後の課題は、提案モデルの頑健性の向上である。現在のモデルは、文節単位の書き換えで文間の意味関係が説明できることを仮定したのになっているため、それに該当しない事例（例えば、構造的に大きく変わる言い換えや、文中で親子関係や順序関係などが表現されている場合）が学習事例に含まれていると、アライメントの推定性能が著しく低下するという現象が確認されている。この問題への対処方法としては、言い換え規則の導入による構造的な言い換えへの対応、文内で述べられている関係に対する編集の導入などが考えられる。これらの問題に、今後取り組んでいく予定である。

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, *Proceedings of the 7th Workshop on Asian Language Resources, ACL-IJCNLP 2009*, pp. 1–8 (2009).
- [2] Bos, J. and Markert, K.: Recognising Textual Entailment with Logical Inference, *Proceedings of Human Language Technology Conference and Conference on Empirical Methods in Natural Language Processing (HLT/EMNLP)*, 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, *Proceedings of the Ninth International Conference on Computational Semantics (IWCS 2011)*, pp. 105–114 (2011).
- [6] Hashimoto, C., Torisawa, K., Kuroda, K., Murata, M. and Kazama, J.: Large-Scale Verb Entailment Acquisition from the Web, *Proceedings of the 2009 Conference on Empirical Methods in Natural Language Processing (EMNLP 2009)*, pp. 1172–1181 (2009).
- [7] Jijkoun, V. and de Rijke, M.: Recognizing Textual Entailment Using Lexical Similarity, *Proceedings of the PASCAL Challenges Workshop on RTE* (2005).

- [8] Kudo, T. and Matsumoto, Y.: Japanese Dependency Analysis using Cascaded Chunking, *CoNLL 2002: Proceedings of the 6th Conference on Natural Language Learning 2002 (COLING 2002 Post-Conference Workshops)*, pp. 63–69 (2002).
- [9] Kudo, T., Yamamoto, K. and Matsumoto, Y.: Applying Conditional Random Fields to Japanese Morphological Analysis, *Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing*, pp. 230–237 (2004).
- [10] Lakoff, G.: George Lakoff - Linguistics and Natural Logic, *Synthese*, Vol. 22, pp. 151–271 (1970).
- [11] MacCartney, B., Galley, M. and Manning, C.: A Phrase-Based Alignment Model for Natural Language Inference, *Proceedings of the 2008 Conference on Empirical Methods in Natural Language Processing*, pp. 802–811 (2008).
- [12] MacCartney, B.: *Natural Language Inference*, PhD Thesis (2009).
- [13] MacCartney, B. and Manning, C. D.: Modeling semantic containment and exclusion in natural language inference, *Proceedings of the 22nd International Conference on Computational Linguistics (Coling 2008)*, pp. 521–528 (2008).
- [14] Matsuyoshi, S., Eguchi, M., Sao, C., Murakami, K., Inui, K. and Matsumoto, Y.: Annotating Event Mentions in Text with Modality, Focus, and Source Information, *Proceedings of the 7th International Language Resources and Evaluation (LREC '10)* (2010).
- [15] Matsuyoshi, S., Murakami, K., Matsumoto, Y., and Inui, K.: A Database of Relations between Predicate Argument Structures for Recognizing Textual Entailment and Contradiction, *Proceedings of the 2nd International Symposium on Universal Communication (ISUC2008)*, pp. 366–373 (2008).
- [16] 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, *Proceedings of the Ninth International Conference on Computational Semantics (IWCS 2011)*, pp. 225–234 (2011).
- [17] 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, *Proceedings of NTCIR-9 Workshop Meeting*, pp. 291–301 (2011).
- [18] Sumida, A., Yoshinaga, N. and Torisawa, K.: Boosting Precision and Recall of Hyponymy Relation Acquisition from Hierarchical Layouts in Wikipedia, *Proceedings of the 6th International Language Resources and Evaluation (LREC'08)*, pp. 2462–2469 (2008).
- [19] Tatu, M., Iles, B., Slavick, J., Novischi, A. and Moldovan, D.: Cogex at the second recognizing textual entailment challenge, pp. 104–109 (2006).
- [20] Tatu, M. and Moldovan, D.: COGEX at RTE3, *Proceedings of the ACL-PASCAL Workshop on Textual Entailment and Paraphrasing*, pp. 22–27 (2007).
- [21] Valencia, V. S.: *Studies on Natural Logic and Categorical Grammar*, PhD Thesis (1991).
- [22] van Benthem, J.: The Semantics of Variety in Categorical Grammars, pp. 33–55 (1988).
- [23] van Benthem, J.: Language in Action: Categories, Lambdas and Dynamic Logic (1991).
- [24] Wang, M. and Manning, C.: Probabilistic tree-edit models with structured latent variables for textual entailment and question answering, pp. 1164–1172 (2010).
- [25] 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).
- [26] 小林のぞみ, 乾健太郎, 松本裕治, 立石健二, 福島俊一: 意見抽出のための評価表現の収集, *自然言語処理*, Vol. 12, No. 2, pp. 203–222 (2005).
- [27] 渡邊陽太郎, 水野淳太, 岡崎直観, 乾健太郎: 隠れ変数を持つ識別モデルによる文間意味関係の学習, *言語処理学会第18回年次大会発表論文集* (2012).
- [28] 東山昌彦, 乾健太郎, 松本裕治: 述語の選択選好性に着目した名詞評価極性の獲得, *言語処理学会第14回年次大会論文集*, pp. 584–587 (2008).
- [29] 渡邊陽太郎, 浅原正幸, 松本裕治: 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, *人工知能学会論文誌*, Vol. 25, No. 2, pp. 252–261 (2010).
- [30] 増田涼良, 杉本徹: Natural Logic を用いた日本語テキストの含意関係認識, *第26回人工知能学会全国大会 (JSAI 2012)* (2012).