

生成文の文脈に応じ動的に変化する損失関数による 多様な対話応答生成

上山 彩夏

狩野 芳伸

静岡大学 情報学部

aueyama@kanolab.net, kano@inf.shizuoka.ac.jp

1 はじめに

近年、深層学習を用いた対話システムを構築する研究が活発に行われている。中でも、再帰型ニューラルネットワーク (Recurrent Neural Network; RNN) を使わず、Attention と Feed-Forward Network を使用した Transformer [1]モデルに対して、ソーシャルネットワークサービス (SNS) 上の対話データを学習する手法は、ユーザの発話に対して比較的流暢な応答文を生成することが出来るため、対話システムとして良い性能を達成している。

しかし、単に対話データを学習させるだけでは応答文の多様性が低いという問題がある。表 1 に対話例を示す。3)の発話文と 5)の発話文に対して、4)の応答文と 6)の応答文は同一である。参照正解文との近さのみで計算する損失関数で学習した対話システムでは、頻出フレーズは希少フレーズに比べ、大きな生起確率が割り当てられやすくなるため、このような問題が生じる。

対話応答生成の多様化の手法として、ニューラル機械翻訳 (Neural Machine Translation; NMT) [2]や句に基づく統計的機械翻訳 (Phrase-based Machine Translation; PBMT) [3]を利用した対話応答生成モデルも存在する[4]。佐藤らの研究[5]では、PBMT 応答生成モデルが応答を生成し、NMT モデルが生成された応答と元の入力発話

表 1 多様性の低いシステム発話例

1) <i>User</i>	おはよう
2) <i>System</i>	おはよう!
3) <i>User</i>	今日、寒くない?
4) <i>System</i>	それな w
5) <i>User</i>	お腹すいた?
6) <i>System</i>	それな

の両方を入力として受け取り、応答を再生成する手法により、多様な応答生成を試みた。

Nakamura らの研究[6]では、学習データの不均衡を考慮せず、すべての単語を同等に扱う Softmax Cross Entropy 損失 (以下 SCE 損失と表記) がこの問題に起因するとして、新たに Inverse Token Frequency 損失 (以下 ITF 損失と表記) を提案し、対話の多様性の向上を確認した。ITF 損失とは、トークンの頻度の逆数に基づく重みを SCE 損失にかけた損失関数である。各トークンクラスの勾配を調節できるため、希少トークンがより出現しやすくなるような学習を行える。

しかし、文章の多様性においては、独立したトークンの情報だけでなく、トークンの並びを取り入れた頻度も考慮することで、文脈に応じ動的に変化する重みを計算し、求める多様性をより適切に表せると考えられる。そこで本研究では、トークンの頻度ではなく、トークンの n -gram の頻度の逆数に基づいて重みづけする

損失関数 Inverse N-gram Frequency 損失（以下 INF 損失と表記）を提案する。

その実装として、Twitter から抽出した大規模な対話データで学習した INF 損失を利用したニューラル対話システムを構築する。

評価実験として、SCE 損失、ITF 損失、INF 損失を損失関数として利用したモデルを対話応答の多様性の観点から評価を行った。提案手法の INF 損失モデルは、SCE 損失や ITF 損失モデルに比べて、優位な改善が確認され、ITF 損失モデルよりも多様な応答が生成されることを示した。

2 従来手法

2.1 Softmax Cross Entropy 損失

Sequence to Sequence (seq2seq) モデル [7] の訓練に利用される SCE 損失は以下の式によって表される。

$$\text{softmax}_c = \frac{e^{d_c}}{\sum_k e^{d_k}} \quad (1)$$

$$L_{SCE} = -\log \{\text{softmax}_c\} \quad (2)$$

V は語彙、 d_k はデコーダによる出力 $d \in \mathbb{R}^{|V|}$ の k 番目の要素である。また、 c はターゲットとなるトークンのクラスのインデックスを示す。SCE 損失は、(1) の softmax 関数に対して、(2) の交差エントロピーを適用した損失関数である。

2.2 Inverse Token Frequency 損失

Nakamura ら [2] の手法では、ITF 損失は以下の式によって表される。

$$L_{ITF} = w_c L_{SCE} \quad (3)$$

$$w_c = \frac{1}{\text{freq}(\text{token}_c)^\lambda} \quad (4)$$

w_c は重み $w \in \mathbb{R}^{|V|}$ のうちクラス c に対応する要素、 token_c はクラス c に対応するトークン、 $\text{freq}(\text{token}_c)$ は token_c が訓練データ内で現れる

