

B4IM2035

## 修士論文

文脈依存選択嗜好モデルの共参照解析への適用

中山周

2017年2月10日

東北大学 大学院  
情報科学研究科 システム情報科学専攻

本論文は東北大学 大学院情報科学研究科 システム情報科学専攻  
修士 (情報科学) 授与の要件として提出した修士論文である。

中山周

審査委員：

乾 健太郎 教授 (主指導教員)

篠原 歩 教授

木下 哲男 教授

岡崎 直観 准教授 (副指導教員)

# 文脈依存選択選好モデルの共参照解析への適用\*

中山周

## 内容梗概

共参照解析とは、文章内の語句がある世界における同一の指示対象を指しているか否かを解析する、自然言語処理における重要な研究タスクのひとつである。これまで、選択選好と呼ばれる単語間の意味的な制約条件が、共参照解析を行う上で大きな手がかりとなることが知られていた。そのため、既存研究の多くは、「単語間の意味的な制約が名詞の意味クラスにのみ依存する」と仮定し、二つの単語間の選択選好を扱ってきた (e.g., eat の目的語は「食べ物」に関する語句を取りやすい)。しかしながら、実際の文章内には、文脈によっても選択選好性が変容する場合がある (e.g., 「殺した人」は「殺された人」よりも arrest の目的語になりやすい)。また、文脈を考慮した名詞の選択選好性を扱う先行研究も存在するが、モデルの構造上、適用可能な単語の出現パターンが限定されるという問題があった。

本研究では、単語自体の意味クラスだけでなく、単語が文章内でどのように言及されてきたかということも考慮した選択選好モデルを提案する。さらに、単語と、単語間の関係性を表す意味表現をベクトル空間上で表現することで、文脈により変容する単語の意味表現の構成的な計算を可能にする。評価実験では、提案モデルが文脈依存選択選好性を獲得しているかどうかの検証を行った。

## キーワード

自然言語処理, 共参照解析, 選択選好, 照応解析

---

\*東北大学 大学院情報科学研究科 システム情報科学専攻 修士論文, B4IM2035, 2017年2月10日.

# 目次

1	はじめに	1
2	関連研究	3
2.1	選択選好的知識を用いた共参照解析	3
2.2	文脈を考慮した選択選好的知識を用いた共参照解析	3
3	文脈依存選択選好モデル	5
3.1	ニューラルネットワークを用いた文脈依存選択選好モデル	5
3.2	DCS Vector	6
3.3	DCS Vector を用いた文脈依存選択選好モデルの構築	9
4	評価実験	10
4.1	データセットの生成	10
4.2	提案モデルの評価実験	11
4.2.1	評価タスク	11
4.2.2	実験設定	12
4.2.3	実験結果	13
5	おわりに	16
	謝辞	17

## 目次

1	Inoue らのモデルのネットワーク構造例 . . . . .	6
2	依存構造の例 . . . . .	7
3	DCS Tree の例 . . . . .	7
4	DCS Tree を単語ベクトル、意味役割行列で表した木構造の例 . .	8
5	メンション部を他の DCS Tree で置き換えた DCS Tree . . . . .	9

## 表目次

1	提案モデルの実験結果 (PD) . . . . .	13
2	提案モデルの実験結果 (CSPD, CSPD-X) . . . . .	14

# 1 はじめに

自然言語処理は、人間が使う日本語や英語などの自然言語をコンピュータで処理する技術に関する研究分野である。Web 等の発展や計算機器の性能向上に伴い、大量のテキストデータを収集し、高速に処理できるようになった近年において、その重要性がますます注目されている。自然言語処理に必要な技術は数多くあるが、その中でも自然言語処理の基盤技術となる形態素解析や構文解析など統語構造を解析する技術は非常に重要であり、盛んに研究されてきた。一方で、自然言語をより正しく処理するためには、述語項構造解析や共参照解析と呼ばれる、単語間の意味的な関係を解析する技術も非常に重要である。

意味解析で重要な研究タスクの一つである 共参照解析 は、文章内の複数の単語や句が同一の指示対象を指しているか否かを推定するタスクである。例えば、例文 (1) が与えられた時、“ $it_{(?)}$ ” に対して、“ $banana_{(j)}$ ” という名詞が、ある世界において同一の物体を指示しているかどうかということを解析する。

(1) A monkey<sub>(i)</sub> gets a banana<sub>(j)</sub>, and eats it<sub>(?)</sub>.

