

# 接続標識「ため」に基づく文書集合からの因果関係知識の自動獲得

乾 孝 司<sup>†</sup> 乾 健 太 郎<sup>†</sup> 松 本 裕 治<sup>†</sup>

人間のような深い言語理解能力を工学的に実現することを妨げている1つの原因として、計算機で利用可能な大量の常識的知識をいかに構築するかという問題がある。本論文では、常識的知識のうち、因果関係に関する知識に着目し、大規模な電子化文書集合から因果関係知識を自動的に獲得する方法について論じる。本論文では、まず、因果関係に立つ2つの出来事がそれぞれ行為であるか事象であるかに基づき、*cause*, *effect*, *precond(ition)*, *means* の4つの因果関係を定義した。接続標識「ため」を含む複文からこれら4つの因果関係への自動分類実験を行い、*cause*, *precond*, *means* の各関係について、80%の再現率で95%以上の分類精度を達成した。また、*effect* 関係については、30%の再現率で90%の分類精度を達成した。さらに、新聞記事1年分の文書集合に本手法を適用することにより、およそ27,000件を超える因果知識が獲得できる見積りを得た。

## Acquiring Causal Knowledge from Text Using the Connective Marker *tame*

TAKASHI INUI,<sup>†</sup> KENTARO INUI<sup>†</sup> and YUJI MATSUMOTO<sup>†</sup>

This paper reports the present results of our approach to the automatic knowledge acquisition of causal relations. We created a new typology of the causal relation — *cause*, *effect*, *precond(ition)* and *means* — mainly based on volitionality. From our experiments using a Japanese resultative connective *tame*, we achieved 80% recall with over 95% precision for the *cause*, *precond* and *means* relations, and 30% recall with 90% precision for the *effect* relation. The results indicate that over 27,000 instances of causal relations can be acquired from one year of Japanese newspaper articles.

### 1. はじめに

因果関係という概念は、古代ギリシャ哲学の時代から今日にいたるまで心理学、哲学をはじめ多くの学問領域で研究対象になってきた。人工知能の領域でも、初期の頃から知能の源として因果関係知識に関心が向けられ、それらの知識を蓄積した知識ベースを利用した推論や言語理解研究が活発になされてきた<sup>5),20)</sup>。たとえば、プラン認識に基づく談話理解過程では、行為の前提条件や効果に関する知識を用いる<sup>2),3)</sup>。図1(a)はそのような知識の例であり、洗濯物を干せばその結果としてどのような状況になるか(効果)、洗濯物を干すにはどのような状況である必要があるか(前提条件)という因果関係によって構成されている。こうした因果関係知識が深い言語理解の実現に必要であることは従来より広く認識されている。

ただ、言語理解にこのような知識集約的な手法を適

用するには、知識ベースの構築に多大なコストを要することが欠点となる。CYCプロジェクト<sup>12)</sup>やOpen Mindプロジェクト<sup>22)</sup>に見られるように、常識的知識を手でどこまで書き尽せるかは依然として未知数であるし、それらの知識を自動的に獲得する方法論についても目覚ましい進展があるとはいえない。しかしながら、近年では、WWWに代表される電子化テキストを知識源と見なし、そこから(半)自動的に因果関係知識・世界知識を獲得する試みがいくつか報告され始めている<sup>4),11),19),23)</sup>。これらは興味深い可能性を秘めているものの、研究はまだ初期の段階にあり、どのような因果関係知識が獲得できるか、あるいはどの程度の精度で、かつどの程度の規模で知識が獲得できるかは明らかでない。

このような背景のもと、本論文では、電子化文書集合から因果関係知識を自動的に獲得する手法について論じる。我々が獲得を目指す因果関係知識は、談話理解で想定されている図1(a)のような知識を分解した、図1(b)のような二項関係知識である。本論文では、このような二項関係知識を因果関係知識、あるいは単

<sup>†</sup> 奈良先端科学技術大学院大学情報科学研究科  
Graduate School of Information Science, Nara Institute  
of Science and Technology

## (a) 【談話理解で利用される知識例】

洗濯物を乾かす (\$主体, \$洗濯物, \$屋外)
precondition: 天気(晴れ)
effect: 乾く(\$洗濯物)
decomposition: 干す(\$主体, \$洗濯物, \$屋外)

“\$” 記号は変数項であることを示す。

## (b) 【(a) を構成する因果関係知識】

【知識】 *precond*(〈 天気が晴れる 〉, 〈 洗濯物を乾かす 〉)

【意味】「天気が晴れる」という事態は「洗濯物を乾かす」という行為の前提条件である。

【知識】 *effect*(〈 洗濯物を乾かす 〉, 〈 洗濯物が乾く 〉)

【意味】「洗濯物が乾く」という事態は「洗濯物を乾かす」という行為の効果である。

【知識】 *means*(〈 屋外に洗濯物を干す 〉, 〈 洗濯物を乾かす 〉)

【意味】「屋外に洗濯物を干す」という行為は「洗濯物を乾かす」という行為の手段である。

図 1 談話理解に利用される知識例

Fig. 1 Example of plan operator and causal relations.

に因果知識と呼ぶ。

これらの因果関係知識は、人間が持つ因果関係に関する知識がそうであり、また、談話理解の先行研究<sup>2),3)</sup>においてもすでに指摘されているように、論理的な必然性が満たされる関係だけではなく、ある程度の必然性は持つが、論理的必然性を満たさない関係も含んでいる。たとえば、図 1 の知識の例の中には論理的必然性を満たさない因果関係が含まれているが、このような知識を利用することで「今日は晴れていたので、洗濯物がよく乾いた。」という発話から、発話者はおそらく洗濯物を屋外に干す行為を行っただろうと推論できるようにと考えられる。

文書集合から図 1 (b) のような因果関係知識を獲得するにあたり、たとえば、次の (1) のような例文が手元にあるとすると、これらの例文からは矢印の右側に示された知識がそれぞれ獲得できると考えられる。

## (1)

a. 晴れている ので, 洗濯物を乾かそう。

→ *precond*(〈 晴れる 〉, 〈 洗濯物を乾かす 〉)

b. 洗濯物を乾かす ために 屋外に洗濯物を干した。

→ *means*(〈 屋外に洗濯物を干す 〉, 〈 洗濯物を乾かす 〉)

本論文で論じる知識獲得手法の特徴は、例文の下線部分に示されたような接続標識を手掛かりとして用いることにある。接続標識に基づく因果知識獲得の研究自体はすでに存在する(たとえば文献 19))が、本論文では特に、既存研究で明らかになっていない以下の

項目について論じる。

- 新聞記事を知識源とした場合、接続標識をともなって表現される因果関係にはどのような関係がどの程度出現しているか(4章)。
- どの程度の精度で因果関係知識が自動獲得できるか(5章, 6章)。
- 利用可能な知識源に対して、どの程度の量の因果関係知識が獲得できるか(6章)。

## 2. 因果知識の関係類型

本論文では、古典的な知識集約型の談話理解研究で設計されたプランオペレータ<sup>3)</sup>にかかわる因果関係を主に取り扱う。図 1 (a) は計画演算子の例である。演算子は、ある中心となる出来事とその周辺の出来事との関係を取りまとめた知識であり、中心となる出来事(図 1 (a) の先頭行)には主に主体の意志的な行為が記述され、周辺の出来事には、中心となる出来事に前後する事態や状態、中心となる出来事をさらに詳細化した出来事などが記述される。

ここで、1 つの計画演算子が違和感なく複数の出来事から構成される理由として、中心となる出来事とその周辺の出来事の間には何らかの因果関係が成立することが仮定できる。また、演算子の構成要素が 1 種類ではなく、いくつかの役割( precondition, effect, decomposition )に分かれていることから、中心となる出来事とその周辺の出来事のかかわり方によって、出来事間に成立する因果関係の種類も異なると考えられる。

我々は、計画演算子に関する上記の考えをふまえ、表 1 の関係類型を定義した。類型における最も基本的な分類は、因果関係に立つ 2 つの出来事が行為か事態かという基準に基づく。ここで、因果関係の項となりうる要素のことを出来事と呼び、主体の有意志的な行為(たとえば「薬を飲む」)を表す出来事を行為、非意志的な事態(たとえば「風邪が治る」)を表す出来事すべてを事態と呼ぶ。この基準は各因果関係を定めるうえでの必要条件となっており、関係名とともに、表 1 の「関係名 出来事<sub>1</sub>, 出来事<sub>2</sub>」欄に示されている。たとえば、「*effect*( 行為<sub>1</sub>, 事態<sub>2</sub> )」は、2 つの出来事間に *effect* 関係が成立するには、少なくとも、第 1 項目に入る出来事は行為であり、第 2 項目に入る出来事は事態でなければならないことを表している。談話理解研究では行為の背後にある主体の意図を理解することが主要な目標の 1 つとされるなど、行為とその他の事態を区別することの重要性はすでに指摘されているとおりである。

表 1 因果知識の関係類型  
Table 1 Typology of causal relations.

