

## 対話システムにおける少数話題の発話文 自動生成手法に関する検討

宅和 晃志† 吉川 大弘† ジメネス フェリックス† 古橋 武†

†名古屋大学

### 1 はじめに

近年、人間と自然な対話を行うことを目的とした対話システムが注目されている。特定のタスクの達成を目的とせず、日常的な雑談を行う非タスク指向型対話システムにおいては、想定される対話の話題が広範囲に及ぶ。そのため、「こういった発言にはこう返す」というルールを大量に記述する、従来のルールベースの発話システムでは、ルールを記述するコストが非常に大きくなってしまふ。

そこで近年、Twitter などのウェブ上から、発話文を大量に取得する手法が提案されている [1][2]。これらの手法を用いることで、多様な話題の発話文を容易に取得することができる。しかし、ウェブ上で言及されにくい話題に関しては、十分な数の発話文を取得することができない。そこで本稿では、すでに取得されている発話文から、新たな発話文を生成する手法を提案し、その有用性について検討する。

提案手法のアイディアは単純である。取得したい話題語（話題となる単語）と意味的に近い単語を含む発話文から、単語を置換することにより新たな発話文を生成する。しかし、単純に置換を行うだけでは、無効な発話文（意味が通らない、文として成り立たないなど）が生成される可能性がある。そのため、無効な文を除去し、有効な（使用可能な）発話文のみを取得する手法についても検討する。

### 2 提案手法

#### 2.1 新たな発話文の生成

ある話題語を含む発話を新たに生成したいとする。まず、word2vec により計算された単語の分散表現を用い、話題語とコサイン類似度が高い単語（意味的に近い単語）を上位  $N$  個、類似語として取得する。類似語を含む発話文に対し、各類似語を目的の話題語で置換することで、新たな発話文を生成する。

意味的に近い単語で置換を行っただけでは、生成された発話文が有効な発話文となるとは限らない。例えば、「やっぱりビールは黒ラベル

だね」という発話文から「やっぱりワインは黒ラベルだね」という発話文が生成されることが考えられる。「ワイン」と「黒ラベル」という本来結びつかない単語が共起することで、無効な発話文となってしまう。提案手法では、このような発話文に対し、以下の手法で除去を行う。

#### 2.2 無効な発話文の除去

無効な発話文は本来共起しない単語を含むと考えられるため、ここでは、共起関係を用いた除去方法を提案する。

まず、置換する前の発話文と置換した後の発話文を MeCab により形態素に分解し、名詞・形容詞・動詞のみを取得する。このとき、活用により形が変わってしまう形容詞と動詞に関しては、形態素の原形として取得する。取得された各形態素  $w_i$ （話題語  $w_t$  と類似語  $w_s$  は除く）に対して、以下の値  $d_i$  を計算する。

$$d_i = \frac{n(w_i, w_s)/n(w_s) - n(w_i, w_t)/n(w_t)}{n(w_i, w_s)/(n(w_s) + 1) + n(w_i, w_t)/(n(w_t) + 1)}$$

ここで、 $n(w_1, w_2)$  は Wikipedia と Twitter における一文内での  $w_1$  と  $w_2$  の共起回数、 $n(w)$  は Wikipedia と Twitter における単語  $w$  の出現する文の数、分母に含まれる 1 は極端な値となることを避けるためのスムージング項である。 $d_i$  は +1 ~ -1 の値を取り、置換を行うことで不適切な共起が生じる場合、 $d_i$  が大きな値をとることが期待される。そこで発話文内における各  $d_i$  の値の最大値  $d_{max}$  が、ある閾値  $thres$  を超える発話文は除去を行う。

### 3 実験 1

#### 3.1 発話文データベースの構築

まず、[1][2]の手法を参考に、発話文データベースを構築しておく。構築には、約半年分（2016/5/18~10/27）の Twitter データを使用した。

#### 3.2 話題語の設定、類似語の取得

発話文を生成する話題語を設定した。ここでは、[3]で登場する 19 種類の話題語ジャンルに関する話題語をそれぞれ 1 つずつ設定した。ここで、提案手法は少数話題において大きな意味を持つため、発話文データベースから発話文が 11 文以下しか取得できない話題語を選択した。実際に

A study on Automatic Utterance Generation Method for Minor Topics on Conversational Systems

Koji Takuwa†, Tomohiro Yoshikawa†, Felix Jimenez† and Takeshi Furuhashi†

†Nagoya University

選択した話題語とその発話文の数を表 1 第 1, 2 列に示す. 次に, 日本語 Wikipedia 全文より学習を行った分散表現を用いて, 類似語を取得した. 今回の実験では  $N=5$  (上位 5 単語) とした.