このように、同一の物体を指示する単語間関係を共参照関係と呼び、共参照関係を構成する単語句をメンションと呼ぶ。共参照関係を自動解析できるようになれば、情報抽出や質問応答、機械翻訳など自然言語処理の応用技術に活用することができる。

先程の例で、“ $it_{(?)}$ ” と “ $banana_{(j)}$ ” は共参照関係にあるが、“ $it_{(?)}$ ” と “ $monkey_{(i)}$ ” は共参照関係にないということは、人間は文を読んですぐに判断することができる。これは、“eat” の目的語としてふさわしいのは、“ $monkey_{(i)}$ ” のような一般に食さない物ではなく、“ $banana_{(j)}$ ” のような食べ物であるという知識があるためだと考えられる。このような、主語や目的語となりうる単語が述語によって制限される選択選好という言語現象があり、共参照解析にも利用されてきた。

共参照解析において選択選好が有効であることは知られており、多くの研究で利用されてきた。しかし、単なる選択選好だけでは共参照を解析するにあたって十分でない場合がある。例えば、例文 (2) において、“ $him_{(?)}$ ” に対して、“ $John_{(i)}$ ” という単語は共参照関係にあるが、単に動詞だけの選択選好だけを考えると “ $arrest$ ”

の目的語は、人物である "John<sub>(i)</sub>" にも "Bob<sub>(j)</sub>" にもなりうる。

(2) John<sub>(i)</sub> killed Bob<sub>(j)</sub>. Police arrested him<sub>(?)</sub>.

この場合、動詞だけの選択選好ではなく、選択選好対象の単語がどのように言及されてきたのかも考慮するほうが自然である。例文 (2) に当てはめて考えると、「kill された人」よりも「kill した人」のほうが "arrest" されやすいため、"arrest" の目的語は "John<sub>(i)</sub>" であると判定できる。

我々は、ある単語が文章内でどのように言及されてきたかという文脈情報により選好性が変容するような選択選好（文脈依存選択選好）が共参照解析に有効であると考えた。こうした背景のもと、本研究では文脈を考慮した選択選好モデル（文脈依存選択選好モデル）を提案し、このモデルが共参照解析に有効であるかどうかを検証する。

本論文の構成は以下の通りである。まず 2 節において、選択選好的知識を利用した共参照解析の先行研究について述べる。次に、3 節において、本研究で提案するモデルのベースとなる、既存の文脈依存選択選好モデルについて述べる。さらに、既存の文脈依存選択選好モデルの欠点に言及し、その改善点に基づいた提案モデルについて述べる。4 節では、提案モデルが文脈に依存した選択選好性を捉えられているかどうかについて検証する。最後に、5 節にて本論文のまとめを述べる。



## 2 関連研究

本節では、まず文脈に依存しない選択選好的知識を用いた共参照解析に関する研究について概要を説明する。その後、本研究と類似した研究として、文脈を考慮した選択選好的知識を用いた共参照解析に関する研究についても説明し、本研究との違いを明確にする。

### 2.1 選択選好的知識を用いた共参照解析

共参照解析で選択選好性を扱う研究では、述語と項の共起用例辞書や、コーパスから獲得した述語と項の共起度を、知識ベースとして利用するアプローチが主流である。

選択選好的知識として使われている代表的な知識データの一つに、FrameNet[1]がある。FrameNet 自体は選択選好を目的として作られたものではないが、選好性が顕著に現れる、述語と項の関係がアノテーションされており、一種の選択選好的な知識として利用することができる。FrameNet は、例えば、動詞に対する主語や目的語がどんな単語であるかがアノテーションされている。このアノテーションを辞書として使い、共参照関係のある単語としてふさわしいかどうかを述語と項の関係から制限することで、ある種の選択選好的知識として共参照解析に利用する [2, 3]。

しかし、FrameNet のような、述語が取りうる項が列挙されている辞書では、その述語の選好性を、項を選ぶか否かの二値でしか表現できない。より柔軟に選好性を表現するために、述語と項の共起度をあらかじめコーパスから算出しておき、共参照解析の素性として利用する研究も多い [4, 5]。

### 2.2 文脈を考慮した選択選好的知識を用いた共参照解析

共参照解析で選択選好性を扱う研究では、ひとつの述語に対する項の選好性を考えるのが一般的である。しかし、本論文の冒頭で述べたように、ある述語に対する項が、それより以前に出現した述語項によって選好性が変容する場合がある。そこで、二つの述語項間関係を考慮することで、他の述語に依存する選択選好も