関係名(出来事 <sub>1</sub> , 出来事 <sub>2</sub> )	関係の意味	言語テストで用いるテスト文の例
<i>cause</i> (事態 <sub>1</sub> , 事態 <sub>2</sub> )	事態 <sub>1</sub> は 事態 <sub>2</sub> の原因である.	『事態 <sub>1</sub> <sub>a</sub> (という)ことが起こると、その結果としてしばしば『事態 <sub>2</sub> <sub>a</sub> (という)ことが起こる。 『事態 <sub>1</sub> <sub>a</sub> (という)状態になれば、それにともない、しばしば『事態 <sub>2</sub> <sub>a</sub> (という)状態になる。
<i>effect</i> (行為 <sub>1</sub> , 事態 <sub>2</sub> )	事態 <sub>2</sub> は 行為 <sub>1</sub> の効果である.	『行為 <sub>1</sub> <sub>a</sub> (という)ことをする結果、『事態 <sub>2</sub> <sub>a</sub> (という)ことがおうおうにして起こる。 『行為 <sub>1</sub> <sub>a</sub> (という)ことをすることは、通常、『事態 <sub>2</sub> <sub>a</sub> (という)状態を保つ。
<i>precond</i> (事態 <sub>1</sub> , 行為 <sub>2</sub> )	事態 <sub>1</sub> は 行為 <sub>2</sub> の前提条件である.	『事態 <sub>1</sub> <sub>a</sub> (という)状態になる場合、しばしば『行為 <sub>2</sub> <sub>a</sub> (という)ことをする。 もし『事態 <sub>1</sub> <sub>a</sub> (という)ことが起こらなければ、通常、『行為 <sub>2</sub> <sub>a</sub> (という)ことができない。
<i>means</i> (行為 <sub>1</sub> , 行為 <sub>2</sub> ) (ただし、行為主体は同一)	行為 <sub>1</sub> は 行為 <sub>2</sub> を実行するための手段である.	X が『行為 <sub>2</sub> <sub>a</sub> (という)ことを実現する手段として、X が『行為 <sub>1</sub> <sub>a</sub> (という)ことを行うのは最もである。 X が『行為 <sub>1</sub> <sub>a</sub> (という)ことをすることによって、しばしば X が『行為 <sub>2</sub> <sub>a</sub> (という)ことができる。 (“X” は、主体を指す変数。同一変数を共有することで、行為主体の同一性を表現している。)

表 1 の各関係のうち、*effect* 関係は、計画演算子の中心となる出来事とその効果 (effect) となる周辺の出来事との間に成り立つ因果関係に対応し、*precond* 関係は、中心となる出来事とその前提条件 (precondition) となる周辺の出来事との間に成り立つ因果関係に対応する。*means* 関係は、中心となる出来事とそれを詳細化した出来事 (decompositon) との間に成り立つ因果関係に対応する。2 つの出来事がともに行為である場合、自分の意志で両方の行為をする場合と、他人が自分の意志とは独立に一方を行為する場合は、意図構造が明らかに異なることから、*means* 関係では行為主体が同一であることも必要条件としている。*cause* 関係は主体行為が介在しない事態間の因果関係を表す。この関係は、上記の 3 つの関係ほど計画演算子とのかかわりはないが、典型的な因果関係 (たとえば、「大雨が降り、河川が氾濫した」) が認められる場合が多いことから類型に含めた。

上記の 4 つの因果関係について、厳密な意味での十分条件を定めることは容易なことではない。このことは、因果関係という概念自体が哲学的にも一定の見地に至っていないことから明らかである。本論文では、不必要に哲学的議論に立ち入ることを避け、言語テストを課すことによって各関係の十分条件を定めた。具体的には、まず、表 1 中に示したような、スロット (テスト文中の“『出来事<sub>i</sub><sub>a</sub>』”) 付きのテスト文をそれぞれの関係ごとに用意する。そして、関係に立つ 2 つの出来事をテスト文中の各スロットにそれぞれ代入する。このとき、テスト文の文意が適格であれば、テ

スト文に合格していると判断され、そのテスト文に対応する因果関係の十分条件が満たされていると判断される。

テスト文中の各スロットの添字  $i$  は、因果知識 (“関係名(出来事<sub>1</sub>, 出来事<sub>2</sub>)”) の引数の添字と対応しており、因果関係に立つ 2 つの出来事と因果知識の持つ引数との間の対応関係を指定している。

### 2.1 基本的アプローチと問題提起

我々の知識獲得手法は接続助詞などに代表される接続標識を手掛かりとして用いる。知識の獲得対象となる文 (接続標識を下線で表示) とそこから獲得される因果知識の例を以下に示す。

(2)

- 晴れていた ため, 洗濯物がよく乾いた。
- 晴れていない のに, 洗濯物はよく乾いた。
- もしも晴れていた なら, 洗濯物がよく乾いたのに。
- 晴天 で 洗濯物がよく乾いた。

→ e. *cause*(〈晴れる〉, 〈洗濯物がよく乾く〉)

(3)

- 洗濯物をはやく乾かす ため, 乾燥機を使った。
- 乾燥機を使っていれ ば, もっとはやく洗濯物が乾かせたはずだ。
- 乾燥機を使ったのは、はやく洗濯物を乾かした から だ。
- 乾燥機 で 洗濯物をはやく乾かした。

→ e. *means*(〈乾燥機を使う〉, 〈洗濯物をはやく乾かす〉)

これらの例文より、いくつかの異なる接続標識を含む文から同じ種類の因果関係を持つ因果知識が獲得できる可能性があることが分かる。(2e)の *cause* 関係の因果知識は、(2a) から (2d) のそれぞれ異なる接続標識を含む文から獲得できそうであるし、(3e)の *means* 関係の因果知識の場合も同様である。

一方、同じ接続標識を含む文から異なる関係を持つ因果知識が獲得される可能性も観察される。たとえば、(2a) と (3a) は同じ接続標識を含んでいるが、それらから獲得されるのは、それぞれ *cause* 関係と *means* 関係を持つ因果知識である。

このように、接続標識は因果知識を獲得する際の手掛かりとなりうるが、標識とその標識を含む文から獲得できる因果知識の間には、必ずしも 1 対 1 の対応関係が存在しているわけではない。そのため、接続標識以外の情報を利用して獲得可能な因果関係を分類し、適切な因果知識を抽出する枠組みを検討する必要がある。

## 2.2 因果知識の位置付け

具体的な問題設定の準備として、ここでは、文書内の修辞関係という視点から因果知識の位置付けを行い、本論文で獲得を目指す因果知識をより明確にする。

以下の例文 (4) は、「みかんの皮を剥く」という行為と「みかんを食べる」という行為の関係の仕方がさまざまな修辞的表現を使って言語化されており、一般にはそれぞれ異なる修辞関係が認められる。例文 (4a) は一般に『目的』の修辞関係が成立すると解釈され、(4b) は『仮定』、(4c) は『逆接』の修辞関係がそれぞれ成立すると解釈される。

(4)

- みかんを食べる ために ていねいに皮を剥いた。
- みかんは皮を剥かない と 食べられない。
- みかんの皮を剥いた のに 結局食べる事ができなかった。

ここで、我々がこれらの修辞的表現をどれも同様に一貫している (coherent である) と感じられるのは、どの文も、

(5)

【知識】 *means*(〈みかんの皮を剥く〉, 〈みかんを食べる〉)

【意味】「みかんの皮を剥く」という行為は「みかんを食べる」という行為の手段である。

という我々の持つ因果知識と整合しているからであると考えられる。このことは、(6) のような一貫性のない例を考えると明らかである。

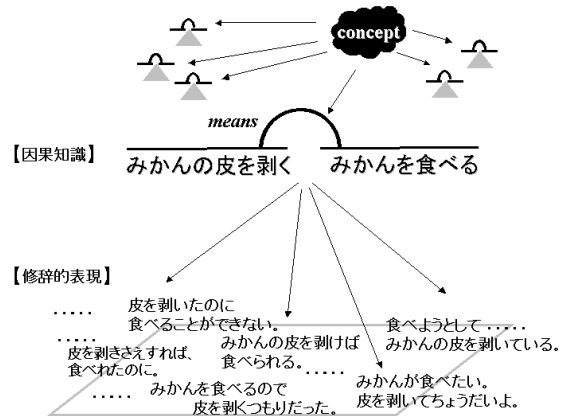


図 2 因果知識と修辞的表現

Fig. 2 Causal knowledge and rhetorical relations.

