

条件付き敵対的生成ネットワークを用いた データ拡張による対話行為分類法の検討

河野 誠也^{1,a)} 吉野 幸一郎^{2,b)} 中村 哲^{1,c)}

概要: 対話行為分類は、ユーザの発話における「意図」を分類するタスクであり、対話システムにおいて対話制御を行うための重要な構成要素の一つである。対話行為分類の手法としては、教師あり学習を用いた手法が既に数多く提案されている。しかしながら、教師あり学習により高精度な対話行為分類器を訓練するためには多くの人手でアノテーションされた学習データが必要となる。こうした人手によるアノテーション作業には多くのコストがかかるため、訓練データの拡張は容易ではない。そこで本研究では、条件付き敵対的生成ネットワークを用いた発話生成モデルを構築し、任意の対話行為に対して高品質な発話の自動生成を行い学習データの拡張を行う。また、拡張した学習データで訓練を行った対話行為分類モデルの性能が改善されることを示す。

キーワード: 対話行為, 対話行為分類, データ拡張, 敵対的生成ネットワーク

1. はじめに

対話行為分類 (Dialogue act classification) は、ユーザの発話における「意図」を分類するタスク [1] であり、対話システムにおいて対話制御を行うための重要な構成要素の一つであることが知られている [2]。ここで、対話行為 (Dialogue act) とは、話者が発話において持つ何かしらの「意図」あるいは発話における「機能」であり、その意図や機能の種類として対話行為タグが定義される。一般に対話行為分類のタスクは、対話における話者の発話に対して、既知の対話行為タグのいずれかを付与する多クラス分類問題として扱われる。対話行為の分類手法としては、教師あり学習を用いた手法が既に数多く提案されている [3], [4]。しかしながら、教師あり学習による手法は訓練データとなる発話集合への対話行為のアノテーションが必要であり、高精度な対話行為分類器を訓練するためには多くの学習データが必要となる。こうした、人手によるアノテーション作業には多くのコストがかかるため、訓練データの拡張は容易ではない [5]。

そこで、本研究では、条件付き敵対的生成ネットワーク

を用いた発話生成モデルを構築し、任意の対話行為に対して高品質な発話の自動生成を行うことで学習データを自動拡張する。また、拡張した学習データにより訓練された対話行為分類モデルの対話行為分類精度が従来手法と比較して改善されることを示す。

本稿の構成は次の通りである。2章では、関連研究について述べる。3章では、本研究で用いたベースライン及び提案手法について述べる。4章において、評価実験の概要について述べる。5章において、評価実験の結果について述べ、その考察を行う。最後に6章において本稿のまとめを行う。

2. 関連研究

2.1 置き換えベースアプローチ

テキスト分類のタスクにおけるデータ拡張の手法としては、訓練データとなるテキスト中の単語を別の任意の単語に置き換えることでデータ拡張を行う手法 (置き換えベース) が良く知られている。例えば、WordNet などのシソーラスや単語類似度計算に基づいて選択された同義語で単語を置き換える手法などがある [6], [7]。実際には、同義語が存在するような単語を含むテキストの割合が少ない場合、置き換えによるデータ拡張の適用事例は限られたものになる。また、対話行為分類のような対話システムにおける言語理解タスクは、文脈、履歴の考慮が重要である [8]。データ拡張手法をこうしたタスクに適用するためには、分類対

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology

² 科学技術振興機構
Japan Science and Technology Agency

a) kawano.seiya.kj0@is.naist.jp

b) koichiro@is.naist.jp

c) s-nakamura@is.naist.jp

象のテキストだけではなく、文脈においても一貫性を考慮した単語の置き換えを行うことが必要となる。そのため、置き換えベースの手法の適用可能な事例はより少なくなる。また、置き換えベースの手法では、文全体の構造が全く異なるようなテキストの生成を行うことが困難であり、データ拡張により新しく生成されるテキストの多様性を確保することが難しい。そこで、本研究では、ニューラルネットワークを用いた生成モデルによるデータ拡張の手法(生成ベース)に着目する。

