

生成AIを用いた鹿児島方言生成 —日琉諸語の低資源言語・方言の生成に向けた試み—

坂井美日 (鹿児島大学)



1. はじめに

- 本研究の目的: **低資源言語・方言**の生成
- 本発表の試み: **鹿児島方言**(鹿児島市)の生成

- ・ 日琉諸語に属す⇒語順や承接順序等は標準日本語等と共通。
- ・ 語彙、音韻、文法面で固有の特徴。

(1) へがわっぜふっでもーびんたがしれ、はよなけにぐっど。

(2) he//hai//=ga wazze fur-Q=de
灰=nom 非常に 降る-NPST=CSL

moo binta=ga sire//siro-i//

感嘆 頭=NOM 白い-ADJS

hajo//haja-u// nake//naka=i// nigu-Q=do

はい-ADV 中=DAT 逃げる-NPST=SFP
(灰がひどく降るので、もう頭が白い。はやく中に逃げるよ。)

- ・ 低資源かつ消滅危機方言。機会学習可能な言語資源は乏しい。
- ・ GPT-4のzero-shot→精度ほぼ0%。

- 標準語=**同系高資源言語**の活用&**言語知識**の補填

機械翻訳の知見を応用!

- ・ 高資源言語の活用有効 (Zoph et al. 2016)
- ・ 言語間の類似度が性能向上に影響 (Martínez-García et al. 2021等)

初チャレンジ!

- ・ 現段階のLLMは、言語分析が苦手。
↓
言語知識を与えれば精度向上?

【本発表の結論】

- 日琉諸語の低資源方言たる鹿児島方言の生成は、
- ・ 標準日本語と対訳形式で整備されたデータ
- ・ 当該方言の言語知識の説明
- を入力することで生成の精度が上がる。

2. 言語知識の入力は精度を上げるか

- 実験: 母音融合現象の処理
- 形容詞2タイプ(カ系/イ系)のうち、イ系で当該現象。
- 母音が融合かつ短縮した形が表層形になる。

(4) 形容詞2タイプ(例: 甘い)

カ系: あまか/イ系: あめ (//amai//→//ame://→/ame/)

(7) イ系に見られる規則

I. //ai//→/e/、II. //ui//→/i/、III. //oi//→/e/、IV. //i://→/i/

- タスク20問を設定。GPT-4を使用。4パターンを検証。

Zero-shot…タスク(5)のみ

(5) 次の意味の形容詞を鹿児島方言でどのように言うか答えて下さい。

1. ひどい、2. ながい、3. 古い、4. 美しい、5. 高い、6. 安い、7. 速い、8. 遅い、9. 苦しい、10. 熱い、11. 冷たい、12. 重い、13. 軽い、14. まぶしい、15. 明るい、16. 寂しい、17. 強い、18. 弱い、19. 悲しい、20. 白い

【条件】語尾が「か」で終わる形式以外で答えて下さい。つまり「ひどか」「ながか」等、語尾が「か」で終わる形式以外の言い方を答えて下さい

言語知識 (音素ベース) …(9)→(5)

(9) 鹿児島方言では、母音が連続すると母音が融合します。

(法則)

1. ai→e、2. ii→i、3. ui→i、4. ei→e、5. oi→e
この法則は、形容詞の語末にも適用され、発音に反映されます。

(例) あまい (amai) →あめ

嬉しい (ureshii) →うれし

寒い (samui) →さみ

黒い (kuroi) →くれ

(—以下(5)を入力—)

Few-shot…例示(8)→(5)

(8) 鹿児島方言の形容詞の例を挙げます。
標準日本語=鹿児島方言

a. 甘い=あめ、b. 寒い=さみ、c. 固い=かて、d. 嬉しい=うれし、e. 太い=ふて、f. 清々しい=清々し、g. 悪い=わり、h. 美味しい=おいし、i. えぐい=えぎ、j. 黒い=くれ、k. 痛い=いて、l. 細い=ほせ

それでは、上記の例を参考に、鹿児島方言の法則を分析しつつ、
(—以下(5)を入力—)

言語知識 (仮名ベース) …(10)→(5)