(6)

- \* みかんの皮を剥いた ために 結局食べる事ができなかった。
- \* みかんの皮を剥いた のに 雨が降ってきた。

本論文で獲得を目指す因果知識は、(4) のような修辞的表現を一貫性のある表現として成り立たせている (5) のような因果関係に関する知識である。

ここで図 2 のように、個々の出来事のインスタンス間の関係 (たとえば、「皮を剥いたのに、みかんが食べられない」) を「修辞的表現」レベルと考え、「修辞的表現」レベルの個々の出来事のインスタンスを抽象化したクラス間の関係 (たとえば、「みかんの皮を剥く」と「みかんを食べる」の関係) を「因果知識」レベルの関係ととらえると、(5) のような因果知識は具体的な修辞的表現を一段抽象化した「因果知識」レベルのものであると見なせる。

抽象化の程度としては、以下に列挙したようなモーダル情報は少なくとも捨象されると考えられる。

- テンス・アスペクトに関する情報：文に表現されている出来事が完了した出来事なのか、これから起こることが予測される出来事なのか。
- 認め方に関する情報：文に表現されている出来事が実際に起こったのか、起こらなかったのか。
- 情報構造に関する情報：文に表現されている出来事のうち、どの出来事に焦点があたっているか。何が新情報であるか。

一般に、言語学の分野では、「表現主体から独立した客観的な事態を表す部分」のことを命題、「表現主体の発話時における判断、発話・伝達態度を表す部分」のことをモーダルあるいはモダリティと定義されるが、テンス・アスペクトがどちらに属するかについては言

語学者の間でも見解が異なっている。本論文での命題、モーダルの定義は、ほぼ上記の言語学における定義に従っているが、出来事のインスタンスを抽象化したクラス間の関係を扱うことから、テンス・アスペクトはモーダル情報に含めて取り扱う。

次に、出来事の命題情報についても何らかの抽象(捨象)処理を仮定することが望ましい可能性がある。しかしながら、本論文では、次の理由から命題情報の抽象処理は仮定せず、命題情報を自然言語のまま保持する。6.5節で後述するように、本研究では実例に基づく手法によって因果知識を利用することを想定している。そのため、獲得された因果知識は、命題情報の抽象化を仮定しなくとも十分に活用可能であると考えている。

- 知識に基づく処理を仮定した場合、知識を抽象化して蓄積しておくことが最適な戦略であるかどうかは証明されていない。また、仮に、知識を抽象化した形で蓄積するとした場合、どのような抽象化のレベルを想定することが最適であるかが明らかではない。
- 世界の意味(抽象化された概念)を記述するのに十分な表現能力を持つ形式言語を設計することが困難であることがすでに認識されている。
- 意味記述研究と比較して自然言語処理技術が確実に進展していることから、自然言語表現による意味記述が最適な妥協案であるというパラダイムが存在する(たとえば、Iwanskaら<sup>8)</sup>)。

意味記述として自然言語表現を採用した研究はすでにいくつか存在する。たとえば、Singhら<sup>21)</sup>のOpen Mind Common Sense知識ベースは人手によって蓄積された英語文から構成されている。Liuら<sup>13)</sup>は、実際にこの知識ベースを知識源と見なして、テキストの感情的理解(textual affect sensing)の実現に応用し、十分に期待できる実験結果を報告している。

### 2.3 問題設定

以上の議論から、(1)や(2)、(3)のようなテキストから因果知識を獲得するには、少なくとも、次の2つの処理を行う必要があると考えられる(図3)。

- 対象文からモーダル要素を捨象して、出来事の命題要素を抽出する処理。
  - 抽出した命題要素間の因果関係を分類する処理。
- 本論文ではこのうち、後者の因果関係の分類問題を特に取り上げ、以下の節で議論する。

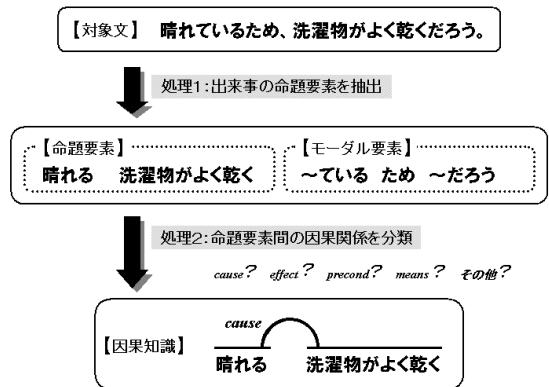


図3 出来事の命題抽出と因果関係の分類

Fig. 3 Proposition extraction and causal relation classification.

表2 接続標識の出現頻度

Table 2 Frequency distribution of connective markers.

が	131,164
ため	76,087
と	56,549
(れ-)ば	48,606
ながら	13,796
から	10,209
ので	9,994
なら	7,598
たら	6,027
のに	2,917

### 2.4 対象とする接続標識と文タイプ

我々は、現時点で利用できる言語資源の中になるべく多く出現する接続標識から順次研究対象とすることが望ましいと考えた。そこでまず、日本経済新聞 CD-ROM データ(1990年)の全記事を茶筌<sup>17)</sup>で形態素解析し、接続助詞(あるいはそれに類する表現)の出現頻度分布を求めた。上位10位の語とその頻度を表2に示す。また、取り扱う接続標識の性質として、ある程度の必然性を持つ因果関係を明示的に表現していることが望ましいと考えた。たとえば、「ため」や「(れ-)ば」は、出来事間の必然性に関する語用論的な制約を持っており、これらによって接続されている2つの出来事の間には、たいていの場合、高い必然性を持つ因果関係が成り立っている。詳細は後述するが、この制約に関しては、計算機実験の際に用いた「ため」を含む約2,000件の新聞記事データを言語テストを用いて人手分析することによっても確認した。

以上の2点の理由から、我々は研究の出発点として、接続標識「ため」(茶筌での品詞は“名詞-非自立-副詞可能”)を含む文に対象を絞ることにした。

後述する文タイプに対象を限定すれば、前者の出来事の抽出は比較的容易に実現できるため詳細は割愛する。

表3 文内文脈における「ため」の分類  
Table 3 Frequency distribution of *tame* in intra-sentential contexts.

複文形式	42,577
一日中晴れていたため洗濯物がよく乾いた。	
その他	33,510
洗濯物が乾きにくいのは、湿度が高いためだ。	
雨のため試合が中止になった。	
ここは旅行者のためのスペースで...	




図4 タメ複文の内部構造

Fig. 4 Structure of a *tame* complex sentence.

ここで、どのような接続標識を対象とするかで、取り扱う問題の難しさも変化することに注意されたい。「ため」が持つ上記のような出来事間の必然性に関する語用論的な制約によって、本研究では、出来事間の必然性の有無に関してはそれほど考慮することなく、因果関係の種類を分類する問題に取り組むことが可能になっている。しかしながら、必然性の高い出来事間を接続することが「ため」に比べて少ない接続標識(たとえば、「たら」)を手掛かりとする場合には、因果関係の種類を分類する際に、必然性の有無を自動的に判別する機構についても熟慮する必要がある。

次に、「ため」の出現分布を文内における周辺形態素によって分類したものを表3に示す。表中の“複文形式”には、次の条件を満たす文が該当する。

複文形式 「ため」を含む文を係り受け解析器(CaboCha<sup>10</sup>)で係り受け解析する。その後、「ため」を含む文節の係り元文節(図4のA)および係り先文節(図4のB)がそれぞれ次のいずれかに該当する場合を“複文形式”とする。

- c1.) 品詞が“動詞-自立”である形態素を含んでいる(たとえば、「乾いた」),
- c2.) 品詞が“形容詞-自立”である形態素を含んでいる(「強い」),
- c3.) 品詞が“名詞-形容動詞語幹”である形態素を含んでいる(「好調だった」),
- c4.) 品詞が名詞-形容動詞語幹以外の“名詞”である形態素を含みかつ、“助詞-連体化”の「の」を含んでいない(「見通しである」)。

表3より、「ため」は“その他”の形式に比べ“複文形式”をともなって出現する頻度が高いことが分か

る。また、出来事は基本的に述語要素と格要素からなる節の形式で過不足なく表現できることを考慮し、「ため」を含む文の中でも“複文形式”にさらに対象を絞り込むことにした。以下、このタイプの文をタメ複文と呼ぶ。

