

# 直接照応解析における分野情報および文脈情報の有効性検証

浜田伸一郎† 齋藤佳美††

東芝ソリューション(株) プラットフォームソリューション事業部†

東芝ソリューション(株) IT技術研究所††

{hamada.shinichiro,saito.yoshimi}@toshiba-sol.co.jp

## 1 はじめに

直接照応解析とは、文章中の談話要素が参照している、同一のエンティティまたは同一の意味を持つ別の談話要素を推定する技術である。参照される談話要素を先行詞、参照する談話要素を照応詞という。情報検索・情報抽出・自動要約・機械翻訳などに役立つことが期待されている。

たとえば要約処理の1つである重要文抽出処理では、文脈から切り離すことで曖昧となる抽出文中の要素をより具体的な内容に置き換える必要がある。直接照応解析を行い、照応詞をより具体的な内容を持つ先行詞で置き換えることで、このような問題を解決することができる。

このような応用において解決すべき有用な照応関係は、先行詞と照応詞とが表層一致しない事例(以降、表層不一致ペアと呼ぶとする)である。しかし、照応関係がタグ付与されている京大コーパス 4.0[1]における名詞間の直接照応の内訳(表1)が示すように、日本語での直接照応ペアの大半は表層一致ペアである。本稿では、少数割合となる表層不一致ペアを対象とした、機械学習による直接照応の解析方法について論じる。

照応性の成否には、統語的特徴、語彙的特徴、文脈的特徴、分野的特徴などが影響すると考えられている。このうち語彙的特徴は、先行詞・照応詞間の意味や表層の近さを判定するなど、照応性の成否に最も大きな影響力を持つ特徴である。

さらに性能を追求していくことを考える場合、文脈的特徴や分野的特徴が重要となる。少し意味的に遠いと思われる語の組合せであっても、照応性が成立することがあるように、同じ語彙の組合せであっても、その語が出現する文脈やそのテキストの分野によって照応性の成否が変わることがある。

このような文脈的特徴や分野的特徴において、核となる概念が顕現性(Salience)である[2]。顕現性とは、中心的な話題として焦点が当たっている度合いのこと

であり、分野や文脈の特徴を捉えると考えられている。顕現性の高い語は、英語では代名詞参照されやすく、日本語では省略されやすいことが知られているが、直接照応の判定においても顕現性を用いることで、精度や再現率が向上する可能性がある。

ここで1つのジレンマがある。統語的特徴や語彙的特徴については、性質や事例数の違いから、表層一致ペアを除外するほうが表層不一致ペアをうまく学習することができる可能性がある。しかし分野的特徴や文脈的特徴などの顕現性を捉えるには、事例が多い方が好ましい。

本稿ではこの解決として、表層一致ペアに基づいて算出される素性を用いて文脈的特徴を捉える方法、および表層一致ペアと表層不一致ペアとの間の転移学習を用いることで分野的特徴を捉える方法、の2種類について、有効性を検証する。

以下、2章ではこれらの手法についての説明、3章では、これらの手法の有効性に関する評価実験について説明する。4章では本論についてまとめる。

## 2 表層一致ペアに基づく顕現性

### 2.1 顕現性の算出

談話における語の顕現性については、最も単純には語の頻度、検索や自動要約で一般的に用いられるtf-idfのほか、飯田らによる[3]など様々な指標があるが、これら顕現性と直接照応との関連性については明らかになっていない。

ここでは、照応ペアに実際に用いられた語の頻度を用いることを提案する。これにより、より直接的に、照応性への影響度を織り込んだ顕現性が得られることが期待される。

ここで表層一致ペアは、名詞同士に違いがないため、照応性を決めるのは語の選択だけであり、語の顕現性を良く表すと推察されること、照応ペアの大半を占め

ており、標本として良質であること、近傍に位置する同じ表層の名詞ペアであれば、多くの場合照応関係が成立するため、表層一致ペアの抽出は比較的簡単なタスクであること、という3点の特徴により、表層一致ペアに含まれる語の頻度を調べることで、良質な顕現性の近似値を簡単に得ることができる可能性がある。

具体的には、まず表層一致ペアの抽出を行って語の頻度を算出し、顕現性に関する素性を生成する。この際、抽出する表層一致ペアを判定対象の名詞ペアの近傍に出現するものに限定することで、文脈の特徴を捉えることを目的とする。続いて、顕現性に関する素性を併せ用いて直接照応の判定を行う。このようにして得られる素性を、以降は文脈的素性と呼ぶものとする。

