

対話行為を導入した GPT による対話システムの構築

林益 (名古屋工業大学) 田口亮 (名古屋工業大学)

y.lin.635@nitech.jp, taguchi.ryo@nitech.ac.jp

1 はじめに

近年, Apple社の「Siri」, Google社の「Dialogflow」, 日本マイクロソフト社の「りんな」などの知能的な対話システムが提供されている. 対話システムを構築する手法は主に検索ベース手法と生成ベース手法がある. 検索ベース手法は, あらかじめ用意された応答データベースから検索アルゴリズムで発話文の応答として相応しい応答を抽出する手法である. 生成ベース手法は, Seq2Seq[1]などのEncoder-Decoder構造のモデルのEncoder部に発話文を入力し, Decoder部による逐次的な単語選択で応答文を生成する手法である. 本研究では生成ベースの対話システムに着目する.

生成ベースの対話システムは急速に進歩しているが, 多様性の低い応答文や一般的な応答文 (例えばI don't knowなど) を生成する傾向があることをLiら[2]が指摘している. この問題は, 学習データセットに一般的な応答が高頻度で存在し, その応答が多様な発話文に対応できることに起因する. この問題点を解決するために, 近年二つの方向の解決手法が提案されている. 一つ目は, 生成ベースモデルの改良である. 元のEncoder-Decoder構造のモデルを, Serban[3]らは強化学習, Caoら[4]はVAE, Liら[5]は目的関数の改良により応答の多様性を向上した. 二つ目は, 多様な対話情報の入力である. Serbanら[6]は対話履歴の入力, Zhouら[7]はエモーション情報の入力, Zhangら[8]は話者の個性 (personality) の入力, Kumarら[9]は対話行為の入力により応答の多様性を向上する.

本研究では, (1)現在, 自然言語処理研究で注目されている事前学習モデルのGPT[10]を対話生成タスクにFine-tuningすることで既存のEncoder-Decoderモデルより応答性能の向上を示す. さらに, (2)対話行為情報をGPTモデルに入力することで, GPTモデルの応答生成性能の向上を示す. そして, (3)同じ発話文に対して, 応答文の異なる対話行為を定義することで, 表1のような異なる対話行為の応答を生成することを旨とする.

2 先行研究

2.1 Seq2Seq と注意機構

表1 異なる対話行為による応答の生成

発話文:

I really need to start eating healthier.

応答文 (Inform) :

I know. I have been on a diet for a long time.

応答文 (Question) :

What are you going to do about it?

応答文 (Directive) :

You should start eating fewer foods.

応答文 (Commissive) :

I know. I know.

Sutuseverら[1]はSeq2Seq (Sequence-to-Sequence) という LSTM を用いた系列変換モデルを提案した. Seq2Seq は Encoder と Decoder の二つの RNN から構成される. 入力系列を Encoder で読み込み, 入力系列が読み終わると Decoder の隠れ層の初期値が Encoder の隠れ層の最終値で設定され, Decoder は出力終了を意味する<eos>を出力するまでに出力系列を逐次的に出力を続ける. Encoder に双方向 RNN を使用することで入力系列全体の特徴表現を抽出する性能が向上される.

しかし, Seq2Seq モデルは入力系列を固定長のベクトルでしか表現できないため, 入力系列が長いほど Decoder がデコードするパフォーマンスが悪化するという問題がある. この問題点に対して, Luongら[11]は注意機構をSeq2Seqモデルに応用した. 注意機構は, Encoder の各時刻の隠れ層値をメモリに保持し, Decoder がデコードする時にメモリを参照する機構である. 注意機構の逐次的なメモリ参照により, モデルのデコードする性能を改善した.

2.2 GPT

Radfordら[10]はGPT (Generative Pre-Training) という Transformer の Decoder 部を用いた事前学習言語モデルを提案した. GPT の言語モデルの事前学習は7000冊の本から構成される BooksCorpus データで, 次単語を予測できるように学習を行う.