扱えるようにした先行研究が存在する。Peng らは、Gigaword Corpus<sup>1</sup> 等の大規模コーパスから述語項の共起頻度をあらかじめ計算しておくことで、述語項間の選択選好的知識を獲得する [6]。共参照関係を推定する段階では、ILP Solver を利用し、述語項間の共起頻度をひとつの制約条件として利用する。

また、Inoue らは、大規模コーパスから得た述語項間の因果関係知識に基づき、共参照解析対象の単語周辺の述語間の関連性を論理推論により解析することで、共参照解析を行う [7]。

上記で述べた述語項間の共起関係を選択選好的知識として用いて共参照解析を行う研究では、そのどちらも述語や項を離散的な意味クラスとして表現している。つまり、語の完全一致により共起関係を計算しているため、解析時に膨大な知識ベースを用意しておく必要があり、さらにデータスパースネスの問題が顕著であると予想される。一方で、本研究では、単語をベクトル空間上に表現することで、知識ベースの軽量化や、未知のテスト事例に対してより頑健なモデルとなることを目指す。

---

<sup>1</sup><https://catalog.ldc.upenn.edu/LDC2003T05>

### 3 文脈依存選択選好モデル

本研究は、文脈により変容する単語の意味を考慮した選択選好モデルを構築する。構築するモデルは、柔軟かつ構成的な意味計算を可能にするために、分散表現に基づく手法を導入する。選択選好は、単語の意味と、主語や目的語などの単語間の関係性 (意味役割) によって選好性が変化すると考えられるため、構築するモデルもこれらの情報を取り入れられるように設計する。まず、単語ベクトルと主語・目的語の構造をモデル化することで文脈を考慮した選択選好を表現した Inoue らのモデルについて述べる。次に、単語の意味と意味役割から意味表現を構成的に計算することが可能なモデルとして、Tian らの DCS Vector を導入し、文脈依存選択選好としての意味表現を得られるようなモデルの設計について説明する。

#### 3.1 ニューラルネットワークを用いた文脈依存選択選好モデル

Inoue らは、(主語, 述語) の組、または (主語, 述語, 目的語) の組に対して、主語もしくは目的語を、他の (主語, 述語) の組、または (主語, 述語, 目的語) の組に置き換えることが可能な構造の文脈依存選択選好モデルを提案している [8]。Inoue らのモデルでは、二つの述語項の関係を単語ベクトルを用いたフィードフォワード型ニューラルネットワークで表現しており、選択選好性の獲得と単語ベクトルの学習を同時に行う。例文 (2) を Inoue らのモデルで表現した例を図 1 に示す。

(2) John<sub>(i)</sub> killed Bob<sub>(j)</sub>. Police arrested him<sub>(?)</sub>.

例文 (2) において、"him<sub>(?)</sub>" と共参照関係にある "John<sub>(i)</sub>" について考える。まず、「John が主語」「kill が述語」「Bob が目的語」であることを、それぞれの単語ベクトルを連結することで表現する (図 1 の g)。次に、「Police が主語」「arrest が述語」「him が目的語」であることを、それぞれの単語ベクトルを連結することで表現する。ここで、"him" と「Bob を殺した John」が共参照関係にあることから、それぞれのベクトルが同じ意味を表しているとして、"Bob を殺した John" を線形変換をした上で "him" と置き換える (図 1 の g')。このようにして得たベクトルに隠れ層を 1 層加え、最終的に選択選好性スコアを算出する。