回数を数える関数である。 λ は頻度の調整を行うハイパーパラメータである。本研究では、 $\lambda = 0.4$ とした。そして、ニューラル対話システムに ITF 損失を適用することで、より多様な文を生成させた。

3 提案手法

本研究では、ITF 損失に代わる新たな損失関数として INF 損失を提案する。INF 損失は以下の式で表すことが出来る。

$$L_{ICF} = w_c L_{SCE} \quad (5)$$

$$w_c = \frac{1}{\text{freq}\{\text{ngram}_c(n)\}^\lambda} \quad (6)$$

$\text{ngram}_c(n)$ は訓練データ内の連続する n 個 ($n \in \mathbb{N}, n \geq 2$) のトークンを表す。このように w_c は文脈に応じて、動的に変化することになる。

<BOS> や <EOS> (beginning of sentence と end of sentence の略記) 等の特殊記号は他の通常トークンと同様に処理する。しかし、<BOS> や <EOS> は全文で出現するため、これらが出現する場合の損失関数の重みが極めて小さい値になるように設定した。

文頭及び文末付近には、 $n-1$ 個の <NORM> という特殊記号を追加して、パディングした。 λ は ITF 損失と同様で、 $\lambda = 0.4$ とした。

4 実験

3 節で示した提案手法に対するベースラインモデルとして、2.1 節で示した SCE 応答生成モデル (以下 SCE と表記)、2.2 節で示した ITF 応答生成モデル (以下 ITF と表記) を用いた。これら SCE、ITF では、損失関数を除いたモデル設定は提案手法と同一である。

SCE と ITF 及び INF 応答生成モデル (以下 INF と表記) を用いて実験を行い、その結果を

表 3 自動評価及び人手評価結果

モデル	Perplexity	BLEU-1	BLEU-2	distinct-1	distinct-2	ROUGE-1	ROUGE-2	人手評価
SCE	5792	6.114	0.009621	0.01066	0.03758	0.03063	0.006335	3.280
ITF	3779	4.599	0.006414	0.05461	0.1453	0.03481	0.002501	2.973
INF	147.8	5.151	0.003207	0.06177	0.2512	0.03796	0.001936	3.547

表 2 応答生成の出力例

発話文	寿司食べる！！	発話文	お疲れ様。明日会えるの楽しみだ。
正解文	私もこれから寿司食べる。	正解文	ありがとうー！！私も楽しみ！
SCE	やばすぎw	SCE	ありがとう。
ITF	寿司すき	ITF	明日もあるから楽しみ
INF	寿司屋さんならどこ？	INF	ありがとう、明日も死ぬほど楽しみ

比較・分析することにより、INF 損失の効果を検証した。

4.1 データセット

本研究では Twitter リプライから抽出した対話データを利用した。対話データは複数の発話により構成されているが、本研究ではシングルターンでの対話応答生成を行うため、隣接する発話を[発話文, 応答文]として、データセットを構築した。訓練セットは 40 万対話ペアである。訓練セットを用いて、語彙数 32000 の SentencePiece[8]を学習し、この SentencePiece モデルを利用して、訓練セットのサブワードへのトークン化を行った。検証セット及びテストセットはそれぞれ 1024 対話ペアとした。

4.2 モデル設定

提案手法及びベースライン手法の全てのモデルに共通する設定は以下の通りである。

Encoder, Decoder は共に 6 層の Transformer, Multi-Head Attention の head 数は 8, トークン埋め込み次元は 512, Dropout の比率は 0.1 とした。学習時のパラメータの最適化手法には Adam[9]を利用し, Adam の学習率は 0.001 とし

た。また、INF 損失に対して、訓練セットのトークンの bi-gram を利用したモデル (以下 INF と表記) を提案手法のモデルとした。

4.3 結果

各モデルにより生成された応答文を Perplexity, BLEU[10], distinct[11], ROUGE[12]の指標で評価した結果と人手で評価した結果を表 2 に示した。人手評価では、15 人の評価者に Twitter における 2 人の対話を提示した。評価者は発話文に対する人間の応答文と各モデルにより生成された応答文が首尾一貫した応答かどうかを 1~5 点で評価した。表 2 では、その平均値を示している。また、生成された応答文の例は表 3 に示す。