### 3. 関連研究

テキストを知識源と見なし、そこから因果関係知識を獲得することを目的とした研究はすでにいくつか存在する。Girju<sup>4)</sup>や佐藤<sup>19)</sup>は我々と同様、因果関係を表す接続標識を利用した知識獲得手法を提案している。また、鳥澤<sup>23)</sup>は、接続標識を含む文のほかに、接続標識を含んでいない動詞の並列句からの知識獲得も模索している。しかしながら、彼らの方法では、2章で述べたような因果関係の分類は考慮されていない。

Khoo<sup>9)</sup>は構文パターンによる知識獲得手法を提案している。彼らの手法では因果関係の分類が考慮されているが、研究対象が医療関係のテキストデータから構成されるMEDLINEデータベースに特化しており、構文パターン、関係分類もこの分野に依存したものととなっている。

本論文で取り扱う因果関係の分類問題は、いわゆる修辞構造解析における修辞関係の同定(たとえば、文献15)、16)と同じ問題であるように見えるかもしれない。しかし、我々の因果関係類型は、2.2節でも述べたように、修辞構造理論<sup>14)</sup>に代表され、そこで定義される修辞関係集合とは異なるレベルの関係であり、問題の性質も修辞解析とは異なるものである。そのため、本研究に修辞解析で得られた知見がそのまま適用できるわけではない。

### 4. タメ複文から獲得可能な因果知識の割合

因果関係の自動分類実験の事前調査として、表1に示した4つの因果関係を持つ知識がタメ複文に含まれる割合を調査した。本章では、その概要と調査結果について述べる。

#### 4.1 調査手順

調査の手順を以下に示す。

1. 新聞記事より自動的にタメ複文1,000文を抽出する。今回は、研究の手始めとして、前章で述べた複文形式の条件c1を満たす文のみを選択して抽出する。次に、疑問文であるもの、形態素解析などの解析誤りのため、誤ってタメ複文と解釈されたものを人手で取り除く。上記の文を除去した結果、994件のタメ複文を得た。以下、この文集合を $S_1$ で参照する。

表 4 タメ複文集合  $S_1$  から獲得可能な因果知識の分布  
Table 4 Distribution of causal relations in *tame*-complex sentences in  $S_1$ .

クラス	従属節	主節	出現頻度	最頻出関係とその割合	
A	事態	事態	229	<i>cause</i> ( 事態 <sub>s</sub> , 事態 <sub>m</sub> )	0.96 ( 220/229 )
B	行為	事態	161	<i>effect</i> ( 行為 <sub>s</sub> , 事態 <sub>m</sub> )	0.93 ( 149/161 )
C	事態	行為	225	<i>precond</i> ( 事態 <sub>s</sub> , 行為 <sub>m</sub> )	0.90 ( 202/225 )
D	行為	行為	379	<i>means</i> ( 行為 <sub>m</sub> , 行為 <sub>s</sub> )	0.85 ( 323/379 )
			994		0.90 ( 894/994 )

行為<sub>s</sub>, 事態<sub>s</sub>: 従属節側の出来事 行為<sub>m</sub>, 事態<sub>m</sub>: 主節側の出来事

2.  $S_1$  中の文のそれぞれについて, 従属節, 主節から, 出来事の命題要素を抽出する. 各節の主辞となる文節 (図 4 の A と B) の動詞以降の形態素列をモーダル要素と見なして削除し, それ以外を命題要素と見なして抽出する. 以下, これらの出来事の命題要素を対象として議論を進めるが, 説明の便宜上, これらの命題要素のことを従属節, 主節 (あるいは単に節) として参照する. その後, 従属節と主節が行為を表現しているか事態を表現しているかに基づき, 各文を表 4 の 4 つのクラス (A ~ D) に人手で分類する. 以下, 各節が行為を表現しているか事態を表現しているかに関する属性のことを節の意志性と呼ぶ. それぞれの節の意志性の判断は, 因果関係と同様に言語テストを課することで判断する. テスト文には, 「自分で『出来事』(という)ことをするつもりである」や「自分で『出来事』(という)ことをしたくない」などの表現を用意した. テスト文中のスロット (『出来事』) に節を埋め込んだとき, 文意が適切であると判断されれば, その節は行為を表現しているの見なし, そうでなければ事態であると見なす. A から D の各クラスに該当する文の頻度分布を表 4 の第 3 列に示す. 個々のクラスに該当する文は, クラス A に該当する文が *cause* 関係, B と C が *effect* 関係, *precond* 関係, D が *means* 関係の必要条件を満たすことになる.
3. A から D に分類された各文のそれぞれについて, 従属節と主節の出来事をテスト文に代入し, 言語テストを実施することで, どのような因果関係を持つ知識が獲得できるかを判断する. すべての文に対し言語テストを行った後, テストに合格する文を集計することで, 最終的に我々が獲得を目指す因果知識が含まれる割合を求める.

手順 3. において, 今回は, 各関係ごとに 3 つから 7 つのテスト文をそれぞれ用意し (表 1 参照), 言語

テストを実施した. テスト文中の「しばしば」などの語句は, 本研究で手掛かりとして用いている「ため」と同様に, 必然性の高い 2 つの出来事とともに現れたときのみ語用論的に適格な文として認識される性質を持つ. これらの語の語用論的な制約により, 言語テストには因果関係の分類とともに必然性の高さの検査が反映されており, 必然性がなく偶然的な関係は棄却される.

節の意志性および節間の因果関係は, どちらも言語テストによって弁別される. これらの判断の信頼性を評価するために, 計算言語学を専攻する 2 名の大学院生にそれぞれ節の意志性, 因果関係の判断を依頼し, 判断の一致度を調べた. 現在までに結果が得られている 200 件のタメ複文における 2 者間の一致度を  $\kappa$  値で測定したところ, 節の意志性で 0.93, 因果関係で 0.88 であった. これより, 今回得られた節の意志性, 因果関係に関するデータの信頼性は高いといえる.

#### 4.2 調査結果

集計の結果, A から D のどのクラスについても, 表 1 で示したいずれかの関係が最も多く出現していた. 各クラスの最頻出関係とそのクラス内での出現割合を表 4 の右側に示す. たとえば, 従属節に表現されている出来事が行為で, 主節が事態であるとき (すなわち, クラス B に該当するとき), その事例は 93% (149/161) の割合で *effect*( 行為<sub>s</sub>, 事態<sub>m</sub> ) の関係となっていた. 最頻出関係の具体例を以下に示す. 文頭のアルファベットは例文が該当するクラスを表す.

(7)

B1. タイでマングローブを破壊した ため, 大水害が発生した.

【行為<sub>s</sub>】( 誰かが ) タイでマングローブを破壊する

【事態<sub>m</sub>】大水害が発生する

→ *effect*( 〈タイでマングローブを破壊する〉, 〈大水害が発生する〉 )

D1. 北京への切符を買う ため, 駅の切符売場に行った.

【行為<sub>s</sub>】( 私が ) 北京への切符を買う

ただし, *means* 関係の必要条件である, 行為主体の一致性を満たすとは限らない.

【行為<sub>m</sub>】(私) 駅の切符売場に行く

→ *means*(〈駅の切符売場に行く〉, 〈北京への切符を買う〉)

また, 最頻出関係ではなかった(以下, 例外関係と呼ぶ) 例文を以下に示す.