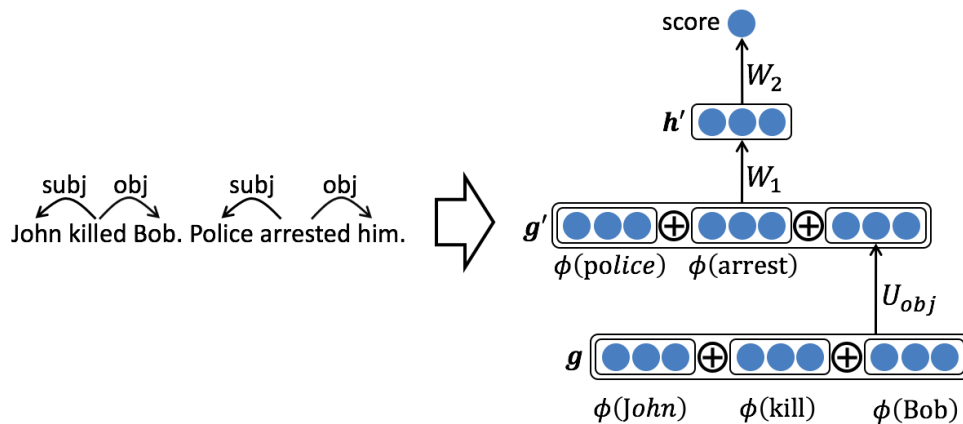


図 1: Inoue らのモデルのネットワーク構造例

### 3.2 DCS Vector

Inoue らのモデルでは、単語をベクトルで表すことで柔軟な意味表現を得ることができる。しかし、(主語, 述語) の組や (主語, 述語, 目的語) の組で表現される構造になっている場合にしか選択選好性のスコアを計算することができない。例えば、例文 (3) で、"there<sub>(?)</sub>" と共参照関係にある語として "restaurant<sub>(i)</sub>" と "store<sub>(j)</sub>" が考えられるが、"store<sub>(j)</sub>" よりも "restaurant<sub>(i)</sub>" と共参照関係にあると考えるほうが自然である。"restaurant<sub>(i)</sub>" が "new" で修飾される形で言及されていることが、人間がこのような判断をするひとつの大きな手がかりになっていると考えられるが、Inoue らのモデルではこのような構造の選択選好性スコアを計算することはできない。

(3) There is a new [restaurant<sub>(i)</sub>] next to a grocery [store<sub>(j)</sub>]. I will go there<sub>(?)</sub>.

項に対する言及は、"new restaurant" のような形容詞修飾以外にも多様な表現があると予想されるため、主語や目的語などの単語・意味役割の組み合わせパターンすべてに対してモデルを構築することは現実的ではない。

そこで、本研究で提案するモデルとして、文や句を構成的に計算できる枠組みを導入する。単語と意味役割をそれぞれベクトル空間上で表現しつつ、それらの

構成的操作を可能にすることで、任意の単語・意味役割の組み合わせを表現することを可能にする。

これを実現するために、依存構造に基づき、単語と意味役割をベクトル空間上に表現することで構成的な計算を可能にする DCS Vector[9] を導入する。依存構造とは、文内の単語間の係り受け関係を表したものである (図 2)。このとき、主語 (subj) や目的語 (obj) など単語間の依存関係のことを意味役割という。DCS Vector は、依存構造を DCS Tree として表現したものを構成的に計算可能にする。DCS Tree とは、依存構造に基づく構成的意味表現を目的とした木構造である (図 3)。




図 2: 依存構造の例




図 3: DCS Tree の例

DCS Vector は、単語をベクトル、意味役割を行列として表現することで、ある単語がどのように言及されたのかを依存構造から計算することを可能にする。具体的には、単語の意味を単語ベクトルとして表現し、単語が持つ潜在的な意味クラスの集合から、特定の意味クラスに写像する行列 (意味役割行列) により、依存構造を考慮した意味を計算する。例えば、"John killed Bob." を DCS Tree 上で表現すると図 4 のようになり、"him" の意味表現は式 1 のように計算される。

$$\mathbf{v}_{john} := (\mathbf{v}_{bob}M_{ARG}M_{COMP}^{-1} + \mathbf{v}_{kill})M_{SUBJ}M_{ARG}^{-1} + \mathbf{v}_{john} \quad (1)$$

式 1 では、 $\mathbf{v}_{bob}M_{ARG}M_{COMP}^{-1}$  で「何かの目的語である Bob」というベクトルが得られ、 $(\mathbf{v}_{bob}M_{ARG}M_{COMP}^{-1} + \mathbf{v}_{kill})M_{SUBJ}M_{ARG}^{-1}$  で「Bob を殺した何か」というベクトルが得られる。さらに、John 自体のベクトルを加算することで、「Bob を殺した John」という意味を表すベクトルが得られる。




図 4: DCS Tree を単語ベクトル、意味役割行列で表した木構造の例

一般に DCS Vector は、DCS Tree 上の単語  $x$  に対して、以下の式 2 で定義される。

$$\mathbf{v}_x := \mathbf{v}_x + \frac{1}{n} \sum_{i=1}^n \mathbf{v}_{y_i} M_{L_i} M_{P_i}^{-1} \quad (2)$$

ただし、 $n$  は  $x$  の子の数、 $y$  は  $x$  の子、 $M_L, M_P^{-1}$  は  $x, y$  間のそれぞれの意味役割を表す行列である。

単語ベクトルと意味役割行列の学習は、DCS Tree 上の任意の単語  $x, y$  に対して、 $x$ 、及び  $x$  から  $y$  に至るまでの意味役割列から、 $y$  を予測するように学習する。具体的には、DCS Tree 上の任意の単語  $x, y$  に対して得られるパスを、式 3 を用いて確率値で表し、最尤推定により学習する。

$$p(\boldsymbol{\theta}) = \sigma(\mathbf{v}_x M_P M_L^{-1} \dots M_K M_N^{-1} \cdot \mathbf{v}_y) \quad (3)$$