GPT の Fine-tuning は Multi-task 学習になっており, 特定タスクのコーパスの言語モデルとタスクラベルの両方を学習する. 教師ありデータ $C = \{x_1, \dots, x_m, y\}$ を与える場合, 言語モデルの目的関数 L_1 は式(1)で表される. Φ は GPT のパラメーターを表す.

$$L_1 = \sum_i \log P(x_i | x_1, \dots, x_{i-1}; \Phi) \quad (1)$$

タスクラベルの学習は、言語モデルの最終層とタスク固有層を付け加えたニューラルネットワークを使ってラベルありの特定タスクを解き、言語モデルとタスク固有層のパラメータを適応させる。特定タスクの目的関数 L_2 を式(2)に示す。 h_m^l は最終時刻のGPT最終層の隠れ層、 W は固有層のパラメータを表す。

$$L_2 = \sum_{(x,y)} \log P(y|x_1, \dots, x_m) \quad (2)$$

$$P(y|x_1, \dots, x_m) = \text{softmax}(h_m^l W)$$

GPTのFine-tuning目的関数 L_3 は、言語モデル目的関数 L_1 と特定のタスクの目的関数 L_2 の重み和で表す。

$$L_3 = \lambda_1 L_1 + \lambda_2 L_2 \quad (3)$$

3 提案手法

3.1 対話行為

Amanovaら[12]は Inform, Question, Directive, Commissive という4つの対話行為を定義した。Informは受け手が知らない情報を話者が提供する行為を表す。Questionは質問行為で、話者が知らない、確信していない情報を相手から引き出す行為を表す。Directiveは話者が要求、指導、提案、受け入れ・拒否(accept/reject)を相手に提供する行為である。Commissiveは話者が要求、受け入れ・拒否(accept/reject)に対する態度や約束を表す行為である。

3.2 GPTを対話システムへの応用

Wolfら[17]はGPTを最初に対話システムに応用したTransferTransfoというフレームワークを提案した。GPTの入力系列は単語Embeddingと位置Embeddingの埋め込みの総和で処理を行うが、発話者と応答者を分別するために、セグメントEmbeddingをGPTモデルに加えた。対話データをFine-tuningする方法を図1に示す。

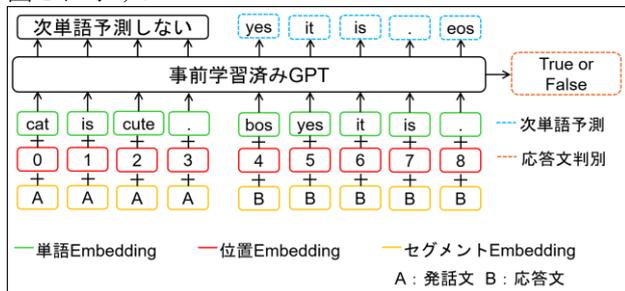


図1 対話タスクにおけるGPTのFine-tuning

対話タスクにFine-tuningする言語モデルは条件付き言語モデルで表され、モデルが発話文を読み込む場合には次単語予測を行わず、応答文だけ次単語予測を行う。特定タスクの学習では、学習データの中に存在する発話文と応答文のペアを正例、発話文とランダムに抽出した応答文のペアを負例として応答文判別学習を行う。最終的なFine-tuningの損失関数は、

応答文の条件付き言語モデルの損失と、発話文に対応する応答文の判別損失の重み和となる。

3.3 対話行為を入力したGPTのFine-tuning

本研究では、TransferTransfoを参考にして、対話行為情報を入力するために対話行為を表現する対話行為EmbeddingをGPT入力Embedding層に追加した。入力系列のEmbeddingは、単語の意味を表現する「単語Embedding」、単語の順番情報を表す「位置Embedding」、発話文と応答文の分別する「セグメントEmbedding」、対話行為情報を表現する「対話行為Embedding」の埋め込みの総和である。対話行為を入力するGPTをFine-tuningする方法を図2に示す。Fine-tuning時のMulti-task学習はTransferTransfoと同様である。