表 2 より、Perplexity において、INF は SCE 及び ITF に比べて優れた数値を示している。これはベースラインと比較して、INF が流暢な文を生成していることを意味する。

BLEU や ROUGE では、SCE が INF と ITF のスコアを上回っている。これはビームサーチを行っていないことが原因であると考えられる。また、表 3 より、SCE の応答文が他のモデルに比べて短い点も、優れた数値を示した理

由だと考えられる。

続いて、生成された応答文の多様性については、**INF** がいずれの **distinct** においても、優れた数値を示している。さらに、**distinct-2** については、**INF** が 0.2512 と、**SCE** と **ITF** のスコアを大きく上回っている。**distinct** は、すべての生成文に含まれる **n-gram** のうち異なる **n-gram** の割合を計算する。よって、この結果は **INF** がトークンの並びも考慮した、より多様な応答文の生成を可能にしたことを示していると考えられる。

最後に、人手評価については、**INF** が最も優れたスコアを示している。表 3 より、**SCE** は「やばすぎw」や「それな」といった文脈依存性の低い応答文を生成する傾向があった。**ITF** は意味的に誤りのない応答文を生成したが、**INF** と比較すると、**INF** のほうが多様な応答を生成していることが確認できる。

5 おわりに

本研究では多様な応答を生成する手法として、トークン単位の **n-gram** の頻度の逆数に基づいて重みづけする **INF** 損失を提案した。提案手法はベースライン手法と比較して、文脈的一貫性を向上しつつ、多様な応答文を生成することを確認した。

今後の課題として、トークンの **bi-gram** のみでなく、**3-gram** を利用したモデルの評価や、データ量を増やすこと、**Transformer** 以外のモデルを利用することが考えられる。

将来的には、複数の手法を組み合わせ、多様性があり流暢な応答文を生成できるニューラル対話システムの実現を目指したい。

参考文献

- [1] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin. “Attention is all you need”. In: *Advances in Neural Information Processing Systems*, pp. 5998-6008, 2017
- [2] 中澤敏明, 機械翻訳の新しいパラダイム: ニューラル機械翻訳の原理, 情報管理 – Vol.60, No.5, pp. 299-306, 2017
- [3] Philipp Koehn, Franz Josef Och, and Daniel Marcu. “Statistical Phrase-based Translation”. In: *Proceedings of the 2003 Conference of the North American Chapter of the ACL on Human Language Technology - Volume 1*, pp. 48-54, 2003.
- [4] Alan Ritter, Colin Cherry, and William B. Dolan. “DataDriven Response Generation in Social Media”. In: *Proceedings of the 2011 Conference on Empirical Methods in Natural Language Processing*, pp. 583-593, 2011
- [5] 佐藤志貴, 大内啓樹, 井之上直也, 鈴木潤, 乾健太郎, フレーズ単位の発話応答ペアを用いた対話応答生成の多様化, 言語処理学会 第 25 回年次大会, 2019
- [6] Ryo Nakamura, Katsuhito Sudoh, Koichiro Yoshino, and Satoshi Nakamura. Another diversity promoting objective function for neural dialogue generation. *arXiv preprint arXiv:1811.08100*, 2018
- [7] Ilya Sutskever, Oriol Vinyals, and Quoc V Le. “Sequence to Sequence Learning with Neural Networks”. In: *Advances in Neural Information Processing Systems*, pp. 3104-3111, 2014
- [8] Kudo, T, and Richardson. “SentencePiece: A simple and language independent subword tokenizer and detokenizer for Neural Text Processing”, In: *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*, pp. 66-71, 2018
- [9] Diederik P. Kingma, and Jimmy Ba. “Adam: A Method for Stochastic Optimization”, In: *Proceedings of the third International Conference on Learning Representations*, 2015
- [10] Kishore Papineni, Salim Roukos, Todd Ward, and Wei-Jing Zhu. “BLEU: a Method for Automatic Evaluation of Machine Translation” In: *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics*, pp. 311-318, 2002.
- [11] Jiwei Li, Michel Galley, Chris Brockett, Jianfeng Gao, and Bill Dolan. “A Diversity-Promoting Objective Function for Neural Conversation Models” In: *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pp. 110-119, 2016
- [12] Chin-Yew Lin. Rouge: A package for automatic evaluation of summaries. In: *Proceedings of the ACL 2004 Workshop on Text Summarization Branches Out*, pp. 74-81, 2004.