(10) 仮名ベース鹿児島方言の形容詞は、次の手順で作ります。

1. 語末の「い」を削除する。

2. 語末から2番目の仮名の発音を変更する。

—ア段ならばエ段に変更。

—イ段ならば変更なし。

—ウ段ならばイ段に変更。

—オ段ならばエ段に変更。

(例) 甘い (あまい: 「ま」はア段) →あめ

嬉しい (うれし: 「し」はイ段) →うれし

寒い (さむい: 「む」はウ段) →さみ

黒い (くろい: 「ろ」はオ段) →くれ

(—以下(5)を入力—)

正解: 1 ひで、2 なが、3 ふり、4 うつくし、5 たけ、6 やし、7 はえ、8 おせ、9 くるし、10 あち、11 つめて、12 おめ、13 かり、14 まぶし、15 あかり、16 さびし、17 つえ、18 よえ、19 かなし、20 しれ

- 各パターン10回生成。正答1点/誤答0点で得点化。




図1: 母音融合の処理

回	Zero		Few		仮名		音素	
	正答	%	正答	%	正答	%	正答	%
1	0	0%	5	25%	8	40%	8	40%
2	0	0%	5	25%	20	100%	8	40%
3	0	0%	6	30%	19	95%	19	95%
4	0	0%	6	30%	18	90%	13	65%
5	0	0%	5	25%	19	95%	12	60%
6	0	0%	8	40%	19	95%	19	95%
7	0	0%	5	25%	19	95%	15	75%
8	0	0%	6	30%	19	95%	13	65%
9	0	0%	5	25%	13	65%	13	65%
10	3	15%	5	25%	19	95%	15	75%

【平均】

Zero: 0.3 (1.5%) Few: 平均5.6 (28%)

音素: 13.5 (67.5%) 仮名: 17.3 (86.5%)

- ・ Zero: ほぼ0% (デフォルトでの生成は困難)
- ・ Few: 30%以下 (例から言語法則を見出すのは不得意)



Few < *¹ 言語知識入力 (音素 < *² 仮名)

*¹: Few vs 音素… t(18)=-6.405, p値約4.97e-06<0.05

*²: 音素 vs 仮名: t(18)=2.242, p=0.0378<0.05

- ・ 言語知識を与えることで、精度が向上。
- ・ 仮名ベースの分析が精度が高い傾向。

【補足】動詞活用の処理




図2: 動詞活用の処理

平均得点率

仮名: 76.4%

音素: 52.9%

やはり仮名ベースのほうが精度高い (p<0.05)

3. 鹿児島方言の生成

タスク「鹿児島方言で東京スカイツリーについて説明して」

- a. 会話文、b. 語彙集、c. 言語知識をプロンプト入力。

方言会話約20分。
(スカイツリーの話はない)
標準日本語と対訳セット。

方言固有語彙の標準語対訳
120セット(a)に出現。
動詞は活用種類と語幹情報。

文法概説。
格、形容詞、動詞、文末、
接続。

(16) 生成結果

東京スカイツリーは、東京のシミダクにあるどー^C。この^Bタワーは、ふっとかで、世界ん中で一番高かタワーじゃった。スカイツリーんてっぺんから見っと、東京ん景色が一望できっと、よか眺めじゃらいね。特に夜ん景色は、光がきらきらして^B、きれいかどー。スカイツリーん中には^Bおみせもずんばいあって、おきやっさーが買い物^Bしたり、食事したりできっと。また、そこには^B展望台もあって^B、わっぜ高かところから^B東京を見がでくっど。天気よか日にゃ、富士山も見えっど。スカイツリーへの行き方は、電車で行くのが^B便利じゃっど。東京スカイツリー駅や押上駅からちかいから^B、そっから歩いていけっど。

評価	基準	点数
A	問題無し	1点
B	不十分 (方言文脈の中にあっても良いが、より伝統的な言い方がある。)	0.3点
C	不自然 (意味はわかるが、当該方言として違和感がある)	0.1点
D	非文 (文法的、意味的に不可)	0点

- 59文節
- **D判定なし**
- 50.4/59点
- **精度85.4%**