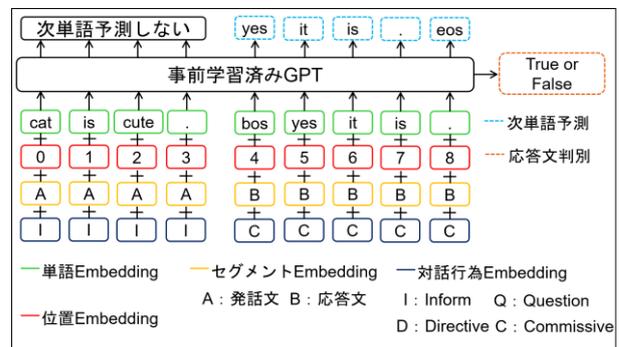


図2 対話行為を入力したGPTのFine-tuning

4 評価実験

4.1 データセット

本研究では対話行為をラベリングしたDaily Dialog[13]をデータセットに用いる。本コーパスは、13,118ラウンドの対話で、シングルラウンドの対話データに変換すると72,759ペアになる。データでの各対話行為の割合はInform(44.7%)、Question(28.5%)、Directives(16.9%)、Commissive(9.8%)である。全データを学習データ61528ペア、検証データ5794ペア、テストデータ5437ペアに分け使用する。

4.2 評価方法

応答性能はBleuスコア、distinct-n、センテンスベクトルコサイン類似度により評価を行う。

Bleuスコアは、生成文とターゲット文の類似度を両者のn-gram一致率で計る手法で、式(4)により計算する。 p_n はn-gramの一致率、 BP は生成文がターゲット文より短い場合のペナルティである。

$$BLEU = BP \cdot \exp\left(\sum_{n=1}^N (1/N) \log p_n\right) \quad (4)$$

生成文とターゲット文の3-gramや4-gramの一致率が低いため、本研究では1-gram、2-gramの一致率を評価するBleu-1、Bleu-2のみを用いる。

Bleuスコアでは“How old are you?”と“What is your

age?”のように、意味が同じでも n-gram が一致しないという欠点があるため、Universal Sentence Encoder[14]から出力された生成文とターゲット文のセンテンスベクトルコサイン類似度を計算する評価 (USE-sim) も行う。

また、生成文の多様性を評価するために distinct-n[5]による評価を行う。distinct-n はテストデータに対して生成文の集合におけるユニークな n-gram の数を全ての n-gram の数でスケールした指標である。本研究では 1-gram, 2-gram の多様性を評価する distinct-1 と distinct-2 のみを用いる。

4.3 実験設定

比較する既存の Encoder-Decoder モデルは Seq2Seq, Seq2Seq-bi (Encoder 部が双方向 RNN), Attention (注意機構を用いた Seq2Seq), Attention-bi (注意機構 + Encoder 部が双方向 RNN) である。四つのモデルの RNN ユニットは LSTM, レイヤ数は 1, 隠れ層の次元は 512, 単語 Embedding の次元は 300 に設定した。トレーニングのバッチサイズは 128, Optimizer は Adam, 学習率は 0.01, Seq2Seq と Seq2Seq-bi の epoch 数は 30, Att-Seq2Seq と Att-Seq2Seq-bi の epoch 数は 60 に設定した。

GPT を用いたモデルは, GPT-no (対話行為を入力しない場合) と GPT-act (対話行為を入力する場合) を比較する。事前学習した GPT モデルは公開されている gpt-2[15], トレーニングのバッチサイズは 8, Optimizer は Adam, 学習率は 0.001, epoch 数は 10 に設定する。また, 式(3)の λ_1 を 2, 応答文判別する時の負例の数を 2 に設定した。

5 実験結果

5.1 応答生成性能評価

実験結果を表 2, 表 3 に示す。GPT を用いた対話システム GPT-no は最良の既存 Encoder-Decoder モデルの Attention-bi より USE-sim, distinct-2 が大きく上回った。GPT を用いた対話システムは既存 Encoder-Decoder より, distinct-1 で 0.0512 ポイント, distinct-2 で 0.201 ポイント, 応答生成性能 (特に多様性) が向上した。また, 対話行為を入力する GPT-act は GPT-no より Bleu スコアと USE-sim の改善が見られた, 多様性を表す distinct-1, distinct-2 では大きな改善は見られなかった。