2.2 生成ベースアプローチ

対話システムにおける言語理解に生成ベースのアプローチを適用した事例としては、Houらによる研究がある[9]。Houらは、ATISにおけスロットフィリングのタスクにおいてデータ拡張を行うために、Encoder-Decoderモデルを導入している。具体的には、まずスロットに基づいて応答発話文のテンプレート化を行ったうえでEncoder-Decoderモデルを訓練し、応答発話の自動生成を行っている。また、テンプレート化された応答発話を、編集距離に基づいたランキングにより復元することでデータ拡張を行っている。この拡張データを用いることで、スロットフィリングにおけるスロットの認識精度が有意に改善したことを報告している。しかしながら、Houらの手法は、発話のテンプレート化を行うことが可能なスロットフィリングなどの限られたタスクのみで有効であるため、対話行為のような文全体の意図について分類するようなタスクにおけるデータ拡張には適用できない。

また、Encoder-Decoderモデルを用いた応答生成の問題点として、あらゆる入力発話に対して過度に一般化された応答(例えば、“I don't know”, “yes”など)を返すという問題が知られている[10]。この問題は、タスク志向対話における応答生成モデルと比較して、オープンドメインにおける応答生成モデルで顕著である。この問題に対して、敵対的生成ネットワーク(Generative adversarial Net; GAN)を導入することで、より多様かつ高品質な応答生成モデルの構築が試みられている[11]。具体的には、応答発話を生成するGeneratorと、与えられた応答が学習データかGeneratorのどちらに由来するものかを識別するDiscriminatorを構築する。これらの2つのモデルを交互に敵対的に訓練することで、より自然な発話を生成しようとする試みである。このような、学習の枠組みを導入した応答生成モデルが、従来の応答生成モデルと比較して高品質かつ多様な応答を生成したことが報告されており、本研究では対話行為分類のデータ拡張にこの枠組みを適用する。

3. 提案手法

対話行為分類のためのデータ拡張では、1) 多様で自然な発話の生成を行うことが可能であること、2) 指定した

対話行為タグに基づいて発話の生成を行うことが可能であることの2点が必要である。本研究では、この1)の問題に対応するために敵対的生成ネットワークを用いた応答生成モデルを導入する。また、先行研究で用いられているEncoder-Decoderモデルでは、応答発話の内容を対話行為を用いて明示的に制御することが難しい。そこで、この2)における問題に対応するために、任意の対話行為を条件として応答生成を行うことが可能な敵対的応答生成モデルを提案する。構築した応答生成モデルを用いて対話行為タグ付き発話のデータ拡張を行い、対話行為分類モデルの訓練に用いることで、対話行為分類の性能向上を試みる。

本章では、まず3.1節で対話行為による条件付き応答生成モデルのベースラインについて述べ、3.2節で敵対的生成学習を用いた提案手法の概要について述べる。

3.1 条件付き Encoder-Decoder モデル

本研究では、GRUによるEncoder-Decoderモデル[12]を対話行為による条件付き応答生成モデルへと応用する。

対話行為による条件付き応答生成では、入力発話 $M = \{m_1, m_2, \dots, m_I\}$ と対話行為 d を用いて、応答発話 $R = \{w_1, w_2, \dots, w_J\}$ を生成する。ここで、 I, J は発話長である。通常のGRUを用いたEncoder-Decoderモデルでは、Decoderにおける各出力ステップにおいて、直前の隠れ状態 h_{t-1} と現在の単語 w_t のベクトル表現 x_t が入力として使用される。一方で、本研究では、直前の隠れ状態 h_{t-1} に加えて、対話行為 d のベクトル表現 e と x_t の連結ベクトル v_t を入力として使用することで、指定した対話行為に基づいた応答をモデルが生成することを期待する*1。評価実験では、EncoderとDecoderにおけるGRUの層数は1、中間層の次元は512、単語埋め込みベクトルの次元は256、対話行為ベクトルの次元は100とした。