(8)

A1. 企業の成長が見込めるようになった ため, 機運が高まっている。( *cause* 関係でない)

B2. たくさん収容する ため, 日本のホールは扇形になっている。( *effect* 関係でない)

B3. 大量の受注をさばく ため, 一部で中途採用の動きが見られる。( *effect* 関係でない)

C1. 微妙な古楽器が舞台の温度になれる ために オーケストラは, 開演までに十分余も調整した。( *precond* 関係でない)

D2. 和菓子と洋菓子両方を取り扱っていた ため, その製造ノウハウを活用した( *means* 関係でない)

例外関係となる文の中には, そこから何らかの因果知識が抽出できる可能性もある。たとえば, 例外関係と判断された C1 は, *precond* 関係は含んでいないが, *effect* 関係の言語テストに合格し, *effect*( 行為<sub>m</sub>, 状態<sub>s</sub> ) を満たす。しかしながら, このような事例は最頻出関係と比べてわずかしか存在しないことから, 本論文では例外関係としてまとめて取り扱うことにした。

表4の結果から, 従属節, 主節の意志性さえ判別できれば, それぞれのクラスにおいて最頻出関係となった *cause*, *effect*, *precond*, *means* の関係を持つ知識が, 平均して90%の精度で分類できることが分かった。このことは, タメ複文に含まれる節の意志性を推定することが, 因果関係を分類する際に有効であることを示唆している。そこで次章では, タメ複文に含まれる節の意志性の自動推定法について検討する。

## 5. 節の意志性の自動推定

本章では, 節の意志性の自動推定について述べる。

### 5.1 節の意志性に影響を与える情報

節の意志性は, 節が持つ述語要素に依る部分が大きいといえる。つまり, 同じ述語要素を持つ異なる2つの節は意志性も等しくなる傾向がある。たとえば, 前章で収集された  $S_1$  中の994文のタメ複文に含まれる従属節と主節をあわせた1,988件の節中には, 異なりで720の述語要素(今回はすべて動詞)が出現し, 出現回数が2回以上の動詞は異なりで299動詞あった。この299動詞のうち, 227動詞(のべ1002)を述語要素に持つ節については, 動詞に対して節の意志性が均一であった。しかしながら, 残りの72動詞(のべ

565)では述語要素に対して意志性が均一ではなかった。たとえば「拡大する」を述語要素に持つ節は合わせて13件あったが, そのうち5件は(9a)のように行為を表現しており, 残りの8件は(9b)のように事態を表現していた。

(9)

a. 生産能力を 拡大する ため 設備投資する。

(「拡大する」を含む従属節は行為を表現)

b. 管理費が削減した ため, 営業利益が 拡大した。

(「拡大する」を含む主節は事態を表現)

述語要素に対して意志性が均一でなかった565件の節事例を分析することにより, 節の意志性に影響を与える情報として, 以下にあげる項目を新たに発見した。知見1.) 主体情報。主体が人や組織でない場合, 節は事態を表現する傾向がある。

知見2.) 統語的な位置情報。文内において節が従属節を担うか主節を担うか。

知見3.) 節末のモーダル情報。節末にどのようなモーダル要素が付属しているか。

### 5.2 SVMに基づく節の意志性推定

以上の調査結果をふまえ, タメ複文に含まれる従属節, 主節の意志性(行為/事態)の推定がどの程度の精度でできるかを機械学習アルゴリズムであるサポートベクトルマシン<sup>24)</sup>(以下, SVM)を用いて実験的に検証した。SVMは種々の分類課題において, 最も高い精度を示しているアルゴリズムの1つであることが採用の理由である。今回は, 5.1節で示した知見2を反映させるため, 1つの意志性推定器(分類器)を作成するのではなく, 主節と従属節について個別の分類器を作成し意志性を推定することにした。以下, 分類ラベルとして, 行為あるいは事態を指し示す場合は, 括弧つき表現(「行為」, 「事態」)を用いる。

#### 5.2.1 実験条件

素性 分類実験で用いた素性情報を表5に示す。今回は素性情報として, 意志性の推定対象である節内の情報のみを取り扱った。動詞の素性情報は, 単語辞書や格フレーム辞書から抽出でき, 格情報, モーダル情報についても簡単な照合規則によって抽出可能である。主体情報は, 特に複文構造において省略される傾向にあり, 省略補完処理を行う必要がある。しかしながら, 本実験では, 実装の都合から省略補完処理は行わず, 格フレーム情報に基づく単純な主体情報抽出器を作成し, 主体情

前節の調査手順でも述べたように, 実際に意志性を推定する段階ではモーダル情報はすでに捨象されているため, 処理の視点からいえば, 捨象前に付属していたモーダル情報ということになる。



表 5 意志性推定に利用した素性

Table 5 Feature set used for volitionality estimation.

クラス — 説明
V 単語 — 述語要素である動詞の基本形
V EDR — EDR 概念辞書 <sup>25)</sup> に基づき、次の 4 素性を割り当てた ;(C1.)対象動詞の上位概念が“移動”か“行為”に該当するか、(C2.)対象動詞の上位概念が“状態”か“変化”か“現象”に該当するか、(C3.)(C1)と(C2)のどちらにも該当するか、(C4.)上記のいずれにも該当しないかどうか。
V ALT-J/E — ALT-J/E 翻訳システム用辞書 <sup>6),7)</sup> に含まれる動詞に関する以下の 11 エントリについての該当/未該当フラグ：“状態動詞”，“継続動詞”，“瞬間動詞”，“自動詞”，“他動詞”，“補助動詞”，“可能動詞”，“自発動詞”，“使役動詞”，“受身”，“受身(被害)”。
V 語彙大系 — NTT 語彙大系 <sup>6)</sup> に掲載されている動詞の用言意味属性。
C 助詞 — ガ格の有無。ヲ格の有無。
C 要素 — ガ格要素，ヲ格要素を NTT 語彙大系 <sup>6)</sup> を用いて抽象化した概念。
M テンス — 節末がタ形であるかル形であるか
M アスペクト — 節末に「～ている」を含むか否か
M ヴォイス — 節末に「(～さ)れる」を含むか否か。節末に「(～さ)せる」を含むか否か。
M 可能 — 節末に「～できる」を含むか否か
M 否定 — 節末に「(～し)ない」を含むか否か
S — 主体が人，組織か否か。

V: 述語要素の動詞情報    C: 格情報    M: モーダル情報    S: 主体情報

表 6 意志性の分布

Table 6 Ratio of volitionality for each clause type.

		出現頻度	
		行為 / 事態	計
S <sub>1</sub>	従属節	539 / 455	994
	主節	603 / 391	994
S <sub>2</sub>	従属節	613 / 372	985
	主節	650 / 335	985

報の抽出を行った。

データ 訓練データには S<sub>1</sub> を用いた。S<sub>1</sub> の 994 件のタメ複文に含まれる従属節と主節のそれぞれを訓練事例とした。また、S<sub>1</sub> とは異なる掲載年からタメ複文 985 件を新たに収集し、それらに含まれる従属節、主節の意志性を評価事例とした。この文集合は、S<sub>1</sub> と同様に、タメ複文を自動的に 1,000 文抽出した後、人手で疑問文などを取り除き、正解となる意志性(および次章で評価する因果関係)に関する情報を付与したものである。以下、この文集合を S<sub>2</sub> で参照する。表 6 に S<sub>1</sub> および S<sub>2</sub> の意志性の分布を示す。

### 5.2.2 実験結果

実験結果を表 7 に示す。表中の値は、評価事例において正しく意志性が推定できた事例の割合を示す。

このため、本実験では、完全な主体情報の素性抽出はできていない。これによる分類結果の影響については後述する。

従属節、主節のそれぞれの分類器について、カーネル関数として 2 次の多項式カーネルを採用した。本論文において、以下で述べる実験結果は、いずれも素性選択、種々のパラメータの調整を試行した中で、精度の最も高かった場合の精度である。素性選択やパラメータなどの最適化については今後検討の余地がある。

表 7 意志性推定の結果

Table 7 Accuracy of volitionality estimation.

	BL1	BL2	SVM1	SVM2
従属節	0.622	0.803	0.841	0.885
主節	0.660	0.864	0.879	0.888
従 ^ 主	0.474	0.686	0.784	0.867

値は、正答事例数/全事例数を示す

“従 ^ 主” は同一文内の従属節と主節の意志性がともに正しく推定できた割合である。“SVM1” は実験条件で示した素性情報のうち、素性抽出が不完全な主体情報を用いずに、残りのすべての素性情報を用いて分類した場合の精度を表し、“SVM2” は、主体情報を加え、実験条件で示したすべての素性情報を用いて分類した場合の精度を表す。“BL1”、“BL2” は比較用のベースラインである。“BL1” は評価事例中で割合の高かった「行為」(表 6 参照)をすべての事例に対する分類結果とした場合の精度を表し、“BL2” は単純多数決に基づく以下に示す戦略によって分類した場合の精度を表す。

BL2 戦略 評価事例文の従属節、主節のそれぞれについて、もし、各節の述語要素となる動詞が訓練事例中に述語要素として 3 回以上現れているなら、その動詞を含む節の意志性の多数決結果を出力する。述語要素となる動詞が 3 回以上現れていないなら、「行為」をデフォルト値として出力する。

表 7 より、“BL1” に比べて “BL2” の精度が著しく向上していることが分かり、述語要素が意志性に強く影響していることが確認できる。また、“SVM1” と “SVM2” の結果はどちらも “BL2” を上回っているこ

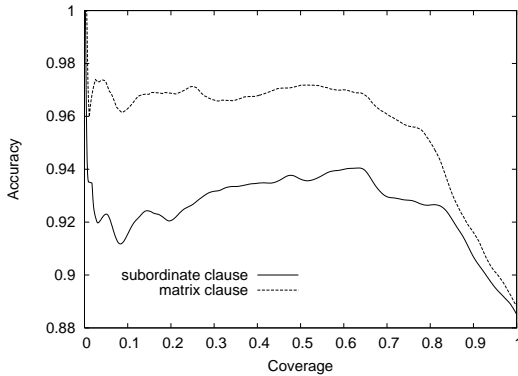


図5 被覆率-精度曲線(節の意志性)

Fig. 5 Coverage-accuracy curves for clausal volitionality estimation.