5.2 異なる対話行為の応答生成

同じ発話文に対して, 応答文の異なる対話行為を定義し, 異なる対話行為の応答が生成可能か検討する。評価は 5437 の発話文に対して行い, テストデータの生成は, 発話文ごとに Inform, Question, Directive, Commissive の対話行為を順番に入力し計 21748 の応答文を生成した。学習したモデルが定義された応答の対話行為により生成した応答文がその対話行為かを評価するためには, 対話行為の判別器が必要であ

表 2 生成文とターゲット文の類似度評価結果

	Bleu-1	Bleu-2	USE-sim
Seq2Seq	0.1480	0.0156	0.2766
Seq2Seq-bi	0.1524	0.0120	0.2846
Attention	0.1801	0.0261	0.2957
Attention-bi	0.1855	0.0309	0.2995
GPT-no	0.1996	0.0664	0.3815
GPT-act	0.2253	0.0721	0.4207

表 3 生成文の多様性評価結果

	distinct-1	distinct-2
Seq2Seq	0.0046	0.0069
Seq2Seq-bi	0.0068	0.0199
Attention	0.0072	0.0279
Attention-bi	0.0116	0.0572
GPT-no	0.0628	0.2582
GPT-act	0.0655	0.2629

る。人で評価すると高いコストがかかるため, 事前に Bert[16]を用いた対話行為判別器を学習した。学習した Bert の対話行為判別器の正解率は 82.6%に達成した。そして, 生成した応答を判別器に入力し, 定義した対話行為のラベルと比較し, 正解率と誤った応答文を生成する割合の分布を求めた。その結果を Confusion Matrix で表し, 図 3 に示す。

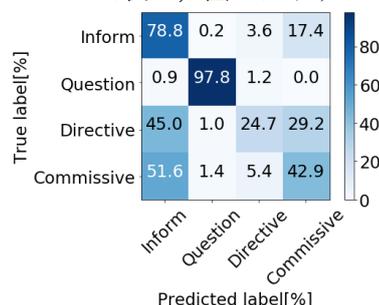


図 3 全テストデータの Confusion Matrix

図 3 の結果から, Inform と Question の正解率は 78.8%と 97.8%となり, モデルが Inform と Question の特徴をよく把握し, 文生成できていることがわかる。一方, Directive と Commissive の場合, 正解率は 24.7%と 42.9%で, 生成した応答が Inform と誤判定された割合が 45.0%と 51.5%であり, 学習データ内の分布の偏りにより, それぞれの文の特徴がうまく学習できていないと考えられる。

また, 発話の対話行為が異なる対話行為の応答生成に影響するのかを検討するために, 発話文の対話行為が Inform, Question, Directive, Commissive の場合の正解率と誤解の割合分布の Confusion Matrix を図 4 から図 7 に示す。図 4 から図 7 の結果から, 発話文の対話行為がどのような場合でも, 対話行為が Question の応答文が生成できる。その生成した例を表 4 に示す。

一方, 発話文の対話行為が Directive の場合, 対話

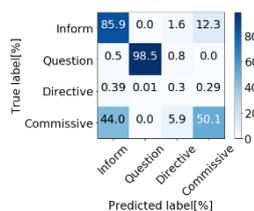


図4 発話文の対話行為が Inform の場合

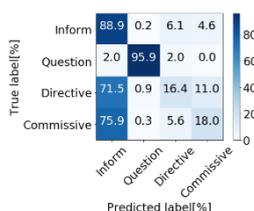


図5 発話文の対話行為が Question の場合

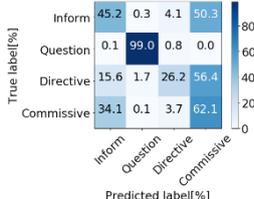


図6 発話文の対話行為が Directive の場合

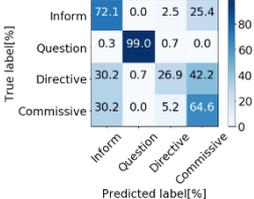


図7 発話文の対話行為が Commissive の場合

表4 異なる対話行為の発話文に対する対話行為が Question の応答文生成例

発話文 (Inform) :

I am sorry I am so late. I had a really bad day.