3.2 条件付き敵対的応答生成モデル

前節では、Encoder-Decoderモデルによって指定した対話行為に基いた応答生成を行うモデルについて述べた。しかしながら、Softmax cross-entropy lossに基づいて訓練されるEncoder-Decoderモデルはしばしば、過度に一般化された応答を生成することが知られており、応答文の多様性の低下が懸念される[10]。この応答文の多様性の問題については、2章で述べたように敵対的生成学習を導入することで改善することが知られている。そこで、前節で提案した条件付きEncoder-Decoderモデルに対して、敵対的生成学習の枠組みを導入することで多様性の向上を試みる。

3.2.1 方策勾配法による Generator の更新

本研究では、敵対的生成学習(GAN)の手法としてSeqGAN(Sequence generative adversarial net)[13]の枠組み

*1 入力単語 w_t 及び対話行為 d は埋め込み層を用いて密ベクトル表現 x_t, e へと変換される。

を採用し、対話行為による条件付き応答生成へ応用する。発話のような離散系列データの生成に GAN を適用する場合、Generator の出力は単語の離散値の系列を前提とするため、Discriminator から Generator への勾配の更新を行うことが難しい。この問題に対して、SeqGAN では、強化学習によるアプローチを Generator の更新に用いることで、離散的な系列データに GAN を適用できることを示している。

対話行為による条件付き応答生成では、入力発話 $M = \{m_1, m_2, \dots, m_I\}$ と対話行為 d が与えられると、応答生成モデルは応答発話 $R = \{w_1, w_2, \dots, w_J\}$ を生成する。このような応答生成における単語選択のプロセスは、マルコフ決定過程において、ある政策に従って実行される一連の行動系列とみなすことができる。SeqGAN では、Discriminator によって推定された応答文の妥当性についてのスコア $Q(M, R, d)$ を Generator の報酬として利用し、この期待報酬を最大化するように Generator を方策勾配法により更新する [14]。本研究における対話行為による条件付き応答生成においては、その目的関数 J と勾配を次式で定義する*2。ここで、 π は応答 R の生成確率である。

$$J(\theta) = \mathbb{E}_{R \sim p(R|M,d)}(Q(M, R, d)|\theta) \quad (1)$$

$$\nabla J(\theta) \approx Q(M, R, d) \nabla \log \pi(R|M, d) \quad (2)$$

$$= Q(M, R, d) \nabla \sum_t \log \pi(w_t|M, d, w_{1:t-1}) \quad (3)$$

3.2.2 Discriminator

応答文の妥当性 $Q(M, R, d)$ について推定する Discriminator の構築方法についてはいくつかの検討の余地がある。本研究では、以下の 2 種類の Discriminator について検討を行う。

- Implicit-Discriminator; 入力発話 M , 応答発話 R , 対話行為 d を入力として、与えられた R が本物 (学習データ由来のもの) か偽物 (Generator 由来のもの) であるかの 2 クラス分類を行う。Generator によって生成された R が本物であると推定される確率を $Q(M, R, d)$ として利用する。
- Explicit-Discriminator; 入力発話 M , 対話行為 d に対応する応答発話 R を入力として、 R が Generator 由来のものであるとき偽物、学習データ由来のものであるときその対話行為を分類するように Discriminator を訓練する。つまり、対話行為の種類数を N としたとき、 $N + 1$ クラスの多クラス分類を行う。ここで、 $Q(M, R, d)$ は、Generator によって生成された R が学習データ由来の対話行為 d であると推定される確率である。

Discriminator には、図 1 に示すように Convolutional

Neural Network (CNN) ベースのモデルを用いる。評価実験においては、一層の 1D-Convolution と Global Max-Pooling で構成されるモデルを採用し、畳み込みカーネルのサイズは 3、畳み込みカーネルの数は 256、中間層のサイズは 256 とした。また、Discriminator の更新においては、Generator による応答文と実際の応答文を 1:1 の割合で使用し、損失関数には Negative log-likelihood loss を用いる。