なお文脈的素性を得るために先行して判定する表層一致ペアについても機械学習を用いることが考えられるが、今回は処理効率を考慮し、閾値以内の距離に出現する同じ表層の名詞句を表層一致ペアとみなして、擬似的に顕現性を算出するものとする。

## 2.2 転移学習の利用

本稿の直接照応では、表層不一致ペアの識別性能の向上を目的としている。表層一致ペアは、全体に占める割合が多い上、表層不一致ペアと比べて判定が容易であるため、1つのタスクとして学習すると、表層一致ペアに優先的に適合して、表層不一致ペアの正解率が低下する懸念がある。しかし先ほど述べたように、表層一致ペアは顕現性を表す標本として有効である可能性がある。

そこで、表層一致ペアと表層不一致ペアとを1タスクとして学習する方法、別タスクとして学習する方法、両者を別タスクとして扱い転移学習を行う方法、の3種類の方法の有効性を検証する。

転移学習を行う方法では、表層一致ペアと表層不一致ペアを別タスクとして独立的に扱うことで、表層一致ペアへの優先的な適合による表層不一致ペアの正解率低下を回避するとともに、表層一致ペアが持つ顕現性のうち必要なものだけを、表層不一致ペアへ転移させることができる。なお本方法で扱うことができる顕現性は、訓練テキスト全体から得られる語の顕現性、すなわち分野全体における語の顕現性である点が、前節の方法と異なる。

表 1: 京大コーパスの名詞間の直接照応の内訳

表層一致		9152 件	71.5%
表層不一致	語彙的言換	3480 件	27.2%
	代名詞参照	160 件	1.2%

## 3 評価実験

### 3.1 評価データと実験設定

前節で述べた2つの直接照応の判定手法の有効性を検証する評価実験を行う。

評価データには京大コーパスを用いるとし、京大コーパスにおいて「＝関係」として示されている、共参照の関係を持つ名詞ペア、および「≠関係」で示されている、総称・非総称、上位・下位などの関係を持つ名詞ペアを直接照応の認定対象として扱うとする。事例数は、表1に示す通りである。

また今回は、照応詞が与えられている状況で、単一の先行詞を選択する問題を解くとする。ただし京大コーパスにおいて複数の先行詞が指定されている事例については、最近傍の先行詞のみを正解とする。

直接照応の判定には、先行詞と照応詞のペアを2値分類する機械学習手法を用いるとし、負例には、照応詞と先行詞の間の任意の名詞と、照応詞とで組み合わせられるペアを用いて、学習および評価を行う。この負例の設定は、標準的な方式としてしばしば参照されるSoonの共参照解析方式[4]と同じである。また評価指標には、各照応詞に対する先行詞の予測結果の正解率を用いるとする。

機械学習のアルゴリズムには、SVMと線形カーネルを用いる。また超パラメータとして、正則項係数に加え、クラス不均衡性の緩和のため事例重みを用い、最良の組合せを調整する。評価処理には10交差検定を用いる。

### 3.2 素性と学習手法

実験に用いる素性を表2に示す。このうち、統語的素性(fts<sub>syn</sub>)および語彙的素性(ftv<sub>oc</sub>)は、[5]などで用いられているベースラインであり、統語的素性に用いる文法情報にはJumanとKNP、語彙的素性に用いる意味情報にはKNPの固有表現認識結果と分類語彙表を用いた。統語的素性(fts<sub>syn</sub>)および語彙的素性(ftv<sub>oc</sub>)はいずれも2値を持つ。

文脈的素性(ftc<sub>tx</sub>)は、語彙的素性と同じ構成を持ち、判定対象の事例の近傍文脈における表層一致ペア

表 2: 素性一覧

統語的素性	個別	<b>ftsyn.pos</b>	品詞の種類
		<b>ftsyn.case</b>	格助詞の種類
		<b>ftsyn.top</b>	文の先頭かどうか
		<b>ftsyn.mod</b>	修飾されているかどうか
	関係	<b>ftsyn.combi</b>	先行詞・照応詞の統語的個別素性の組合せ
		<b>ftsyn.cent</b>	後続の格に上書きされていない先行詞の格
語彙的素性	個別	<b>ftvoc.surf</b>	表層テキスト
		<b>ftvoc.sem</b>	意味カテゴリおよび固有表現タイプ
	関係	<b>ftvoc.cpsurf</b>	表層の文字列マッチ (前方一致・後方一致・包含関係)
		<b>ftvoc.cpsem</b>	先行詞・照応詞の共通の意味カテゴリ
文脈的素性	個別	<b>ftctx</b>	(語彙的素性と同じ構成だが実数値を取る, 詳細は本文で説明)