とから、今回用いた素性情報が意志性の推定にある程度貢献していることが分かる。さらに、“SVM1”と“SVM2”の比較から、素性抽出が不完全であるにもかかわらず、今回の実験では主体情報を考慮した方が分類精度が向上することが確認できた。

#### 信頼度の導入

今回の実験で最も高い精度で意志性が推定できたのは“SVM2”であり、ベースラインを上回る結果が得られた。しかしながら、節の意志性は、因果関係分類の主要な素性情報であることを考慮すると、上記の結果は十分に高い精度であるとはいえない。そこで、上記の推定結果に信頼度の指標を取り込むことを考えた。今回は、SVMが返す判別関数値の絶対値を推定の信頼度と解釈した。この信頼度に対して、ある閾値 $\beta$ を設け、 $\beta$ 以上の信頼度を持つ事例の分類結果のみを最終的な推定結果と見なし、 $\beta$ 未満の信頼度を持つ事例については意志性の推定を保留することにした。すると、 $\beta$ を変化させることにより、図5の被覆率-精度曲線が得られた。ただし、被覆率、精度はそれぞれ以下の式で求めた。

$$\text{被覆率} = \frac{\text{出力された事例数}}{\text{全事例数}}$$

$$\text{精度} = \frac{\text{正しく意志性が推定された事例数}}{\text{出力された事例数}}$$

図5より、閾値を上げていくと、出力を保留する事例が多くなり被覆率が下がる一方で、推定が保留されなかった残りの事例全体での推定精度が向上すること確認ができた。このことは、信頼度の低い事例を犠牲にすれば、より高い推定精度を有する意志性情報が因果関係分類に利用できることを表している。

## 6. 因果関係の自動分類

前章より、ある程度の精度で節の意志性を自動的に決定できる見通しを得た。そこで次に、自動決定された意志性の情報を利用して、タメ複文から獲得できる因果関係の分類がどの程度の精度で自動的にいけるかを実験的に検証した。分類クラスには、*cause*, *effect*, *precond*, *means*の4つの因果関係のクラスのほかに、4.2節で述べた例外関係のクラス *exception*を加えた5クラスを設定した。分類器には前章と同様SVMを用いた。

### 6.1 分類手順

分類の手順を以下に示す。

**Step A. (意志性推定)** タメ複文から従属節と主節を抽出し、それぞれの節に対して5章で示した手法により信頼度つきで意志性を推定する。従属節に対して求められた意志性の信頼度を  $conf_s$ 、主節側の意志性の信頼度を  $conf_m$  とする。

**Step B. (低信頼度事例への対処)** 意志性の信頼度に対する閾値を、従属節側が  $\beta_s$ 、主節側が  $\beta_m$  であるとする。もし、 $conf_s \geq \beta_s$  であり、かつ、 $conf_m \geq \beta_m$  を満たすなら、Step Cに進む。上記の条件を満たさないなら、決定的に *exception* クラスを割り当て、分類手続きを終了する。

**Step C. (因果関係分類)** Step Aで求めた意志性の推定値を素性情報に用い、SVMに基づいて因果関係を分類する。ここでの分類は5クラスの多値分類問題であるため、One vs. Rest法の適用によりSVMを多値分類に応用する。

意志性の信頼度が低く、誤推定の確率が高い場合には、因果関係の分類を誤る可能性も同時に高くなると予想される。そこで、意志性が誤推定である確率が高い場合には、Step B(低信頼度事例への対処)の処理で *exception* クラスに割り当てることによって、誤っていずれかの因果関係に分類する可能性を排除する。この処理によって再現率は低下するが、逆に分類精度は向上すると期待できる。

One vs. Rest法は、分類したいクラスが  $N$  個ある場合、あるクラス  $c_i$  ( $1 \leq i \leq N$ ) がそれ以外(たとえば、*effect* クラスが *effect* クラスではない)かという2値分類器をクラス数  $N$  だけ構築し、それらの分類結果の中で  $c_i$  と分類されたクラスを最終的な分類結果と見なす。この手法により2つ(あるいはそれ以上)の分類器の間に競争が生じた場合は、判別関数値がより大きい分類器の結果を優先した。なお、作成したすべての分類器について、カーネル関数には2次の

多項式カーネルを採用した。

## 6.2 実験条件

素性 分類に用いた素性を以下に示す。用いた素性は、前章の意志性推定の際に用いたものとほぼ同様であるが、ここではタメ複文を構成している従属節と主節の両方に含まれる要素が考慮される。

素性 1.) 節の意志性とその節位置の組。つまり、「従属節\_意志性」、「主節\_意志性」のように節の位置を明示的に素性に反映させる。表 5 に示したすべての素性を用い、5 章で示した手法によって意志性を推定する。

素性 2.) 表 5 の“V 単語”以外の素性とその素性要素が含まれている節位置の組。たとえば、ガ格に関する素性は「従属節\_ガ格」と「主節\_ガ格」を区別して考慮する。

素性 3.) 従属節の主体と主節の主体が同一かどうか。この情報は、*means* 関係の必要条件である。複文における主体の同一性については、主体情報の省略現象を考慮した Nakaiwa ら<sup>18)</sup>の手法により高精度で抽出することがすでに可能である。しかしながら、本実験では彼らの手法を実装するには至らなかったため、規則に基づく簡単な主体の一致性判定器を独自に作成し対応した。

データ 訓練データには  $S_1$  に含まれる 994 件のタメ複文を用い、評価データには  $S_2$  に含まれる 985 件のタメ複文を用いた。 $S_2$  から獲得可能な因果関係知識の分布を表 8 に示す。表中の各用語は表 4 に従う。

評価指標 分類性能は、4 つの因果関係のそれぞれについて、 $n$  点平均精度によって評価する。 $n$  点平均精度は、任意の  $n$  点の再現率における精度の平均値であり、再現率-精度曲線を要約した値である。今回は再現率 = 0.25, 0.50, 0.75 の 3 点による平均精度を計算した。再現率-精度曲線は、5.2.2 項と同様の方法で獲得する。再現率を変化させる際の指標となる信頼度には、One vs. Rest 法により得られた各分類器の判別閾数値のうち、最大値を  $s_1$ 、2 番目に大きい値を  $s_2$  としたときに  $s_1 + (s_1 - s_2)$  で求める値を用いた。ただし、

実際には、“V 単語”情報を考慮した試行実験も同時に行った。しかし、“V 単語”により素性空間の次元数が急激に増加し、精度の低下を招く結果となったため、今回は“V 単語”素性を考慮しない実験結果を掲載する。実験で用いたデータセットが比較的少量であることが精度低下の原因の 1 つとして考えられ、必ずしも“V 単語”が分類に悪影響を与えるわけではない。

表 8 タメ複文集合  $S_2$  から獲得可能な因果関係知識の分布  
Table 8 Distribution of causal relations in *tame*-complex sentences in  $S_2$ .