### 3.3 発話文の取得・生成

構築した発話文データベースから, 類似語を含む発話文を取得し, 単語の置換を行うことで発話文を生成した. 新たに生成された発話文の数を表 1 第 3 列に示す. 表 1 から, 多くの話題語では新たに多くの発話文が生成されたことがわかる. 各話題語を平均すると, 145 の発話文が新たに生成された.

表 1 話題語と発話文の数

話題語	発話文の数	生成された数
年末ジャンボ	6	38
パターゴルフ	3	17
エンタの神様	4	8
三億円事件	6	5
ダウンジャケット	7	780
トカゲモドキ	9	1
幸福の黄色いハンカチ	1	0
キマグレン	6	80
レイコップ	6	335
ひ孫	9	401
特定保健用食品	2	76
フレックスタイム制	3	60
バルーンアート	9	341
エスニック料理	6	348
職場恋愛	11	34
森絵都	4	8
ケーズデンキ	10	28
ビリーズブートキャンプ	5	10
ミステリーツアー	5	178

## 4 実験 2

### 4.1 置換前の無効な発話文の除去

生成された発話文には, 置換により無効となった発話文と, 置換する前から無効な発話文が含まれている. 本実験では, 提案手法の有効性を検証するため, 置換する前から無効となっている発話文はあらかじめ除去する.

まず, 各類似語を含む発話文を最大 100 文ずつ無作為に取得し, 有効無効の判定を行った. 大学生 3 名が個別に有効無効の判定を行い, 1 名でも無効と判定したものは除去した. その上で, 残った発話文に対し, 話題語への置換を行い, 生成された発話文の有効無効の判定を行った. こちらについては, 大学生 3 名が個別に有効無効

の判定を行い, 多数決により有効無効を決定した.

### 4.2 各発話文の $d_{max}$ の値の確認

各発話文に対する  $d_{max}$  の値を図 1 に示す.  $d_{max}$  の値が  $-1.2$  となっている発話文は, 名詞・形容詞・動詞が 1 つしか含まれておらず,  $d_{max}$  の値を計算することができなかった発話文である.




図 1 各発話と  $d_{max}$  の値との関係

図 1 より, 無効な発話文は期待通り高い  $d_{max}$  の値をとっていることがわかる. 有効な発話文と無効な発話文の  $d_{max}$  の値の平均はそれぞれ 0.46 と 0.66 であり, ウェルチの  $t$  検定により有意差が見られた ( $p$  値 =  $4.9 \times 10^{-9}$ ).

$thres=0.5$  として無効な発話文の除去を行うと, 除去前の無効な発話文の割合が 7.7% であるのに対し, 2.9% へと減少した. 類似語ごとのこの無効文割合に対する対応のある検定により, 有意差が見られた ( $p$  値 = 0.016).

## 4 おわりに

本稿では, ウェブ上で言及されにくい話題に対する発話文の自動生成手法を提案した. 実験の結果, 平均で 145 の発話文が新たに生成されたことを確認した. また, 置換により無効になってしまう発話文についても, 提案手法により無効な文の割合を削減できることを確認した.

今後は, 検索エンジンでの検索ヒット数などを併用することで, 無効な発話文の除去手法の精度を向上させる予定である.

### 参考文献

- [1] 稲葉通将, 神園彩香, and 高橋健一. "Twitter を用いた非タスク指向型対話システムのための発話候補文獲得." *人工知能学会論文誌* 29.1 (2014): 21-31.
- [2] Higashinaka, Ryuichiro, et al. "Syntactic filtering and content-based retrieval of Twitter sentences for the generation of system utterances in dialogue systems." *Situated Dialog in Speech-Based Human-Computer Interaction*. Springer International Publishing, 2016. 15-26.
- [3] Meguro, Toyomi, et al. "Controlling listening-oriented dialogue using partially observable Markov decision processes." *Proceedings of the 23rd international conference on computational linguistics*. Association for Computational Linguistics, 2010.