

転移学習を用いた対話応答のスタイル制御

赤間 怜奈^{*1} 稲田 和明^{†2} 小林 颯介^{‡3} 佐藤 祥多^{†4} 乾 健太郎^{†5}

^{*} 東北大学 工学部

[†] 東北大学 大学院情報科学研究科

[‡] 株式会社 Preferred Networks

{¹reina.a, ²kazuaki.inada, ⁴shoto-s, ⁵inui}@ecei.tohoku.ac.jp,
³sosk@preferred.jp

1 はじめに

近年, Twitter を始めとするソーシャルネットワークサービス (SNS) に存在する膨大な対話データを用いて, 機械学習ベースの対話システムを構築する研究が盛んに行われている. 中でも, 高性能な言語モデルとして知られている Recurrent Neural Network (RNN) 言語モデルを活用した sequence to sequence モデル (seq2seq) は, ユーザの発話に対して流暢な応答を生成することができる手法として, 対話システムの応答生成モデルとして注目を集めている [5].

しかし, SNS から獲得した対話データを学習させるだけでは, seq2seq が生成する応答に語尾など言葉遣いの一貫性を持たせることが難しいという問題が生じる. たとえば表 1 の対話例では, 2) のように親しげな印象を受ける応答を出力する場合もあれば, 4) のようにです・ます調の丁寧な言葉遣いを出力する場合もある. さらに, その後の 6) では, 優しい印象の語尾「～わ」を含んだ応答をしており, 各応答内で言葉遣いの印象が異なることが確認できる. 本研究では, このような言葉遣いの丁寧さや親密さによる表現方法の違いなど, 発話者のキャラクタを印象づける表層的な表現の違いを, 発話のスタイルと呼ぶ. 表 1 のように応答のスタイルが一貫しないのは, 学習した対話データに不特定多数のユーザの発話が混合しており, 生成する応答を特定のスタイルに固定することが困難なために生じたと考えられる.

システムが生成する発話に特定の一貫したスタイルを付与する試みは, これまでにもいくつか研究がある. 既存研究では, 発話のスタイルに関する規則を手で作成する [6, 7], 特定のキャラクタの対話データを大量に作成して学習させる [2] などの手法が提案されているが, これらの手法には規則やデータの作成にかか

表 1: スタイルに一貫性のない対話システムの応答例

対話例	
1) User:	こんにちは
2) System:	今日も元気いっぱい <u>でいこうな</u>
3) User:	今日は雪です
4) System:	雪降って <u>るんですか</u>
5) User:	寒いです
6) System:	よしよし <u>手をつないであげますわ</u>




図 1: seq2seq による応答生成モデル

るコストが高い.

そこで本研究では, 人手による規則の作成や大量のキャラクタ別の対話データを必要とせず, 従来よりも低いコストで応答にスタイルを付与する試みとして, seq2seq による応答生成モデルと転移学習を組み合わせた手法を提案する. まず, SNS から抽出したスタイルについて特に制限を設けない大規模な対話データを用いて, 応答生成モデルを学習する. その後, 応答にスタイルを付与することを目的に, 大規模な対話データで学習した応答生成モデルをもとにして, 特定のスタイルに制限した少規模な対話データを用いた転移学習を行う. 提案手法のモデルは, 転移学習を行わないベースラインモデルと比較して, 応答としての適切さを保ちつつ, 一貫したスタイルを持つ応答を生成することができた.

2 関連研究

高性能な機械学習ベースの応答生成モデルの 1 つとして, seq2seq が存在する [5]. Sutskever らの seq2seq は, たとえば図 1 のように, 入力として可変長の単語

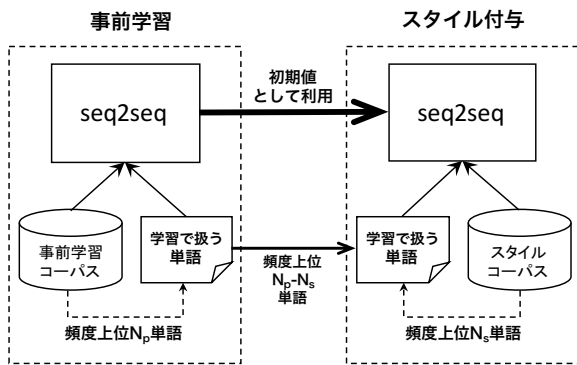


図 2: 提案手法の概観

列「あした/筑波/へ/出張/だ」を受け取ると、可変長の単語列「お/土産/よろしく」を出力する。このモデルは、単語列のエンコーダおよびデコーダとして2つの Long Short-Term Memory (LSTM) を持ち、入力単語列から出力単語列を1単語ずつ生成する。