によく用いられている語について, 大きな実数値を素性値として割り当てる. 具体的には次のように算出する. 判定する照応ペアと同記事内に出現する表層一致ペアを, ルールを用いてまず先にすべて抽出する. 次に, 抽出した表層一致ペア群の語彙的素性ベクトルを総和する. この結果得られた素性ベクトルの各素性値に対数をかけたもののうち, 判定対象の事例における語彙的素性で有効なものを文脈的素性 (**ftctx**) とする. 今回, 京大コーパスが扱う記事のサイズは比較的小さいため, 同記事内を近傍文脈とした.

これらの素性については, 統語的素性 (**ftsyn**) と語彙的素性 (**ftvoc**) を備えた標準的素性セット (**ftstd**) に対して, 文脈的素性を加えたセット (**+ftctx**) を比較する. また分析のため統語的素性だけを備えたセット (**ftsyn**) も用意する.

一方, 学習手法は, 表層一致ペアと表層不一致ペアを区別せずに学習するベースラインのシングルタスク方式 (**st**), 表層一致ペアを識別する問題と, 不一致ペアを識別する問題とを別タスクとして学習するマルチタスク方式 (**mt**), その中間的な処理として, 表層一致ペアと表層不一致ペアを別タスクとして転移学習を行う方式 (**t1**), の3種類を比較対象とする. 転移学習手法には FEDA 法 [6] を用いる. FEDA 法は, 素性ベクトルの次元数を3倍に拡張し, 各タスク専用とタスク共用として素性値を割り当てる手法である. 以降では, 特にタスク共用の素性ベクトル部分を単に共有素性と呼ぶとする.

### 3.3 実験結果

表3は, 先行詞予測の結果を, ペアのタイプごとに集計したものである.

文脈的素性については, 表層不一致ペアの先行詞予測について, ほとんど改善が見られなかった. また表層一致ペアの先行詞予測の正解率が低下したことによ

表 3: 先行詞予測の正解率

		<b>st</b>	<b>t1</b>	<b>mt</b>
<b>ftsyn</b>	表層不一致ペア	25	25	21.69
	表層一致ペア	14.27	81.58	81.68
	全照応ペア	15.45	61.08	61.08
<b>ftstd</b>	表層不一致ペア	28.92	<b>31.61</b>	28.30
	表層一致ペア	80.03	81.68	<b>82.06</b>
	全照応ペア	61.01	62.46	<b>62.85</b>
<b>+ftctx</b>	表層不一致ペア	29.13	29.13	28.93
	表層一致ペア	77.24	81.00	81.49
	全照応ペア	60.09	61.41	61.34

り, 全照応ペアでの正解率も低下した.

学習方式については, シングルタスク方式 (**st**) に比べて, マルチタスク方式 (**mt**) および転移学習方式 (**t1**) のいずれも同等か性能改善が見られた. マルチタスク方式 (**mt**) + **ftstd** 素性は, シングルタスク方式 (**st**) に比べ, 表層不一致ペアの正解率がやや低下したが, 表層一致ペアの正解率が大きく改善し, 全照応ペアでの成績は最も良い. 転移学習方式 (**t1**) + **ftstd** 素性は, 表層一致ペアの正解率の改善量は大きくないが, 本稿の目的である表層不一致ペアの正解率がシングルタスク方式 (**st**) やマルチタスク方式 (**mt**) に比べて大きく改善した.

### 3.4 考察

効果が見られたマルチタスク方式 (**mt**) および転移学習方式 (**t1**) について結果を分析した.