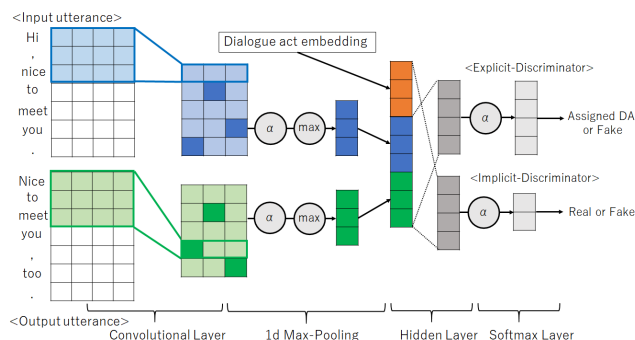


図 1 Implicit-Discriminator, Explicit-Discriminator

4. 実験設定

本章では、使用したデータセットの概要、応答生成モデルの評価方法及び、応答生成モデルを用いたデータ拡張による対話行為分類器の訓練方法について述べる。

4.1 データセット

応答生成モデル、対話行為分類モデルの訓練と評価には Switchboard dialogue act corpus[15] を用いた。本コーパスは、DAMSL に基づいた対話行為タグが付与されている。本研究では、このコーパスを訓練 (163,436 発話ペア)、開発 (17,126 発話ペア)、評価 (2,307 発話ペア) データに分割し、応答生成モデルと対話行為モデルの訓練と評価に用いた。また、これらのモデルの訓練には、訓練データセットにおける出現上位 10,000 単語を用いた。なお、それ以下の出現頻度の単語については未知語 “UNK” に置き換えた上でモデルの訓練を行った。

4.2 応答生成モデルの自動評価

応答生成モデルの評価については、関連性 (Relevance)、多様性 (Diversity)、制御性 (Contorollability) の観点からそれぞれ評価を行う。

- 関連性 (Relevance); 生成された応答発話とレファレンスの応答発話における単語分散表現の類似度により評価を行う。類似度の算出方法には Embedding Average, Greedy Matching, Vector Extreme の三つの評価指標 [16] を採用した.*3
- 多様性 (Diversity); 対話システムの分野で広く採用さ

*2 本研究では簡単化のために全文体で単一の報酬を使用している。

*3 これらの詳細については原論文 [16] を参照されたい。

れている Distinct-1 及び Distinct-2 により評価を行う。Distinct-1 (Distinct-2) は、テストデータに対して生成された応答発話集合におけるユニークな unigram (bigram) の数を、生成されたすべての unigram (bigram) の数でスケールした指標である [10]。

- 制御性 (Controllability); 入力として使用した対話行為と、実際に生成された応答文における対話行為の推定結果の一致率 (Accuracy) により評価する。また、各対話行為タグにおける応答生成の性能についての検証を行うために、Precision, Recall, F 値による評価も行う。応答文の対話行為については、事前訓練した対話行為分類器^{*4}による推定結果を用いる。

4.3 拡張データを用いた対話行為分類器の訓練

本研究では、3章で提案した条件付き応答生成モデルを対話行為分類器訓練のためのデータ拡張へと応用する。具体的には、訓練データセットにおける発話と、自動生成された発話の両方を対話行為分類器の訓練に用いることで、対話行為分類器の性能向上を試みる。本実験では、以下の2つの訓練方法についてそれぞれ検証を行った。対話行為分類器の訓練にはバッチサイズ 64 のミニバッチ学習を使用し、最適化手法には RMSProp (lr=1e-4) を使用する。