ただし、 $\sigma$  はシグモイド関数で、パラメータ  $\boldsymbol{\theta}$  は、ある DCS Tree の任意の単語  $x, y$  の単語ベクトル  $\mathbf{v}_x, \mathbf{v}_y$  と、単語間の意味役割の列  $M_P M_L^{-1} \dots M_K M_N^{-1}$  である。

また、NCE (Noise-contrastive estimation[10]) に基づき、学習データから得られる正例から自動生成した負例を学習に利用することで、効率的に学習する。コーパスから得られるパス  $x, P_1, L_2, \dots, P_{2i}, L_{2i+1}, y$  を正例としたとき、 $P_i, L_i$  または  $y$  を、コーパス全体の出現頻度分布に基づきランダムに入れ替えることで、負例を生成する。

### 3.3 DCS Vector を用いた文脈依存選択選好モデルの構築

Tian らのモデルでは、単語  $x$  から単語  $y$  までたどるパスから、 $y$  を予測するように学習する。本研究では、文脈に依存した選択選好性を獲得するために、共参照関係にある語を根にした DCS Tree 同士を予測するように学習する。

例文 (2) を例に挙げて説明する。通常の DCS Vector では、"police arrest" の目的語として "him" を予測するように学習する。ここで、"him" が「Bob を殺した John」であることを表現するために、Inoue らのモデルと同様に、"him" の単語部分に "John killed Bob" を挿入した DCS Tree を考える (図 5)。この木を Tian らと同様に学習することで、文脈を考慮した選択選好性を獲得する。

(2) John<sub>(i)</sub> killed Bob<sub>(j)</sub>. Police arrested him<sub>(?)</sub>.

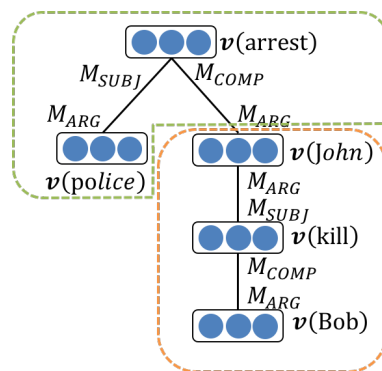


図 5: メンション部を他の DCS Tree で置き換えた DCS Tree

学習は Tian らと同様に行う。ただし、共参照関係にある DCS Tree 同士の内積が大きくなるよう学習するために、式 3 における意味役割列は必ず共参照関係にある単語を含むようにする。

## 4 評価実験

本節では、本研究で提案したモデルの評価実験について述べる。

まず、評価実験のためのデータセット生成について述べる。次に、提案モデルが、文脈に依存する選択選好性を正しく捉えることができるのかを確認するために行った評価実験について述べる。

### 4.1 データセットの生成

モデルの学習に用いるデータには、文章と文章内の単語に対して、共参照関係と依存関係の情報がアノテーションされている必要がある。このようなデータを大量に獲得するために、本研究では ClueWeb 12<sup>2</sup> からデータセットの生成を行う。ClueWeb 12 は、ウェブから取得した約 2.2 億文書、6.9 億文からなる大規模コーパスである。ClueWeb 12 自体は共参照関係や依存構造の情報は付与されていないため、Stanford CoreNLP [11] を用いて依存構造解析及び共参照解析を行う。Stanford CoreNLP による共参照解析結果には誤りが含まれているため、以下のヒューリスティクスに基づく条件をすべて満たす解析結果のみ抽出することで解析誤りを取り除く。

1. 共参照関係が文内で閉じている
2. メンションの主辞の文字列が完全に一致する

大野ら [12] によれば、このフィルタリングによって、共参照解析の精度が 71.0% から 87.0% に向上する。このフィルタリング処理により得たデータから、以下の手順に従い DCS Tree のパスを生成する。

1. 共参照関係にある複数のメンションから、二つの組み合わせを取りメンションペアを作成する
2. メンションペアのうち、元の文において先に出現したメンションをコンテキストメンション、後に出現したメンションをターゲットメンションとし、それぞれのメンションに対して元の文から DCS Tree を作成する