最頻出関係とその割合	
A	<i>cause</i> (事態 <sub>s</sub> ,事態 <sub>m</sub> ) 0.98 (193/196)
B	<i>effect</i> (行為 <sub>s</sub> ,事態 <sub>m</sub> ) 0.78 (108/139)
C	<i>precond</i> (事態 <sub>s</sub> ,行為 <sub>m</sub> ) 0.94 (166/176)
D	<i>means</i> (行為 <sub>m</sub> ,行為 <sub>s</sub> ) 0.79 (375/474)
	0.85 (842/985)
	<i>exception</i> (-, -) 143/985

それぞれの因果関係  $R$  についての再現率、精度は次式によって計算した。

$$\text{再現率} = \frac{\text{正しく関係 } R \text{ を出力した事例数}}{\text{関係 } R \text{ の事例数}}$$

$$\text{精度} = \frac{\text{正しく関係 } R \text{ を出力した事例数}}{\text{関係 } R \text{ を出力した事例数}}$$

## 6.3 実験結果

分類結果を表 9 に示す。R1 は素性 1 (意志性情報) のみを素性情報に用いた場合の分類精度であり、R2 は素性 2 と素性 3 (意志性以外のすべての情報) の素性情報のみを用いた場合の精度、R3 は素性 1 から素性 3 のすべての素性情報を用いた場合の精度である。表 9 の左側は、Step B (低信頼度事例への対処) を考慮していない場合の精度であり、右側は Step B を考慮した場合の精度である。また、R3 で Step B を考慮した場合の再現率-精度曲線を図 6 に示す。

R1 は素性情報が意志性のみであるため、実験条件で示した、SVM に基づく Step C の手続きではなく、次の分類戦略に従って因果関係を分類した。

Step C-forR1. 従属節、主節の信頼度がともに閾値以上であった事例について、

- 従属節の意志性が「事態」、主節の意志性が「事態」であれば、*cause* 関係を出力する。
- 従属節の意志性が「行為」、主節の意志性が「事態」であれば、*effect* 関係を出力する。
- 従属節の意志性が「事態」、主節の意志性が「行為」であれば、*precond* 関係を出力する。
- 従属節の意志性が「行為」、主節の意志性が「行為」であれば、*means* 関係を出力する。

ただし、因果関係分類の信頼度は  $conf_s + conf_m$  で求める。

まず、表 9 の左側に示した、Step B を考慮しない場合の結果を検討する。R1 は、意志性の情報しか分類に考慮していないことから、意志性が誤って推定されれば因果関係も必ず誤分類となってしまう、精度が低い。また、R2 についても、主要な素性である意志性を素性情報として用いていないことから精度が低い。

表 9 因果関係の自動分類結果  
Table 9 Experimental results of causal relation classification.

素性	3 点平均精度							
	Step B を考慮しない場合の結果				Step B を考慮した場合の結果			
	<i>cause</i>	<i>effect</i>	<i>precond</i>	<i>means</i>	<i>cause</i>	<i>effect</i>	<i>precond</i>	<i>means</i>
R1: 素性 1	0.883	0.556	0.781	0.869	0.905	0.593	0.799	0.879
R2: 素性 2 + 3	0.769	0.588	0.943	0.722	—	—	—	—
R3: 素性 1 + 2 + 3	<b>0.993</b>	0.854	<b>0.992</b>	0.972	0.992	<b>0.859</b>	0.989	<b>0.984</b>
R3': 素性 1 + 2' + 3'	0.995	0.864	0.992	0.975	0.996	0.882	0.993	0.988

各関係ごとに R1 から R3 の分類結果の中で最も精度が高い結果を太字で示す

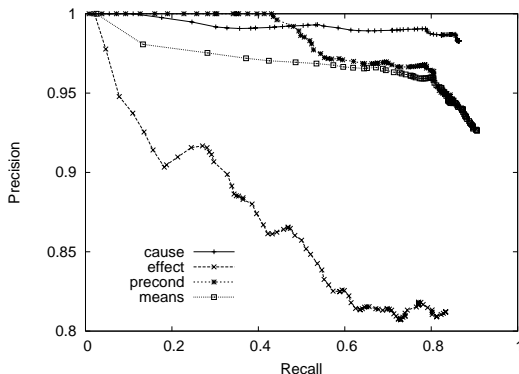


図 6 因果関係分類の再現率-精度曲線 (R3, Step B を考慮)  
Fig. 6 Recall-precision curves for causal relation classification.

一方, R3 は, いずれの関係においても R1 と R2 の結果よりも精度が高い。この結果から, 意志性およびそれ以外の情報のどちらもが, 相補的に因果関係の分類に貢献していることが分かる。また, R3 を R1 に R2 の素性の情報を追加した結果ととらえると, 仮に節の意志性が誤って推定された場合でも, それ以外の素性情報の補正作用によって正しい因果関係に分類することが可能になり, その結果として分類精度が向上したと考えられる。

今回の実験では, 主体素性と主体一致素性の抽出が実装の都合から完全ではなかった。そこで, 作成した素性情報抽出器の代わりに人手で正しい素性情報を付与したデータを用いて, 改めて意志性の推定と因果関係の分類実験を行った。その結果を参考までに表 9 の R3' に示す。この分類精度が現時点で達成できる実際の上限精度となる。R3 と R3' の比較から, 今回の実験結果 (R3) は上限には至っていないことが確認できる。しかし, その精度差は大きくなく, 素性情報抽出器の改善が因果関係分類の精度改善に顕著に結び付くわけではないといえる。

次に, Step B (低信頼度事例への対処) の効果を検討する。今回は, それぞれの素性セットについて一様に約 20% の事例が例外関係クラス *exception* に分類さ

れるように閾値を設けた。結果を表 9 の右側に示す。この処理によって精度が向上したのものには矢印を付与している。結果ごとにばらつきはあるが, 全般的に分類精度が向上する傾向にあり, 特に R1 ではその効果が大きい。これらの結果より, ある程度の事例を犠牲にしてもかまわない場合には, Step B の処理は効果的であるといえる。今回の対処法は単純な手法であったが, 信頼度の見積もり方などを工夫すれば, さらに分類精度の向上へ貢献できると考えられる。

#### 6.4 獲得できる知識量の見直し

新聞記事 1 年分 (約 1,500,000 文) に含まれるタメ複文から獲得できる知識の量は次のように見積もれる。まず, *cause* 関係では 99% の精度, *precond* 関係と *means* 関係では 95%, *effect* 関係では 90% の精度での知識獲得を想定する。このとき, 図 6 より, *cause* 関係が 79%, *effect* 関係が 30%, *precond* 関係が 82%, *means* 関係が 83% の再現率 (REC) で, 指定された分類精度が達成されることが分かる。次に, 1,000 件のタメ複文から獲得可能な因果関係知識の割合 (FR) は, 表 8 の  $S_2$  の分布を仮定すれば, *cause* 関係では 19% (つまり, 193/1000) となり, 以下同様に, *effect* 関係が 11% (108/1000), *precond* 関係が 17% (166/1000), *means* 関係が 38% (375/1000) となる。以上の条件の基での因果関係知識の獲得比率は, 次式の計算により 64% と見積もることができる。

$$0.19 \frac{cause}{FR} \times 0.79 \frac{cause}{REC} + 0.11 \frac{effect}{FR} \times 0.30 \frac{effect}{REC} + 0.17 \frac{precond}{FR} \times 0.82 \frac{precond}{REC} + 0.38 \frac{means}{FR} \times 0.83 \frac{means}{REC} = 0.64.$$

新聞記事 1 年分に現れるタメ複文は, 表 3 より, およそ 42,500 件であるので, 我々が獲得できる知識は  $42,500 \times 0.64 \approx 27,000$  件となる。

これは 1 年分の新聞記事全文の約 1.8% を占める割合である。対象や目的が異なることから, 単純に他手法と比較することはできないが, 今回の 1.8% という割合は, たとえば, Marcu<sup>16)</sup> が獲得した談話解析用の修辞関係知識の割合 (対象コーパスの約 2.0%) と比べてもけっして少なくはない。

## 6.5 因果知識の利用手法

獲得された因果知識の利用手法としては、case-based (memory-based) reasoning のような、実例に基づく手法の援用が想定される。我々の因果知識は、モデル情報は捨象するが、命題情報は原文のまま残されており、大部分が一般化されない。そのため、因果知識を推論ルールと見なした場合には、入力事例と照合可能な推論ルールがきわめて少数となることが懸念される。しかしながら、実例に基づく手法では、入力事例と完全に一致する実例が存在していない場合であっても、入力と実例間の類似性を必要最低限の動的な抽象処理を施すことで見積り、存在する実例における最適な結果を導くことができる。たとえば、関係が未知である2つの出来事「花子が洗濯物を乾かす」と「洗濯物が乾く」に対しては、memory-base 内の最も類似した因果知識、*effect*(〈太郎が洗濯物を乾かす〉, 〈洗濯物が乾く〉)を利用することで、「花子が洗濯物を乾かす」と「洗濯物が乾く」の両者の間には *effect* の関係があることが推定できると期待できる。また、出来事「花子が洗濯物を乾かす」と、先例と同一の因果知識を利用することで、結果として出来事「洗濯物が乾く」が生起するであろうという推論結果を導ける可能性がある。

ただし、現状では、知識の獲得元の文中に代名詞などの照応現象や省略現象があった場合には、それらの要素が欠落したままの状態では因果知識が獲得されるため、これらの要素の補完処理を今後、追加する必要がある。たとえば、4.2 節の (7) で示した例の場合、「大水害が発生する」は、正確には「(タイで)大水害が発生する」であると人間は容易に推測できる。しかしながら、機械処理を想定した場合は、これらの省略要素を適切に補完する機構が必要であり、補完を行わなければ、不完全な知識によって、誤った推論を引き起こすなどの弊害が生じる可能性がある。照応現象や省略現象を補完する技術はすでにある程度の精度まで達しており、現在も研究が進められていることから、これらの技術を適用することで要素の補完処理は近い将来十分に実現可能になると考えられる。