- Pretrain; 対話行為分類器の事前訓練を自動生成された応答発話を用いて行う。その後、訓練データのみを用いて fine-tuning を行う。評価実験では、最初の 1 epoch のみを事前学習に使用した。

```
1: for epoch = 1 : iteration do
2:   for sample (M, R, d) from training data do
3:     if epoch < 2 then
4:       generate the response  $\hat{R}$  using (M, d)
5:       update the classifier using (M,  $\hat{R}$ , d)
6:     else
7:       update the classifier using (M, R, d)
```

- Mixed; 訓練データからサンプルされたミニバッチを、自動生成した応答発話を用いたミニバッチに確率 p で置換する。評価実験では、 $p = \{0.0, 0.1, 0.3\}$ の場合で評価を行った。なお、 $p = 0.0$ はデータ拡張を行わない場合と等しい。

```
1: for epoch = 1 : iteration do
2:   for sample (M, R, d) from training data do
3:     if rand() < p then
4:       generate the response  $\hat{R}$  using (M, d)
5:       update the classifier using (M,  $\hat{R}$ , d)
6:     else
7:       update the classifier using (M, R, d)
```

^{*4} Explicit-Discriminator と同様のアーキテクチャを採用した。

5. 実験結果

5.1 応答生成モデルの自動評価結果

表 1 に対話行為による条件付き応答生成モデルの評価結果について示す。ここで、Adversarial-Implicit モデル、Adversarial-Explicit モデルはそれぞれ、Implicit-Discriminator, Explicit-Discriminator を使用した敵対的生成学習により訓練されたモデルである。応答文の生成においては、貪欲的に出力単語を選択する場合 (greedy) と多項分布に基づいてサンプリングを行う場合 (sampling) の 2通りを試した。

ベースラインモデルにおける応答生成結果

条件付き Encoder-Decoder モデルにおいて、貪欲的に応答を生成する場合、多様性の評価尺度 (Distinct-1, Distinct-2) は他の手法と比較して著しく低いことが確認できる。一方で、制御性 (対話行為分類精度) については高い精度を持っていることが分かる。これは、モデルが指定した対話行為に基づいて応答を生成できているものの、“I don’t know”, “umm” などのような一般的な応答のみしか生成できていないことを示している。一方でサンプリングを使用する場合、多様性の評価尺度は改善しているが、制御性は大きく低下していることが確認できる。

敵対的生成学習による応答生成結果

敵対的生成学習を導入した Adversarial-Implicit モデルでは、条件付き Encoder-Decoder モデルと比較して関連性、多様性についての改善が確認ができなかった。また、制御性については、0.0065 ポイントの低下を引き起こした。一方で、Adversarial-Explicit モデルでは関連性、多様性 (Distinct-2)、制御性が改善していることが確認できる。特に、制御性においては 0.0919 ポイントの顕著な改善が確認できた。Adversarial-Explicit モデルでは、応答文が Generator か学習データのどちらに由来するものかを判別すると同時に、明示的に対話行為の推定を行っている。しかしながら、Adversarial-Implicit モデルでは、生成された応答の対話行為を明示的に推定しないため制御性のスコア改善につながらなかったと考えられる。

また、敵対的生成学習を導入した 2つのモデルでは、条件付き Encoder-Decoder モデルと比較して Perplexity の改善が確認できなかった。敵対的生成学習によるテキスト生成モデルが必ずしも Perplexity を改善しないことは先行研究 [17] においても指摘されている。これは、敵対的生成学習は単語予測の最適化を目的としないためである。

各対話行為タグにおける応答生成結果

表 2 に各対話行為タグ毎の Adversarial-Explicit モデルの応答生成の結果^{*5}について示す。括弧は、条件付き Encoder-Decoder モデル (sampling) におけるスコアとの差分であ

