

2005/5/27 〈NL167-2005〉

文書内に現れる因果関係の出現特性調査

乾 孝司
日本学術振興会 特別研究員
東京工業大学
奥村 学
東京工業大学

背景と目的

- 対話, 質疑応答システム⇒推論機構
 - ◆ 推論規則（因果関係知識）が必要
- 大規模文書から獲得 [Girju02, 鳥澤03, Inui04]
 - ◆ 現状：因果関係の出現特性が不明
 - ◆ 知識獲得の精度, 効率の向上を妨げ
- 目的：文書内に現れる因果関係の出現特性を調査

調査手順

1. 因果関係タグ付きコーパスの構築
 - 文書内の因果関係にタグを付与
2. 出現特性調査
 - 付与情報を基にして出現特性を定量的に調査

調査手順

1. 因果関係タグ付きコーパスの構築
 - 文書内の因果関係にタグを付与

- 調査項目とタグづけ方針
- タグ（例による説明）
- タグ付与基準
- 作成したコーパスの概要

調査項目

- 手がかり標識の有無
 - ◆ 手がかり標識：「ため」, 「ので」など
 - ◆ 手がかり標識が、どれくらい伴うか？
- 出来事表現（原因, 結果）の統語カテゴリ
 - ◆ VPかNPか？
- 出来事表現（原因, 結果）の出現位置
 - ◆ 文末に多いか？
 - ◆ 原因と結果の相対的な位置関係は？

タグづけの方針

- 表現形式に関する制約を設けず、網羅的に、因果関係にタグを付与する

大雨が降ったため、川が増水した。 (明示的)

大雨が降り、川が増水した。 (非明示的)

大雨で川が増水した。 (出来事が名詞句)

大雨が降った。洪水が起こった。 (文をまたぐ)

調査手順

1. 因果関係タグ付きコーパスの構築

- 文書内の因果関係にタグを付与

■ 調査項目とタグづけ方針

■ タグ（例による説明）

◆ head

◆ mod

◆ causal_rel

◆ marker

} 出来事

— 因果関係

— 手がかり標識

■ タグ付与基準

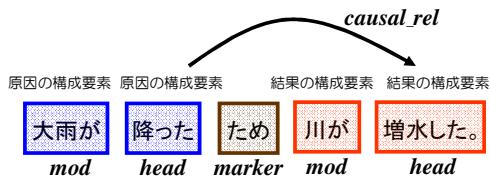
■ 作成したコーパスの概要

タグ付け例

元文：大雨が降ったため川が増水した。

原因：大雨が降る

結果：川が増水する

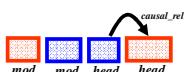


タグ付け（整理）

■ 文節ごとに

◆ 文節の組み合わせ=出来事

◆ 語順の影響を吸収



■ 主辞要素を区別

◆ 主辞要素の位置で出来事の位置を代表させる

■ 手がかり標識に *marker* タグ



調査手順

1. 因果関係タグ付きコーパスの構築

- 文書内の因果関係にタグを付与

■ 調査項目とタグづけ方針

■ タグ（例による説明）

■ タグ付与基準

■ 作成したコーパスの概要

タグ付け基準

■ 言語テンプレートに基づく判断基準

◆ 言語的な判断の拠り所を与える

■ 言語テンプレート

◆ 2つのスロットをもつ文

スロット

『結果側出来事』ということをするのは
大抵『原因側出来事』という状況の時である。

タグ付け基準

■ 判断の手順

1. 判断したい2つの出来事表現を用意する

起きたら晴れだった。
寝いけれど洗濯物を干した。



洗濯物を干す

晴れる

『結果側出来事』ということをするのは

大抵『原因側出来事』という状況の時である。

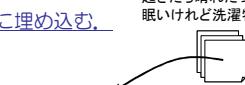
タグ付け基準

■判断の手順

1. 判断したい2つの出来事表現を用意する。
起きたら晴れだった。
眠いけれど洗濯物を干した。
2. 出来事表現をスロットに埋め込む。


『結果側出来事』ということをするのは
大抵『原因側出来事』という状況の時である。

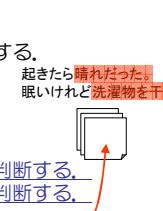
■判断の手順

1. 判断したい2つの出来事表現を用意する。
起きたら晴れだった。
眠いけれど洗濯物を干した。
2. 出来事表現をスロットに埋め込む。


『洗濯物を干す』ということをするのは
大抵『晴れる』という状況の時である。

タグ付け基準

■判断の手順

1. 判断したい2つの出来事表現を用意する。
起きたら晴れだった。
眠いけれど洗濯物を干した。
2. 出来事表現をスロットに埋め込む。

3. 文意が適格であれば、
因果関係があると判断する。
適格でなければ、因果関係がないと判断する。


『洗濯物を干す』ということをするのは
大抵『晴れる』という状況の時である。

■18種類のテンプレートを使用

- ◆それに4つのバリエーション
- ◆因果関係の強さを区別する（強い，弱い）
 - 「大抵」，「しばしば」，「常に」 ⇒強い因果（蓋然）
 - （副詞なし） ⇒弱い因果（偶然）