---

<sup>2</sup><http://lemurproject.org/clueweb12/>



3. ターゲットメンションを含む DCS Tree の、ターゲットメンション部分を、コンテキストメンションを根にした DCS Tree で置き換える
4. 3. で作成した DCS Tree から、ランダムにノードを選択し、ランダムウォークによりパスをサンプルする
5. サンプルしたパスにメンションが含まれていれば、ターゲットメンションから先のパスを、正例のパスからランダムに取得してきたターゲットパスと置き換えることで、負例を生成する (Type A)
6. サンプルしたパスにメンションが含まれていなければ、Tian らの負例生成方法と同様に、単語又は意味役割を正例のパスからランダムに取得して置き換える (Type B)

上記の処理により、Type A は約 14 億、Type B は約 7 億の正例データを得た。ただし、本研究では学習時間の関係上、1/10 を抽出し、Type A は 106,154,102、Type B は 61,998,343 を学習データとして使用した。

また、出現頻度の低い事例はノイズになりうるため、上記の処理を行って得たデータに対して、出現回数が 500 回より小さい単語、出現回数が 5000 回より小さい意味役割は \*UNKNOWN\* に置き換えた。この結果、学習データにおける単語数と意味役割数は、それぞれ 26,756、116 となった。

## 4.2 提案モデルの評価実験

提案モデルが、文脈に依存する選択選好性を正しく捉えることができているのかを確認するために、正例と、自動生成した負例が弁別できるかどうかを評価する。未知の正例データと、学習時の負例の生成方法と同様の方法で生成した負例を判別する二値分類問題を解くことで、文脈に依存する選択選好性が捉えられているかを確認する。

### 4.2.1 評価タスク

以下の三つの評価タスクを解くことで、提案モデルが文脈に依存する選択選好性を正しく捉えることができるのかを検証する。

**Pseudo-disambiguation (PD)** 単語のみの意味表現が選択選好へ与える影響を評価する。文脈を除去し、単語ベクトルのみを使用する。(e.g., "monkey *ARG SUBJ eat COMP ARG*" の選好対象として、正例は "banana"、負例は "watch")

**Context-sensitive PD (CSPD)** 文脈に依存した単語の意味表現が選択選好へ与える影響を評価する。文脈を含めた依存構造から計算されるベクトルを使用する。(e.g., "arrest *COMP ARG*" の選好対象として、正例は "John" を根にした "John *ARG SUBJ kill*"、負例は "Bob" を根にした "Bob *ARG COMP kill*")

**CSPD-X** 共参照関係にある単語の意味表現による影響を消し、文脈のみが選択選好へ与える影響を評価する。CSPD から、共参照関係にある単語を除く。(e.g., "police *ARG SUBJ arrest COMP ARG*" の選好対象として、正例は "John" を根にした "*ARG SUBJ kill*"、負例は "Bob" を根にした "*ARG COMP kill*")

#### 4.2.2 実験設定

学習時は、最初 Type B を用いて通常の DCS Vector として学習する。その後 Type A を用いて学習することで、選択選好性を獲得するようにファインチューニングする。<sup>3</sup>

また、単語ベクトルと意味役割行列の次元数は 256 次元、行列の学習率初期値は 1/1024, 学習率は 1/4096, ベクトルの学習率初期値は 1/8, 学習率は 1/512, orthogonal regularizer の学習率は 1/16, inverse regularizer の学習率は 1/16 として、4,096 事例ごとのミニバッチ学習を行った。

各評価タスクでは、選好対象の正例と負例を正しく弁別できるかどうかを、以下の手順に従い検証する。

1. ターゲットメンションを根にした DCS Tree と、コンテキストメンションを根にした DCS Tree を作成する

---

<sup>3</sup>Type A と Type B の学習順序を考慮せずに学習・評価実験を行ったところ、全ての条件下においてファインチューニングした場合よりも精度が悪い結果となった。

2. ターゲットメンションの DCS Tree からターゲットメンションを取り除いた DCS Tree の DCS Vector を計算する
3. コンテキストメンションを根にした DCS Tree から DCS Vector を計算する
4. データセットからランダムに DCS Tree を抽出し、これを負例のコンテキストとし、DCS Vector を計算する
5. 2., 3. で求めたベクトルの内積と、2., 4. で求めたベクトルの内積をそれぞれ計算し、前者の値が大きければ正解、そうでなければ不正解とする

評価実験では、学習時と異なり、パスではなく DCS Tree 全体を用いて DCS Vector を計算する。選択選好性を決定する上で、どの程度の係り先まで必要なかを調べるため、ターゲットメンションを根にした DCS Tree と、コンテキストメンションを根にした DCS Tree を、それぞれ深さ 0, 1, 2 またはすべてを使う条件で実験した。

