



- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

自己相互情報量を用いた特徴ご予測に基づき雑談応答生成

Shigeaki Onoda

Graduate School of Information Engineering, Toyama Prefectural University
t855005@st.pu-toyama.ac.jp

Friday., December 20, 2019,
Toyama Prefectural Univ.



1.1. 本研究の背景

背景

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

深層学習の発展と Twitter 等のソーシャルネットの発展により雑談対話システムを SNS 上に存在する会話データを用いて構築する取り組みが盛んに行われているそこで seq2seq を用いて流暢性の高い応答文を生成することが可能となっている

現状の課題

現状の手法では訓練時に単語単位で損失計算を行うため出力した単語の意味が妥当かどうかにかかわらず参照文と同じ単語でなければ損失は下がらない

そのため既存の応答文生成器では「そうですね」「わかる」といった高頻度の単語で構成される汎用的な応答ばかり生成してしまう



1.2. 本研究の目的

目的

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

本研究は PMI を用いてある入力発話文に対する応答として現れやすい特徴的な語彙を事前に予測するその結果を別の応答文生成器が含んでいた場合報酬を与えるよう損失関数改良することで自然かつ多様な語彙を出力できるような応答生成器を構築する



2.1. ニューラル対話モデル

特徴

- 1.
1. はじめに
2. 前提知識
3. 提案手法
4. 実験
4. Case Study
6. おわりに

- seq2seq を利用
- ネットワークに RNN を利用
- 単語単位の交差エントロピー損失により学習

これにより単語の順序を考慮しつつ流暢な文生成ができる反面正解しやすい（高頻度な）単語を多く出力する傾向がみられる



2.2. MMI-bidi

PMI

- 1.
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

この問題の解決のため手法として MMI-bidi がある

この手法は発話に対する相互情報量が高い応答を返すため発話文 Q と生成文 R の間 PMI を以下で近似している

$$PMI(Q, R) = (1 - \lambda) \log P(R|Q) + \lambda P(QR) \quad (1)$$

ここで $P(R|Q)$, $P(Q|R)$ はともに seq2seq で構築して $P(R|Q)$ モデルによって N-best の候補文を生成した後

上の式を用いてランキングを行うことで発話と共に強い応答を生成できている

欠点

N-best の生成において妥当性の高い単語が出力が生成されない場合は効果がない

そのため目的関数を改良することが必要



2.3. Gumbel-Softmax

設定

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

通常生成単語を選ぶ際は出力層に対して argmax 操作を行うことで確率分布から尤も確率の高い単語をサンプリングしていたしかし argmax は離散的で誤差逆伝播ができないので Gumbel-Softmax というものが提案された

$$y_i = \frac{\exp((\log(\pi_i) + g_i)/\tau)}{\sum_{j=1}^k \exp((\log(\pi_j) + g_j)/\tau)} \quad (2)$$

ここで τ は温度というハイパーパラメータ、小さいほどワンホットに近いベクトルが得られる

g_i は一様分布 $u_i \sim \text{Uniform}(0, 1)$ を用いて以下の計算によって得られる

$$g_i = -\log(-\log(u_i)) \quad (3)$$



3.1.

- 1.
1. はじめに
2. 前提知識
3. 提案手法
4. 実験
4. Case Study
6. おわりに

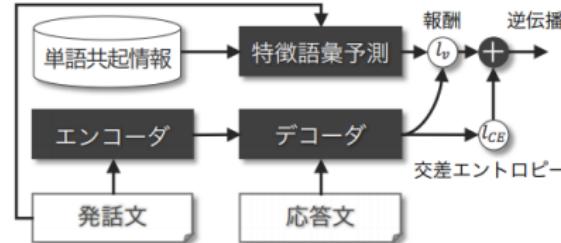


図 1: 提案手法の概要

設定

提案手法ではまず PMI に基づき入力発話と強く共起する特徴語彙を予測して次に Gumbel-Softmax を用いたデコーダが output した語彙をサンプリングする