^{*5} 評価セットのサイズが小さいため、一部の対話行為タグは評価セットに含まれていない。

表 1 対話行為による条件付き応答生成モデルの評価

モデル	Perplexity	Average	Greedy	Extreme	Distinct-1	Distinct-2	Accuracy
Gold response	-	-	-	-	0.0995	0.4416	0.7308
条件付き Encoder-Decoder モデル (greedy)	18.2117	-	-	-	0.0021	0.0122	0.7650
条件付き Encoder-Decoder モデル (sampling)	18.2117	0.2949	90.7342	0.2113	0.0973	0.4539	0.7338
Adversarial-Implicit モデル (sampling)	19.1752	0.2942	90.1862	0.2114	0.0856	0.4535	0.7273
Adversarial-Explicit モデル (sampling)	19.1388	0.2988	91.7376	0.2194	0.0964	0.4711	0.8257

表 2 各対話行為タグにおける応答生成結果 (Adversarial-Explicit モデル)

対話行為	Precision	Recall	F1	出現数
No answers	0.9167 (-0.0833)	0.9167 (0.0000)	0.9167 (-0.0399)	12
Appreciation	0.8800 (0.1467)	0.8627 (0.2157)	0.8713 (0.1838)	51
Reject	0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)	1
Dispreferred answers	0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)	1
Action-directive	0.2857 (-0.2143)	0.1429 (0.0000)	0.1905 (-0.0317)	14
Agree/Accept	0.7521 (0.2483)	0.7395 (0.1933)	0.7458 (0.2216)	119
Declarative Yes-No-Question	0.0000 (-0.5000)	0.0000 (-0.0714)	0.0000 (-0.1250)	14
Statement-non-opinion	0.8289 (0.0275)	0.9153 (0.0736)	0.8700 (0.0489)	815
Affirmative non-yes answers	0.2000 (-0.3000)	0.2000 (-0.2000)	0.2000 (-0.2444)	5
Declarative Wh-Question	0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)	1
Response Acknowledgement	1.0000 (0.5000)	0.4706 (-0.0588)	0.6400 (0.1257)	17
Downplayer	0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)	1
Repeat-phrase	0.1250 (0.1250)	0.0833 (0.0833)	0.1000 (0.1000)	12
Or-Clause	1.0000 (0.3333)	0.5000 (-0.5000)	0.6667 (-0.1333)	2
Negative non-no answers	0.2000 (-0.3000)	0.3333 (0.0000)	0.2500 (-0.1500)	3
Conventional-closing	0.9412 (0.0893)	0.8000 (0.2250)	0.8649 (0.1783)	40
Other answers	1.0000 (0.0000)	0.3333 (0.0000)	0.5000 (0.0000)	3
Conventional-opening	1.0000 (0.0000)	0.3333 (-0.3333)	0.5000 (-0.3000)	3
Self-talk	0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)	1
Apology	0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)	1
Signal-non-understanding	0.3333 (-0.6667)	0.5000 (0.0000)	0.4000 (-0.2667)	2
Acknowledge (Backchannel)	0.8902 (0.0893)	0.9467 (0.0990)	0.9176 (0.0939)	394
Thanking	1.0000 (0.4000)	0.6667 (-0.3333)	0.8000 (0.0500)	3
Maybe/Accept-part	0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)	7
Hold before answer/agreement	0.6000 (-0.4000)	0.6000 (0.4000)	0.6000 (0.2667)	5
Open-Question	0.8182 (0.3182)	0.9000 (0.2000)	0.8571 (0.2738)	10
Rhetorical-Questions	0.5714 (0.1714)	0.3636 (0.1818)	0.4444 (0.1944)	11
Statement-opinion	0.7934 (0.0952)	0.6883 (0.0753)	0.7371 (0.0843)	385
Yes-No-Question	0.7391 (0.0573)	0.8500 (0.1000)	0.7907 (0.0764)	40
Yes answers	0.8966 (0.1546)	0.6842 (0.0789)	0.7761 (0.1095)	38
Backchannel in question form	0.8750 (0.0855)	0.8235 (-0.0588)	0.8485 (0.0152)	17
Summarize/reformulate	0.0000 (-0.2500)	0.0000 (-0.0625)	0.0000 (-0.1000)	16
Non-verbal	1.0000 (0.1538)	1.0000 (0.0000)	1.0000 (0.0833)	11
Uninterpretable	0.8384 (0.2205)	0.8972 (0.1262)	0.8668 (0.1807)	214
Wh-Question	0.8947 (0.1300)	0.8947 (0.2105)	0.8947 (0.1725)	38
weighted avg	0.8110 (0.0843)	0.8257 (0.0919)	0.8148 (0.0901)	2307