#### 4.2.3 実験結果

提案モデルの PD による実験結果を表 1 に示す。正例と負例をランダムに選択した場合、精度は 0.5 である。また、表 1 の no matrix は、意味役割行列を使用せず、単語ベクトルのみを用いて DCS Vector を計算した場合の実験結果である。<sup>4</sup>

target depth	context depth	random	PD	
		accuracy	accuracy	accuracy (no matrix)
1	1	0.5000	0.7602	0.6904
2	1	0.5000	0.7022	0.6683
all	1	0.5000	0.6866	0.6671

表 1: 提案モデルの実験結果 (PD)

<sup>4</sup>意味役割行列を無視するために、式 2 における行列を全て単位行列として計算した。

各値は、正例と負例を弁別する二値分類の精度を表す。表 1 の結果では、ランダムや意味役割行列を使用しない場合より、単語ベクトルと意味役割行列を共に使用した場合の精度が高い。特に、target depth が 1 の時、つまり二つの単語間の選択選好が、高い精度で弁別ができています。しかし、target depth を深くするに従い精度が低くなっていることから、深い係り受け関係を計算できるほどの構成性が獲得できていないと考えられる。

次に、CSPD, CSPD-X による実験結果を表 2 に示す。

target depth	context depth	CSPD		CSPD-X	
		accuracy	accuracy (no matrix)	accuracy	accuracy (no matrix)
1	1	0.6441	0.6360	0.6277	0.6212
2	1	0.6279	0.6247	0.6190	0.6138
all	1	0.6465	0.6348	0.6423	0.6012
1	2	0.6213	0.6370	0.6206	0.6222
2	2	0.6250	0.6391	0.6246	0.6349
all	2	0.6492	0.6600	0.6489	0.6372
1	all	0.5926	0.6464	0.5926	0.6359
2	all	0.5954	0.6580	0.5953	0.6584
all	all	0.6971	0.6946	0.6971	0.6959

表 2: 提案モデルの実験結果 (CSPD, CSPD-X)

target depth 及び context depth が 1 の時、意味役割行列を使った場合と使わなかった場合の精度を比較すると、意味役割行列を使った方が精度が高いという結果となった。一方で、no matrix と比較して、depth を深くした場合、つまり係り受け関係をたくさん考慮した場合、精度が下がっていく傾向がある。これは、深い係り受け関係を構成的に計算できるほど行列が学習できていないためだと考えられる。

また、表 2 の target depth, context depth がどちらも all の場合に特に精度が高い。これは、評価データの作成方法に由来する。評価データは、学習データと同様の性質を持つ正例・負例データを生成するために、ClueWeb 12 から 4.1 節

で述べたフィルタリング方法に従って抽出した文から、正例のターゲット DCS Tree とコンテキスト DCS Tree を作成している。このフィルタリングでは、共参照関係にあるメンションが同一文内に出現していることを条件にしているため、ターゲットとコンテキストの DCS Tree は、同一の文から生成される。そのため、ターゲットとコンテキストの DCS Tree を深く辿るほど、それぞれを構成する単語の共通部分が大きくなるに従い、精度が高くなる。

ただし、実際に共参照解析の問題を解く場合には、解析対象のターゲットとコンテキストのメンションが同一文内に出現するとは限らないため、単語ベクトルだけではなく意味役割行列も使用するべきである。

## 5 おわりに

本論文では、文脈依存選択嗜好モデルを提案した。既存の文脈依存選択嗜好モデルで問題となっていた、モデルに適用できる単語の出現パターンが制限される問題を、単語と意味役割の意味表現の構成的な計算を行う DCS Vector を導入することで解決した。また、提案したモデルの有効性の検証した結果、二単語間の選択嗜好性は獲得していることを確認した。

今後の課題として、学習データサイズを大きくした場合に各評価結果が改善するかどうかを検証することが挙げられる。また、提案モデルを既存の共参照解析器に組み込んだ際の、共参照解析精度への影響を評価することが挙げられる。

## 謝辞

本研究を進めるにあたり、適切なお指導・ご助言をくださった乾健太郎教授、岡崎直観准教授に深く感謝致します。システムの実装から研究内容、研究活動に対する考え方まで様々な相談に乗って頂き、助けて下さった松林優一郎研究特任助教に心より感謝致します。データの整備やシステム実装面において数々のご助言・ご協力をして下さった井之上直也助教授、田然研究特任助教に深く感謝致します。また、ご多用の中、審査委員をお引き受け下さいました篠原歩教授、木下哲男教授に深く感謝致します。最後になりますが、大学・研究生活の様々な場面でお世話になりました研究室の皆様心より感謝致します。