『結果側出来事』ということをするのは
大抵『原因側出来事』という状況の時である。

調査手順

1. 因果関係タグ付きコーパスの構築

- 文書内の因果関係にタグを付与

- 調査項目とタグづけ方針
- タグ（例による説明）
- タグ付与基準
- 作成したコーパスの概要

作成したコーパスの概要

- データ：毎日新聞，社会面から750記事
- 作業者：3名
- 記事を読み、
因果関係を発見次第，タグ付け

因果関係が認められた例

| 原因側 | | 結果側 | |
|-----------|-------|---------|--------|
| mod | head | mod | head |
| 冬型の 気圧配置と | なる | 冷え込み | |
| | 逮捕する | 取り調べ | |
| | 急性心不全 | 死去 | |
| 交信が | 途絶える | 安否が | 気遣う |
| 頭の 骨を | 折る | | 死亡 |
| 線路に | 転落 | 電車 | 停止 |
| 韓国大統領 | 訪日 | 交通 | 規制 |
| 琴 調べ | 響く | | うつとり |
| 東海道新幹線 | 遅れる | 約二十一万人に | 影響する |
| 酒を | 飲む | | 酔いつぶれる |

(語順は修正)

総数

| 作業者 | 総数 | 記事あたり |
|-----|------|-------|
| A | 2014 | 2.7 |
| B | 1587 | 2.1 |
| C | 1048 | 1.4 |

- 1000～2000件の因果関係が認められた
- 作業者間で総数が2倍近く異なる
 - ◆ 原因1：判断結果が異なる
 - ◆ 原因2：判断の試行回数が異なる
 - ⇒特に、非明示的な表現では
判断自体がされない傾向がある

作業者間の一致度

- 作業者の判断が一致
= head タグの位置が一致
- 2人以上一致
 - ◆ 蓋然：0.36 (699/1952)
 - ◆ 偶然：0.24 (314/1311)
- 母比率の差の検定
 - ◆ H_0 「母比率の差がd %である」
 - ◆ H_0 を棄却
($d \leq 7$ のとき p 値 ≤ 0.00805)
 - ◆ 「蓋然」の強さをもつ事例の方が信頼できる

| 一致 | A | B | C | 蓋然 | 偶然 |
|----|---|---|---|-----|-----|
| 1 | 1 | 0 | 0 | 632 | 535 |
| 1人 | 0 | 1 | 0 | 487 | 255 |
| | 0 | 0 | 1 | 134 | 207 |
| | 1 | 1 | 0 | 230 | 90 |
| 2人 | 1 | 0 | 1 | 92 | 77 |
| | 0 | 1 | 1 | 107 | 83 |
| 3人 | 1 | 1 | 1 | 270 | 64 |

調査手順

1. 因果関係タグ付きコーパスの構築
 - 文書内の因果関係にタグを付与
 2. 出現特性調査
 - 付与情報を基にして出現特性を定量的に調査
- 対象データ：699件（2人以上が一致 & 「蓋然」）
- 手がかり標識の有無
 - 出来事表現（原因, 結果）の統語カテゴリ
 - 出来事表現（原因, 結果）の出現位置

手がかり標識の有無

- marker タグを伴う割合を調査
- 約7割が標識なし
 - ◆ 非明示的な表現は判断されない傾向にある
 - ◆ 標識なし：さらに増える

| 手がかり | 頻度 |
|------|-----|
| 標識 | |
| あり | 219 |
| なし | 480 |
| 計 | 699 |

出来事表現の統語カテゴリ

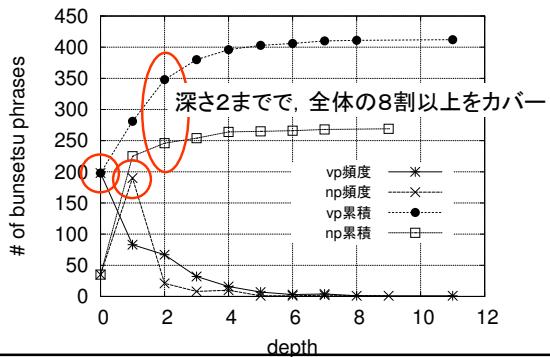
| カテゴリ | head の例 | 原因側 | 結果側 |
|------|-----------|-----|-----|
| VP | 焼く 難しい | 365 | 412 |
| NP | 停電 火災 | 322 | 269 |
| その他 | うつとり | 12 | 18 |

- カテゴリ（VP, NP）の割合を調査
- 原因, 結果ともに, VP が過半数
- NP も VP と同等数存在

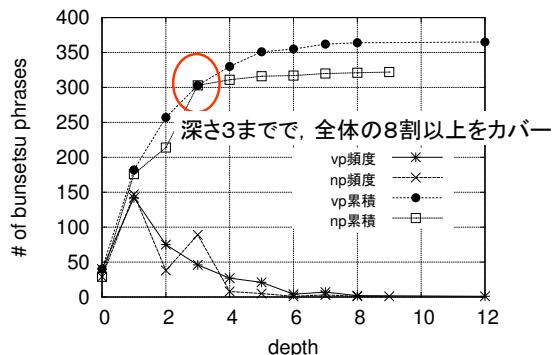
出来事表現の出現位置

- 元文の係り受け木を考える
(文末文節が根, 深さ=0)
- head タグを含む文節の根からの深さ
- 統語カテゴリごとに, 深さの出現分布を調査

出来事表現の出現位置（結果側）



出来事表現の出現位置（原因側）



原因-結果の相対的な出現位置

- 元文の係り受け木を考える



- 原因と結果の
head タグを含む文節が位置する深さの差

原因-結果の相対的な出現位置

| | | 頻度 |
|----------|--|-----|
| 文内 | | 頻度 |
| 深さの差 = 1 | | 259 |
| = 2 | | 152 |
| > 2 | | 33 |
| 係り受けなし | | 72 |
| 文間 | | 141 |

(原因が結果よりも深い場合)

- 原因が結果に直接係る場合が最も多い
- ただし、それ以外の位置にも存在

出現傾向調査（まとめ）

- 約7割が標識なしで出現
- 過半数がVP (NPもほぼ同数)
- 原因(文末-1) ⇒ 結果(文末)
- 原因が結果に直接係る



- 既存の知識獲得のカバーする範囲
◆標識あり + VP