最後にデコーダが生成した語が特徴語の割合を計算して損失関数に加える



3.2. PMI に基づき特徴語予測

設定

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

本研究では学習コーパス全体から PMI を計算してある入力に対する応答に現れやすい語彙を予測する単語 x が発話文、応答文中に現れる確率をそれぞれ $P_Q(x), P_R(x)$ とする
PMI は以下で計算する

$$PMI(x, y) = \log_2 \left(\frac{P(x, y)}{P_Q(x) \cdot P_R(y)} \right) \quad (4)$$



3.3. Gumbel-Softmax を用いた生成語彙の疑似サンプリング

設定

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

デコーダの各タイムステップ i におけるデコーダの出力 π に対して Gumbel-Softmax を以下のように適用

$$B = \sum_{i=1}^T \text{GumbelSoftmax}(\pi_i) \quad (5)$$



3.4. 損失関数の設計

設定

- 1.
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

予測語彙集合 V_{pred} 中の単語を生成すればするほど誤差を下げるような損失関数を設計する

式は以下のようになる。ここで $\min(b_n, 1)$ としているのは複数回単語を 1 回としてまとめるためである

$$l_v = - \sum_{n=0}^N f(b_n, V_{Pred}),$$
$$f(b_n, V_{Pred}) = \begin{cases} \min(b_n, 1) & (t(b_n) \in V_{Pred}), \\ 0 & (\text{otherwise}), \end{cases}$$

また損失関数 L は以下のようになる

l_{CE} は通常のデコーダの損失で交差エントロピー誤差である

$$L = (1 - \alpha) \cdot l_{CE} + \alpha \cdot l_v \quad (6)$$



4.1. 実験設定

設定

Twitter から収集した 130 万件の発話応答データのうち一万を検証、一万をテスト、残りを学習データとした

比較手法

- Proposal : 提案手法
- Proposal + MMI : 提案手法のデコード時に MMI-bidi を適用したモデル
- baseline : seq2seq によって構成されるオーソドックスな生成器
- MMI ; baseline のデコード時に MMI-bidi を適用したモデル



4.2. 実験結果

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験

4. Case Study
6. おわりに

表 1: 実験結果

	BLEU-1	BLEU-2	NIST	dist-1	dist-2
Proposal + MMI	8.970	2.881	0.618	0.025	0.063
Proposal	9.022	2.906	0.640	0.023	0.055
MMI	7.930	2.568	0.479	0.038	0.093
Baseline	7.833	2.527	0.484	0.035	0.082

表 2: 予測語彙使用率の比較

	使用率
Proposal + MMI	5.7%
MMI	5.0%

結果

提案手法は distinct が下がった一方で BLEU や NIST は大幅に上昇していることがわかった。

つまり語彙の多様性は低下するが妥当な内容語を多く生成できるようになっている

また表 2 の PMI による予測語彙の使用率も提案手法のが向上して



4.3. 実験結果

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに

表 3: 提案手法と比較手法の応答生成例

Input:	いっぱい絡んでいただけると嬉しいです
Proposal+MMI:	もちろんです！絡みましょー！
MMI:	こちらこそ！
Input:	これは絶対みた方がいいってアニメ教えて！
Proposal+MMI:	七つの大罪も見てみます！
MMI:	SAO の曲を聴いてみたいと思います！
Input:	昨日サンタさんに会ってきましたよ
Proposal+MMI:	おー！よかったね！私も会いたい！
MMI:	しゃしん

生成された応答文の一例

MMI では淡白な応答にたいして提案手法のほうが長文の生成に成功している

実際文長の平均も提案手法のほうが有意水準 1%で有意差が確認できた

また MMI はアニメに対して「SAO」と妥当な返答をできているが「見た」と動詞に妥当な返答ができていないそれに対して提案手法は発話の動詞に対して妥当な返答ができている



5. おわりに

- 1.
1. はじめに
2. 前提知識
3. 提案手法
- 4 実験
4. Case Study
6. おわりに



NN 応答生成器が応答として自然さを持ちつつ多様な応答を生成できるように PMI に基づく特徴語予測用いて生成する語のヒントを与えるながら学習する手法を提案した今後は人手評価などの定性的な分析を進め、文単位の共起強さを評価しそれが大きくなるように学習したい

ご清聴ありがとうございました。