る。表 2 より、条件付き Encoder-Decoder モデルと比較して、Adversarial-Explicit モデルでは、18 個の対話行為タグで F 値が改善していることが確認できる。また、9 個の対話行為タグで F 値が低下、8 個の対話行為で F 値に変化はなかった。しかしながら、これらの対話行為タグは出現頻度が低いものや、より長期の対話履歴を考慮したうえで付与される対話行為タグ (例えば、Summarize/reformulate) が主である。したがって、低頻度の対話行為タグについては、例えば文字・サブワードレベルのモデリングを行うことでデータスパースネスに起因する問題を軽減することが期待できる。また、対話履歴の参照が必要な対話行為タグ

については、直前のユーザの発話だけではなく、より過去の対話履歴を考慮した Discriminator と Generator を敵対的生成学習に用いることで改善を行うことができると考えられる。

5.2 拡張データを用いた対話行為分類結果

前節において、最も優れた性能を示した Adversarial-Explicit モデルを、対話行為分類におけるデータ拡張へと適用した結果を表 3 へ示す。ここで、Precision, Recall, F1 は各対話行為タグにおける分類結果の加重平均であり、開発セットにおける Negative log-likelihood loss が最も下がっ

たときの評価結果を示している。また、Mixed ($p = 0.0$) は訓練データセットのみを用いて訓練された通常の対話行為分類モデルである。

表 3 対話行為分類の結果

分類モデル	Precision	Recall	F1
Pretrain (1 epoch)	0.7243	0.7347	0.7241
Mixed ($p = 0.0$)	0.7301	0.7441	0.7300
Mixed ($p = 0.3$)	0.7314	0.7451	0.7315
Mixed ($p = 0.1$)	0.7334	0.7457	0.7320

表 3 より、対話行為分類器の事前学習に自動生成した発話を用いる場合は、訓練データセットのみを用いたモデルと比較して分類性能の向上を確認することができなかった。一方で、対話行為分類器の訓練の際に、自動生成された応答発話を用いたミニバッチを使用する場合 ($p = 0.1, 0.3$) では、Precision, Recall, F 値が向上することを確認できた。特に、 $p = 0.1$ の場合では、Precision, Recall, F 値がそれぞれ 0.0033, 0.0016, 0.0020 ポイント改善しており提案モデルによるデータ拡張の有効性が示唆される結果となった。

6. おわりに

本研究では、任意の対話行為に対して発話の自動生成を行う条件付き敵対的生成ネットワークを提案し、その評価を行った。その結果、提案モデルはベースラインモデル(条件付き Encoder-Decoder モデル)と比較して、関連性、多様性、制御性における客観評価が改善されることを示した。しかしながら、生成文の品質についてより厳密に評価するためには人手による評価を行うことが必要である。また、本研究で用いた Switchboard corpus は質・量ともに十分な対話行為タグがアノテーションされたデータであるため、データ拡張の効果がよりはっきりとする他の小規模コーパスで実験を行うことも今後の課題である。

さらに、本研究では、提案モデルを用いたデータ拡張により訓練された対話行為分類モデルの対話行為分類性能が、従来手法と比較して改善される可能性を示した。ニューラルネットワークによる応答生成モデルを用いたデータ拡張は、訓練データへのノイズ付加など正則化の文脈でも議論を行うことができると考えられる。今後は実験結果の理論的分析や提案手法の他ドメインにおける有効性の検討を進める予定である。

謝辞 本研究は JST さきがけ (JPMJPR165B) および JST CREST (JPMJCR1513) の支援を受けた。

参考文献

[1] Boyer, K. E., Ha, E. Y., Phillips, R., Wallis, M. D., Vouk, M. A. and Lester, J. C.: Dialogue act modeling in a complex task-oriented domain, *Proc. of SIGDIAL*, Association for Computational Linguistics, pp. 297–305

(2010).

