

CCGによる日本語文処理の モデリング

梶川康平 吉田遼 大関洋平 (東京大学)


概要

- 人間は逐次的にどのようにして統語/意味構造を構築しているのか？
 - 英語において、
 - ① CCGの右枝分かれ構造より左枝分かれ構造の方が、
 - ② さらにreveal操作という文処理方略が
認知的に妥当と主張されている
 - 言語の構造が異なる日本語においても同様の主張は成り立つのか？
 - 特に、日本語においては②は成り立たないように思われる。
- ➡ ① は成り立ったが、② は成り立たなかった。


Combinatory Categorical Grammar

Steedman (2000), 戸次 (2010)

- 形式文法として高い記述力をもつ (Joshi, 1985; Stabler, 2013)
- 型依存 (type-dependent) な組合せ規則により統語/意味構造を並行して計算
 - 単語の逐次的な合成による文の導出が可能



右枝分かれ構造




左枝分かれ構造

- ▶ 英語における、左枝分かれ構造の(右枝分かれ構造に対する)妥当性は、fMRIデータを通して示されている (Stanojevic' et al., 2021)

日本語の左枝分かれ構造

動詞に先んじた項同士の関係の計算を行う



- 心理言語学において、「verb-finalな日本語では、動詞を待たずに項構造が計算されている」と主張されている (Kamide and Mitchell, 1999; Miyamoto, 2002; Isono and Hirose, 2022)

- 特定の構造に対して検証済み

➡ ナチュラルリスティックコーパスを使った計算心理言語学的検証


Reveal操作

Stanojevic' and Steedman (2019)


- 後置修飾詞は、逐次的な文処理の障害となる (e.g., Hale, 2014)





- 左枝分かれ構造は右枝分かれ構造に変換し (木の回転)
- 後置修飾詞は既に作った構成素に付加する



木の回転
→




付加
→



- ▶ 英語におけるreveal操作の認知的妥当性は、fMRIデータを通して示されている (Stanojevic' et al., 2021; 2022)

日本語におけるreveal操作



• Reveal操作は日本語においても妥当な操作か？

1. 後置修飾詞がない (Greenberg, 1963)

2. 関係節が埋め込まれた文には、reveal操作を応用できる

• そのような文は、**典型的なgarden-path文** (井上, 1990)

➡ 日本語の文処理では、reveal操作による予測に反するかも？

実験 方法論

- 検証する仮説:

日本語において、逐次的に構築している構造として

- ① CCGの右枝分かれ構造より、左枝分かれ構造が妥当
- ② 左枝分かれ構造より、reveal操作による構造が妥当

- データ：BCCWJ-EyeTrack (浅原ら, 2019)

視線走査法による視線情報がアノテーションされたコーパス

- 橋渡し仮説:

CompositionCount

- ▶ 尤度比検定で評価

実験

木構造の獲得


右枝分かれ構造 : depccg (Yoshikawa et al., 2017) の best parse

➡ 一部のcategoryを型繰り上げ ($>T$)

➡ 木を左方向に回転

➡ 左枝分かれ構造

$x \geq y$ のとき




木の回転の例

詳細は予稿集、appendixへ


実験

橋渡し仮説：CompositionCount (cc)

- 各単語ごとに新たに構築される二分木の数 = 意味合成の数
- 先行研究でのNodeCountと異なり、パーサー特有のunary ruleの影響を排した上で、意味計算という側面に注目した指標



CCright: (0, 0, 2)



CCleft: (0, 1, 1)

実験

統計分析

- ① CompositionCountの有効性検証
- ② Nested model comparisonによる仮説検証

Baseline:

RT ~ dependent + length + frequency + is_first + is_last +
is_second_last + screenN + lineN + segmentN + (1|article)
+ (1|subj)

Data:

視線走査法による総注視時間、13,232/19,176のデータポイントを使用

有意水準:

$\alpha = 0.05/t$ (tは検定数)

結果・考察

1. CompositionCountの有効性

	χ^2	df	p
Baseline < All	127.51	3	< 0.0001

➡ CompositionCountそれ自体に眼球運動データを説明できる効果がある

ALL:

RT ~ [baselineの回帰式] + CCright + CCleft + CCreveal

結果・考察

2. 右枝分かれ vs. 左枝分かれ

	χ^2	df	p
Baseline < Right	91.438	1	< 0.0001
Baseline < Left	126.96	1	< 0.0001
Left < RightLeft	0.5483	1	0.459
Right < RightLeft	36.068	1	< 0.0001

➡ 眼球運動データに説明力は、CCleft > CCright

- 日本語において逐次的に構築されていると考えられる構造として、CCGの左枝分かれ構造の方が妥当

結果・考察

3. 左枝分かれ vs. reveal操作

	χ^2	df	p
Baseline < Left	126.96	1	< 0.0001
Baseline < Reveal	125.72	1	< 0.0001
Reveal < LeftReveal	1.2392	1	0.2656
Left < LeftReveal	0.0004	1	0.9837

➡ 眼球運動データに説明力は、CCleft \neq CCreveal

日本語において逐次的に構築されていると考えられる構造として、
reveal操作による構造の方が妥当とは言えない

まとめ

- 日本語の逐次処理で構築される構造として、CCGの右枝分かれ構造より左枝分かれ構造の方が妥当
 - 動詞に先んじた項関係の計算を、計算心理言語学の知見から支持
 - 左枝分かれ構造よりreveal操作による構造の方が妥当とは言えない
 - reveal操作が通言語的には妥当でないことを示唆
- ➡ reveal操作を、その前提から考え直す必要性