## 7. おわりに

本論文では、接続標識に基づき、電子化文書集合から因果関係知識を獲得する手法を検討した。今回は、特に、対象を「ため」を含む複文に絞り、この対象文から獲得可能な因果関係を自動的に分類する問題を取り扱った。分析、実験を通して得られた結果から、以下の知見が得られた。

- 「ため」を含む複文の従属節、主節の意志性さえ判別できれば、我々が定めた種類の *cause*, *effect*, *precond*, *means* の関係が平均して 85%以上の精度で分類できることが分かった(表4, 表8)。
- サポートベクトルマシンを用いた機械学習手法により、*cause*, *precond*, *means* の各関係について、80%の再現率で 95%以上の分類精度を達成した。また、*effect* 関係については、30%の再現率で 90%の分類精度を達成した(図6)。
- 新聞記事1年文のテキストに本手法を適用することにより、およそ 27,000 件を超える因果知識が獲得できる見積りを得た。

今後は、知識の被覆率向上を目指し、「ので」や「(れ-)ば」、「から」などの異なる標識を手掛かりに用いた場合についても検討していきたい。常識的な出来事は標識をともなって記述されにくいという指摘<sup>1)</sup>もあることから、対象とする接続標識の拡張と同時に「ビールを飲み、酔った」といった標識のない並列句を利用できる鳥澤<sup>23)</sup>の手法との統合方式も検討していきたい。また、今回は因果関係知識の自動獲得手法に焦点を当て議論を進めたが、獲得できた知識を応用分野へ適用し、その効果を確認することが今後の課題として残っている。

謝辞 日本語語彙大系、ALT-J/E 翻訳システム用辞書の利用を許可していただいた NTT コミュニケーション科学基礎研究所の諸氏に感謝いたします。(株)電子化辞書研究所より EDR 電子化辞書を利用させていただきました。また、日本経済新聞社より日本経済新聞 CD-ROM データを利用させていただきました。諸機関の方々に深く感謝いたします。本研究に対して有益な多くの助言をいただいた通信総合研究所の諸氏の皆様に感謝いたします。

## 参考文献

- 1) 有田節子：因果の言語学，月刊言語，Vol.25, No.5, pp.20-23 (1996)。
- 2) Allen, J.F.: *Recognizing intentions from natural language utterances*, *Computational models of discourse*, Brady, M. and Berwick, R.C. (Eds.), MIT Press (1983)。
- 3) Allen, J.F.: *Natural Language Understanding*, Benjamin/Cummings (1995)。
- 4) Girju, R. and Moldovan, D.: Mining Answers for Causation Questions, *Proc. the AAAI Spring Symposium on Mining Answers from Texts and Knowledge Bases* (2002)。
- 5) Hobbs, J.R., Stickel, M., Appelt, D. and Martion, P.: *Interpretation as Abduction*,

- Artificial Intelligence*, Vol.63, pp.69–142 (1993).
- 6) Ikehara, S., Miyazaki, M., Shirai, S., Yokoo, A., Nakaiwa, H., Ogura, K., Ooyama, Y. and Hayashi, Y.: *Goi-Taikei — A Japanese Lexicon*, Iwanami Shoten (1997).
  - 7) Ikehara, S., Shirai, S., Yokoo, A. and Nakaiwa, H.: Toward an MT System without Pre-Editing — Effects of New Methods in **ALT-J/E**-, *3rd Machine Translation Summit: MT Summit III*, Washington DC, pp.101–106 (1991).
  - 8) Iwanska, L.M. and Shapiro, S.C.: *Natural Language Processing and Knowledge Representation — Language for Knowledge and Knowledge for Language*, The MIT Press (2000).
  - 9) Khoo, C.S.G., Chan, S. and Niu, Y.: Extracting Causal Knowledge from a Medical Database Using Graphical Patterns, *Proc. 2000 ACL*, pp.336–343 (2000).
  - 10) 工藤 拓, 松本裕治: チャンキングの段階適用による係り受け解析, 情報処理学会論文誌, Vol.43, No.6, pp.1834–1842 (2002).
  - 11) 黒橋禎夫, 酒井康行: 辞書とコーパスからの世界知識の自動抽出, 「知識発見のための自然言語処理」シンポジウム (1999).
  - 12) Lenat, D.: Cyc: A large-scale investment in knowledge infrastructure, *Comm. ACM*, Vol.38, No.11, pp.33–38 (1995).
  - 13) Liu, H., Lieberman, H. and Selker, T.: A Model of Textual Affect Sensing using Real-World Knowledge, *International Conference on Intelligent User Interfaces*, pp.125–132 (2003).
  - 14) Mann, W.C. and Thompson, S.A.: Rhetorical Structure Theory: A Theory of Text Organization, *USC Information Sciences Institute, Technical Report ISI/RS-87-190* (1987).
  - 15) Marcu, D.: The Rhetorical Parsing of Natural Language Texts, *Proc. ACL97/EACL97*, pp.96–103 (1997).
  - 16) Marcu, D.: An Unsupervised Approach to Recognizing Discourse Relations, *Proc. ACL Conference*, pp.368–375 (2002).
  - 17) 松本裕治, 北内 啓, 山下達雄, 平野善隆, 浅原正幸, 松田 寛: 日本語形態素解析システム『茶筌』version 2.2.1 使用説明書, 奈良先端科学技術大学院大学 (2000).
  - 18) Nakaiwa, H. and Ikehara, S.: Intrasentential Resolution of Japanese Zero Pronouns in a Machine Translation System using Semantic and Pragmatic Constraints, *Proc. 6th TMI*, pp.96–105 (1995).
  - 19) 佐藤浩史, 笠原 要, 松澤和光: テキスト上の表層的因果知識の獲得とその応用, 信学技報 (TL98-23) (1999).
  - 20) Schank, R. and Abelson, R.: *Scripts, Plans, Goals and Understanding*, Lawrence Erlbaum Associates (1977).
  - 21) Singh, P., Lin, T., Mueller, E.T., Lim, G., Perkins, T. and Zhu, W.L.: Open Mind Common Sense: Knowledge Acquisition from the General Public, *Proc. 1st. International Conference on Ontologies, Databases and Applications of Semantics for Large Scale Information Systems* (2002).
  - 22) Stork, D.G.: Character and Document Research in the Open Mind Initiative, *Proc. Int. Conf. on Document Analysis and Recognition*, pp.1–12 (1999).
  - 23) 鳥澤健太郎: 「常識的」推論規則のコーパスからの自動抽出, 言語処理学会第9回年時大会, pp.318–321 (2003).
  - 24) Vapnik, V.N.: *The Nature of Statistical Learning Theory*, Springer (1995).
  - 25) Yokoi, T.: The edr electronic dictionary, *Comm. ACM*, Vol.38, No.11, pp.42–44 (1995).  
(平成15年7月30日受付)  
(平成16年1月6日採録)



乾 孝司

1999年九州工業大学情報工学部卒業。2001年九州工業大学大学院情報工学研究科修士課程修了。同年奈良先端科学技術大学院大学情報科学研究科博士課程入学。現在に至る。

自然言語処理の研究に従事。



乾 健太郎 (正会員)

1967年生。1995年東京工業大学大学院情報理工学研究科博士課程修了。同年より同研究科助手。1998年より九州工業大学情報工学部助教授。1998年～2001年科学技術振興事業

団さきがけ研究21研究員を兼任。2001年より奈良先端科学技術大学院大学情報科学研究科助教授。現在に至る。博士(工学)。自然言語処理の研究に従事。言語処理学会, 人工知能学会, 電子情報通信学会, ソフトウェア科学会各会員。



松本 裕治(正会員)

1955年生．1977年京都大学工学部情報工学科卒業．1979年同大学大学院工学研究科修士課程情報工学専攻修了．同年電子技術総合研究所入所．1984年～1985年英国インペリアルカレッジ客員研究員．1985年～1987年(財)新世代コンピュータ技術開発機構に出向．京都大学助教授を経て，1993年より奈良先端科学技術大学院大学教授，現在に至る．工学博士．専門は自然言語処理．人工知能学会，日本ソフトウェア科学会，言語処理学会，認知科学会，AAAI，ACL，ACM各会員．

---