

地方議会会議録における オノマトペの自動抽出手法の提案

- 木村泰知(小樽商大) 渋谷英潔(横浜国大)、
内田ゆず(北海学園大) 乙武北斗(福岡大)、
高丸圭一(宇都宮共和大) 森辰則(横浜国立大)

オノマトペとは

✓ 擬音語および擬態語

例. 擬音語 「**どんどん**(叩く)」

例. 擬態語 「**のびのび**」「**どんどん**(進める)」

✓ 音, 雰囲気, 程度, 様子を効果的に伝える手段

例. 雨の音 「**しとすと**」「**ぽつぽつ**」「**ざーざー**」

✓ 日本語の話しことばで多用される

特に、3文字以下の誤抽出が多い

文字長	正抽出数	誤抽出数	正抽出率
2	15	604	2.4 %
3	580	1,549	27.2 %
4	999	356	73.7 %
6	61	0	100.0 %

2文字

「ぼっ」 まつぼっくり…

「ふっ」 いきいきふっつ高齢者プラン

「ごん」 ごんは、いたずらを後悔し…

3文字

「えへん」 せえへん人が出てくる…

「ぼやっ」 何ぼやったんですか。

「ちゃっ」 全部押さえられちゃったらば

提案手法

形態素解析器と構文解析器を用いて

2つの規則のみで抽出する

形態素解析によって1つの形態素に分割されており、
以下の品詞に解析されているオノマトペ候補

(A-1) 4文字以上の「副詞」「名詞」

(A-2) 3文字以下の「副詞」

規則A

文節の先頭にあり、以下の3条件のいずれかにあては
まるオノマトペ候補

(B-1) 4文字以上である

(B-2) 3文字で最後が「り」である

(B-3) 3文字以下で直後に「と」「っと」「に」のいずれ
かが続く

規則B

実験方法

✓対象とする会議録

1. 2010年度、402 自治体、約1319万文(約3億語)

✓実験データ

オノマトペ	12,261発言
非オノマトペ	6,437発言

正解データの作成方法

1. 形態素解析によってオノマトペを抽出
2. 正解ラベルの作成 (177語を人手で確認)

✓比較実験

- ベースライン… JUMAN辞書にオノマトペを登録
- 提案手法 … 規則Aと規則Bの適用

実験結果（提案手法）

提案手法の精度 88.4%

正解ラベル	総数	抽出	非抽出
オノマトペ	12,261	11,484	777
非オノマトペ	6,437	1,390	5,047
合計	18,698	12,874	5,824

ベースライン 67.5% から 20.9ポイント向上

実験結果

- ✓ ベースラインから **20.9 ポイント向上**
 - 予備抽出で67.5%
 - 提案手法で88.4%
- ✓ **4文字以上の精度** … **変化なし**
 - 例 「ぴったり」「ごちゃごちゃ」
 - 予備抽出で91.12%
 - 提案手法で91.09%
- ✓ **3文字以下**の精度 … **45.9ポイント向上**
 - 例 「にやり」「じん」
 - 予備抽出で39.5%
 - 提案手法で85.4%

考察 誤抽出・未抽出(1/7)

形態素解析, 同音異義語, その他の観点から要因を明らかにする

未抽出 6.3%(777 例)

正解ラベル	総数	抽出	非抽出
オノマトペ	12,261	11,484	777
非オノマトペ	6,437	1,390	5,047
合計	18,698	12,874	5,824

誤抽出 21.6%(1,390 例)

考察 誤抽出・未抽出(2/7)

形態素解析

同音異義語, その他の観点から要因を明らかにする

誤抽出の多いオノマトペ

たった	ごくごく	おいおい	しとり	さらさら	くすり	さんさん
かったん	かんから	とことこ	なんなん	たっ	ぽっ	とくとく

方言文法「～しとります」「～言わへんかったんで～」「～せないかんから～」

未抽出の多いオノマトペ


ばさっと	➡	ば[助詞]	さっと[副詞]		
ごちゃ	➡	ご[接頭詞]	ちゃ[名詞]		
ずらずらと	➡	ずら[動詞]	ず [助動詞]	ら[名詞]	と[助詞]

形態素解析の精度向上が必要

考察 誤抽出・未抽出(3/7)

形態素解析, **同音異義語** その他の観点から要因を明らかにする

誤抽出の多いオノマトペ



「唯」転化、表層的に一致する副詞、ひらがな表記

形態素解析の精度向上が必要

考察 誤抽出・未抽出(4/7)

形態素解析, **同音異義語** その他の観点から要因を明らかにする

誤抽出の多いオノマトペ

たった

ごくごく

おいおい

しとり

さらさら

くすり

さんさん

かったん

かんから

とことこ

なんなん

たっ

ぽっ

とくとく

制度・施設の名称として利用される

語の意味・構文解析の係り先情報等を利用する必要がある

考察 誤抽出・未抽出(5/7)

形態素解析, **同音異義語** その他の観点から要因を明らかにする

✓ 「**きらら**」

- 語義「明るくまぶしく輝き続けているさま」
- 一般の辞書に掲載される意味は「**雲母**」の別称
- 名詞として解析されるため未検出

語の意味・構文解析の係り先情報等を利用する必要がある

考察 誤抽出・未抽出(6/7)

形態素解析, 同音異義語, **その他の**観点から要因を明らかにする

✓ 3文字以下のオノマトペ

- 促音や長音を伴い、連続して出現することがある

✓ 連続して出現するオノマトペ

- 例. 「**ぽん**」 「**ぽんぽん**」 「**ぽんぽんぽん**」

- 「ぽん」と「ぽんぽん」はオノマトペ辞典に掲載あり

■ 本手法による抽出結果

– 結果 「ぽんぽん」 → 「ぽん[副詞] + ぽん[副詞]」

– 評価 「ぽんぽん」の未抽出

– 課題 検出には成功しているため、精度評価の検討の余地あり

考察 誤抽出・未抽出(7/7)

形態素解析, 同音異義語, **その他の**観点から要因を明らかにする

✓ 2文字のオノマトペ

• 規則(B-3) により誤抽出

■ 「ぽっ」 「まち**ぽっ**と」 (組織名称)

■ 「たっ」 「**たっ**とい」 (尊い)

– 「たっ」は87,534回出現するが、オノマトペの可能性が低い

文字長の短い抽出規則について、事例の分析が必要

まとめ

- ✓ 地方議会会議録からオノマトペを抽出する手法の検討
 - 形態素解析と構文解析の利用
 - 2つのルール
- ✓ 実験結果
 - 精度 88.1%
 - 対象データ 177 語 (12,261 例) のオノマトペを含む文
- ✓ 有効性
 - 短いオノマトペにおいて誤抽出が大幅に削減された
 - **3文字以下** のオノマトペの抽出精度
45.9 ポイント向上
- ✓ 今後の課題
 - 形態素解析において口語表現や方言文法への対応が必要
 - 同音異義語に対応するために、構文解析の係り先情報の利用する必要あり