[2] Yoshino, K. and Kawahara, T.: Conversational system for information navigation based on POMDP with user focus tracking, *Computer Speech & Language*, Vol. 34, No. 1, pp. 275–291 (2015).

[3] Lee, J. Y. and Deroncourt, F.: Sequential Short-Text Classification with Recurrent and Convolutional Neural Networks, *Proc. of NAACL-HLT*, pp. 515–520 (2016).

[4] Khanpour, H., Guntakandla, N. and Nielsen, R.: Dialogue Act Classification in Domain-Independent Conversations Using a Deep Recurrent Neural Network., *COLING*, pp. 2012–2021 (2016).

[5] 白井清昭, 洪陽杓ほか: 決定木に基づく対話行為のタグ付け支援, 情報処理学会研究報告音声言語情報処理 (SLP), Vol. 2005, No. 50 (2005-SLP-056), pp. 119–124 (2005).

[6] Zhang, X., Zhao, J. and LeCun, Y.: Character-level convolutional networks for text classification, *Advances in neural information processing systems*, pp. 649–657 (2015).

[7] Wang, W. Y. and Yang, D.: That’s So Annoying!!!: A Lexical and Frame-Semantic Embedding Based Data Augmentation Approach to Automatic Categorization of Annoying Behaviors using# petpeeve Tweets, *Proc. of EMNLP*, pp. 2557–2563 (2015).

[8] Ortega, D. and Vu, N. T.: Neural-based Context Representation Learning for Dialog Act Classification, *Proc. of SIGDIAL*, pp. 247–252 (2017).

[9] Hou, Y., Liu, Y., Che, W. and Liu, T.: Sequence-to-Sequence Data Augmentation for Dialogue Language Understanding, *Proceedings of the 27th International Conference on Computational Linguistics*, pp. 1234–1245 (2018).

[10] Li, J., Galley, M., Brockett, C., Gao, J. and Dolan, B.: A Diversity-Promoting Objective Function for Neural Conversation Models, *Proc. of NAACL-HLT*, pp. 110–119 (2016).

[11] Li, J., Monroe, W., Shi, T., Jean, S., Ritter, A. and Jurafsky, D.: Adversarial Learning for Neural Dialogue Generation, *Proc. of EMNLP*, pp. 2157–2169 (2017).

[12] Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y.: Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation, *Proc. of EMNLP*, pp. 1724–1734 (2014).

[13] Yu, L., Zhang, W., Wang, J. and Yu, Y.: SeqGAN: Sequence Generative Adversarial Nets with Policy Gradient., *AAAI*, pp. 2852–2858 (2017).

[14] Williams, R. J.: Simple statistical gradient-following algorithms for connectionist reinforcement learning, *Machine learning*, Vol. 8, No. 3–4, pp. 229–256 (1992).

[15] Stolcke, A., Ries, K., Coccaro, N., Shriberg, E., Bates, R., Jurafsky, D., Taylor, P., Martin, R., Van Ess-Dykema, C. and Meteer, M.: Dialogue act modeling for automatic tagging and recognition of conversational speech, *Computational linguistics*, Vol. 26, No. 3, pp. 339–373 (2000).

[16] Liu, C.-W., Lowe, R., Serban, I., Noseworthy, M., Charlin, L. and Pineau, J.: How NOT To Evaluate Your Dialogue System: An Empirical Study of Unsupervised Evaluation Metrics for Dialogue Response Generation, *Proc. of EMNLP*, pp. 2122–2132 (2016).

[17] Tevet, G., Habib, G., Shwartz, V. and Berant, J.: Evaluating Text GANs as Language Models, *arXiv preprint arXiv:1810.12686* (2018).