マルチタスク方式 (**mt**) において, 表層不一致ペアの識別タスクは, 極端に少ない正例と極端に多い負例という不均衡データを扱うのに対して, 表層一致ペアの識別タスクは, やや多い正例とやや少ない負例という均衡データを扱っている. このため, これらを混合するシングルタスク方式 (**st**) では, 均衡の変化によ

り、表層不一致ペアの識別性能は改善し、表層不一致ペアの識別性能は低下する。転移学習は重みの共有度合いが両方式の中間的となるため、中間的な性能になる。これらは性能に与える最も基本的な要因の1つと考えられる。

**ftsyn** 素性セットを用いた方式群を性能比較すると、この考察と符合する。一方で **ftstd** 素性セットを用いた方式群を性能比較すると、表層不一致ペアについては、シングルトask方式 (**st**) よりも、転移学習方式 (**t1**) の方が、性能が高いという逆転現象が起きている。これは、**ftstd** 素性セットに含まれる語彙的素性 (**ftvoc**) について、表層不一致ペアと表層一致ペアとで性質が異なっており、全素性を両タスクで共有すると性能低下することを意味している。性質が異なる原因は、語彙的特徴の1つである表層を用いて両タスクを区別したためであると考えられる。

次に、転移学習方式 (**t1**) + **ftstd** 素性セットにおいて、どのような素性群がどのような働きによって表層不一致ペアの性能向上をもたらしたかについて確認した。

FEDA 法は、正則項のペナルティを最小化する働きにより、誤差が大きくなりえない限り、できる限り素性を共有素性で扱うようにする仕組みを持つ。

ここで FEDA 法の2つの特徴に注目する。1つは、大きい重みが割り当てられている共有素性は、共有価値が高いことを示していることである。もう1つは、一方のタスクでは非常に重要度が低い、もう一方のタスクでは非常に重要度が高く、かつタスク間で共有価値がある素性があつた場合、まず共有素性に中間的な重みが割り当てられ、各タスクの素性には、負値を含めた差分となる重みが割り当てられるということである。

これらに注目し、転移学習方式 (**t1**) で生成された素性の中で、重み上位ランク 200 件の中から、語彙に関する共有素性を抽出し、表層不一致タスクの重み下位ランク 100 件に含まれる語彙的素性と共通あるいは類似するものを抽出したところ、素性上位 200 件に含まれていた語彙に関する共有素性は 57 件、そのうち 12 件が、表層不一致タスクの下位 100 件に含まれる素性群と、同じか類似する素性群であった。

少なくともこれら 12 件は、表層不一致ペア単独の学習では元々小さい重みが割り当てられていたが、表層一致ペアとの転移学習により、重みが引き上げられた共有価値の高い素性群と考えられる。12 件は、政府、民主、数記号、機関、成員 (職業など)、大中小、政治、街・集落、文法、～部、環境、時間的前後であり、新聞記事が扱う分野として、顕現性が認められる

意味カテゴリが多く含まれている。

このことから、表層不一致ペアだけではうまく捉えていなかった顕現性を、表層一致ペアの語彙的特徴を選択的に用いることで補完することができ、それが識別性能の向上をもたらしたと考えられる。

## 4 おわりに

表層不一致ペアの直接照応解析の性能改善を目的として、分野や文脈の特徴を用いた解析手法の有効性検証を行った。

文脈の特徴を捉える方法として、近傍にある表層一致ペアに含まれる語の頻度を元に算出した文脈的素性を用いる方法と、分野の特徴を捉える方法として、表層一致ペアと表層不一致ペアとを別タスクとして扱い転移学習を行う方法を検証した。

文脈的素性を用いる方法は効果が得られなかったが、転移学習を用いる方法では、表層不一致ペアだけではうまく捉えていなかった分野の顕現性を、表層一致ペアの語彙的特徴によって補完することができ、表層不一致ペアの識別性能を改善することができた。

## 参考文献

- [1] 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).
- [2] Walker, M., Iida, M. and Cote, S: Centering in Japanese Discourse in Proc of the 13th International Conference on Computational Linguistics (1990)
- [3] 飯田龍: 談話の顕現性を考慮した重要語抽出とその応用 NL-193-9 (2009).
- [4] Soon, W. M., Ng, H. T. and Lim, D. C. Y.: A Machine Learning Approach to Coreference Resolution of Noun Phrases, Computational Linguistics, Vol. 27, No. 4, pp. 521-544 (2001).
- [5] 飯田龍: 最尤先行詞候補を用いた日本語名詞句同一指示解析, 情報処理学会論文誌 46(3), pp.831-844 (2005).
- [6] H. Daume III: Frustratingly Easy Domain Adaptation, proc. of the 45th Annual Meeting of the Association of Computational Linguistics. pp.256-263 (2007).