## 参考文献

- [1] Collin F. Baker, Charles J. Fillmore, and John B. Lowe. The Berkeley FrameNet Project. *ACL '98 Proceedings of the 36th Annual Meeting of the Association for Computational Linguistics and 17th International Conference on Computational Linguistics*, Vol. 1, pp. 86–90, 1998.
- [2] Cosmin Bejan and Sanda Harabagiu. Unsupervised Event Coreference Resolution with Rich Linguistic Features. *Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics*, No. July, pp. 1412–1422, 2010.
- [3] Altaf Rahman and Vincent Ng. Coreference Resolution with World Knowledge. *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*, Vol. 1, pp. 814–824, 2011.
- [4] David Bean and Ellen Riloff. Unsupervised Learning of Contextual Role Knowledge for Coreference Resolution. *Proceedings of the Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics (HLT-NAACL 2004)*, pp. 297–304, 2004.
- [5] Mohit Bansal and Dan Klein. Coreference Semantics from Web Features. *Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics (ACL-2012)*, pp. 389–398, 2012.
- [6] Haoruo Peng, Daniel Khashabi, and Dan Roth. Solving Hard Coreference Problems. *Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, Vol. 61801, pp. 809–819, 2015.
- [7] Naoya Inoue, Ekaterina Ovchinnikova, Kentaro Inui, and Jerry Hobbs. Coreference Resolution with ILP-based Weighted Abduction. *Proceedings of COLING 2012*, Vol. 2, No. December 2012, pp. 1291–1308, 2012.



- [8] Naoya Inoue, Yuichiro Matsubayashi, Masayuki Ono, Naoaki Okazaki, and Kentaro Inui. Modeling Context-sensitive Selectional Preference with Distributed Representations. In *Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers*, pp. 2829–2838, 2016.
- [9] Ran Tian, Naoaki Okazaki, and Kentaro Inui. Learning Semantically and Additively Compositional Distributional Representations. *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*, Vol. 1, pp. 1277–1287, 2016.
- [10] Michael U Gutmann and Aapo Hyvärinen. Noise-contrastive estimation of unnormalized statistical models, with applications to natural image statistics. *Journal of Machine Learning Research*, Vol. 13, No. Feb, pp. 307–361, 2012.
- [11] Christopher D Manning, Mihai Surdeanu, John Bauer, Jenny Rose Finkel, Steven Bethard, and David McClosky. The stanford corenlp natural language processing toolkit. In *ACL (System Demonstrations)*, pp. 55–60, 2014.
- [12] 雅之大野, 直也井之上, 優一郎松林, 直観岡崎, 健太郎乾. 分散表現による文脈情報を用いた選択選好モデル. 言語処理学会第 22 回年次大会, pp. 885–888, 2016.

## 発表文献一覧

### 学術論文誌

- 松林優一郎, 中山周, 乾健太郎. 日本語述語項構造解析タスクにおける項の省略を伴う事例の分析. 自然言語処理, December 2015.

### 国際会議論文

- Kotaro Sakamoto, Madoka Ishioroshi, Hyogo Matsui, Takahisa Jin, Fuyuki Wada, Shu Nakayama, Hideyuki Shibuki, Tatsunori Mori and Noriko Kando. Forst: Question Answering System for Second-stage Examinations at NTCIR-12 QA Lab-2 Task. Proceedings of the 12th NTCIR Conference on Evaluation of Information Access Technologies, June 2016.

### 国内会議・研究会論文

- 阪本浩太郎, 中山周, 渋谷英潔, 石下円香, 森辰則, 神門典子. 東大入試世界史第1問(大論述問題)を解く質問応答システムの検討. 言語処理学会第22回年次大会発表論文集, March 2016.
- 石下円香, 阪本浩太郎, 中山周, 渋谷英潔, 森辰則, 神門典子. 東大入試世界史第2問(小論述問題)及び第3問(語句問題)を解く質問応答システムの検討. 言語処理学会第22回年次大会発表論文集, March 2016.
- 中山周, 松林優一郎, 乾健太郎. 日本語述語項構造解析のための統語パターン分析. 言語処理学会第21回年次大会発表論文集, March 2015.

### ワークショップ

- 松林優一郎, 吉野幸一郎, 林部裕太, 中山周. Project NEXT 述語項構造タスク. 言語処理学会第21回年次大会ワークショップ「自然言語処理におけるエラー分析」, March 2015.