応答文 :

What happened?

発話文 (Question) :

That's excellent. How have you managed that?

応答文 :

I have been working very hard. How about you?

発話文 (Directive) :

Would you tell me something about your family?

応答文 :

I'm not sure. What do you do?

発話文 (Commissive) :

Thanks. I will be right back.

応答文 :

Do you have any more question?

行為が Inform の応答文を生成する正解率が図3 ベースラインの 78.8%から 45.2%に下がり、対話行為が Commissive の応答文を生成する正解率がベースラインの 42.9%から 62.1%に向上した。この結果より、発話文の対話行為が Directive の場合、対話行為が Commissive の応答文生成が可能だが、Inform の応答文生成は困難であることがわかる。

また、発話文の対話行為が Question の場合、対話行為が Commissive と Directive の応答文を生成する正解率は 18.0%と 16.4%であり、対話行為が Commissive と Directive の応答文生成は困難であることがわかる。

6 終わりに

本研究では、対話行為をラベリングした対話データを用いて GPT を Fine-tuning する手法を提案し、既

存の Encoder-Decoder モデルより高い応答生成性能を達成した。さらに、「対話行為 Embedding」を加え、対話行為の学習も可能になった。しかし、同じ発話文に対する異なる対話行為の応答文の生成では、Inform と Question の応答文生成は可能だが、Directive と Commissive の応答文生成は困難であることが示された。今後はこの問題点を解決するとともに、他の対話情報 (エモーション、トピックなど) も利用できる総合的な対話システムの検討を進める予定である。

参考文献

- [1] Sutskever, Vinyals, et al. : "Sequence to Sequence learning with Neural Networks", arXiv:1409.3215, 2014.
- [2] Li, Monroe, et al. : "Deep Reinforcement Learning for Dialogue Generation", arXiv:1606.01541, 2016.
- [3] Serban, Sankar, et al. : "A Deep Reinforcement Learning Chatbot", arXiv:1709.02349, 2017
- [4] Cao, Clark, et al. : "Latent Variable Dialogue Models and their Diversity", arXiv:1508.04025, 2015
- [5] Li, Galley, et al. : "A Diversity-Promoting Objective Function for Neural Conversation Models", arXiv:1510.03055, 2015
- [6] Serban, Sordoni, et al. : "A Hierarchical Latent Variable Encoder-Decoder Model for Generating Dialogues", arXiv:1605.06069, 2016
- [7] Zhou, Huang, et al. : "Emotional Chatting Machine: Emotional Conversation Generation with Internal and External Memory", arXiv:1704.01074, 2017
- [8] Zhang, Dinan, et al. : "Personalizing Dialogue Agents: I have a dog, do you have pets too?", arXiv:1801.07243, 2018
- [9] Kumar, Agarwal, et al. : "Dialogue-act-driven conversation model: An experimental study", Proc, COLING2018, pp.1246-1256, 2018
- [10] Radford, Narasimhan, et al. : "Improving Language Understanding by Generative Pre-Training", 2018
- [11] Luong, Pham, et al. : "Effective Approaches to Attention-based Neural Machine Translation", arXiv:1508.04025, 2015
- [12] Amanova, Petukhova, et al. : "Creating annotated dialogue resources: Cross-domain dialogue act classification", In LREC, 2016
- [13] Li, Su, et al. : "DailyDialog: A Manually Labelled Multi-turn Dialogue Dataset", arXiv:1710.03957, 2017
- [14] Cer, Yang, et al. : "Universal Sentence Encoder", arXiv:1803.11175, 2018
- [15] Radford, Wu, et al. : "Language Models are Unsupervised Multitask Learners", OpenAI Blog, 2019
- [16] Devlin, Chang, et al. : "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding", arXiv:1810.04805, 2018
- [17] Wolf, Sanh, et al. : "TransferTransfo: A Transfer Learning Approach for Neural Network Based Conversational Agents", arXiv:1901.18149, 2019