システムが生成する発話に一貫したスタイルを付与する研究として、Walker らは映画字幕のコーパスを参考に、キャラクタを表す表層的な特徴を規則として記述することで、システムの発話に特定のキャラクタ性を持たせることに成功した [6]。また、宮崎らは各文節の機能表現部分について書き換えを行うことで、生成される発話にキャラクタ性を付与した [7]。具体的には、一般的なコーパスの機能表現部分に対して、特定のキャラクタ性を持たせるように人手で書き換える作業を通して、書き換え規則を抽出した。一方で、人手での規則の記述や書き換えを必要としない研究として、対話データに付与された発話者情報をベクトル空間上で表現し、seq2seq で対話データと発話者情報を合わせて学習することで、特定の発話者のキャラクタ性を持つ応答を生成する手法が提案されている [2]。

データの十分な質と量が確保できないタスクにおいて、モデルの精度を向上させるための機械学習の手法の1つに転移学習がある。転移学習では、本来の目的と関連する他のデータで事前に学習し、事前の学習で得られた知識を目的のデータでの学習に適用することで、目的のデータでの学習を効果的に行う。転移学習は、固有表現抽出や商品レビューの極性分類、翻訳などのタスクで有効であることが確認されており [3]、また、GloVe [4] などで事前学習した単語ベクトルは、様々なタスクで広く活用されている。

3 提案手法

図 2 に提案手法の概観を示す。応答生成モデルとして Sutskever らの seq2seq [5] を利用する。seq2seq のデコーダでは、RNN 言語モデルの枠組みで各単語の

生成確率を算出することで、単語列を生成することができる。

本研究では、まず、特定のスタイルの付与を考慮する前に、事前学習としてスタイルに制限のない大規模な対話データ (以降、事前学習コーパスと呼ぶ) で、応答生成モデルを学習する。その後、事前学習コーパスで学習したモデルと、特定の話者による応答を収集した小規模な対話データ (以降、スタイルコーパスと呼ぶ) を用いて、転移学習を行う。具体的には、スタイルコーパスを学習データとして応答生成モデルを学習する際に、事前学習コーパスにより学習したモデルをスタイルコーパスによる学習のモデルパラメータの初期値として用いる。

Seq2seq による学習を行う場合、学習時の計算時間や消費メモリの削減、過学習の防止などを目的として、扱う単語数に制限を設けることが多い。一般的には、コーパス中の出現頻度が高い単語のみで学習し、他の単語は一括して $\langle \text{unk} \rangle$ などの特殊な記号として扱う。しかし、2種類以上のコーパスを用いて転移学習を行う場合、スタイルコーパス中で出現頻度の高い単語が、事前学習コーパス中の出現頻度の上位の単語に含まれず、スタイルコーパス中で特有な単語が扱えなくなるという問題が生じる。そこで本研究では、スタイルコーパスによる学習の前に、事前学習コーパスに出現しないかつスタイルコーパスに出現する単語のうちの出現頻度上位 N_p 個と、事前学習で扱った N_p 個の単語のうちの出現頻度下位 N_s 個の入れ替えを行う。たとえば $N_p = 25,000$, $N_s = 1,000$ とすると、事前学習コーパスの学習時には事前学習コーパスの出現頻度上位 25,000 単語、スタイルコーパスの学習時には事前学習コーパスの頻度上位 24,000 単語とスタイルコーパスの頻度上位 1,000 単語を学習で扱う。

4 実験

4.1 データセット

本研究では、事前学習コーパスとして Twitter から抽出した対話データと、スタイルコーパスとして TV 番組字幕データから抽出した対話データを学習に使用した。Twitter の対話データは、2015 年に投稿されたリプライ付きの投稿から、ノイズとなるハッシュタグや URL などの自然言語でない文字列、日本語以外の言語を除去した後、ランダムに抽出した約 370 万対を事前学習コーパスとして利用した。TV 番組字幕データは、2015 年 9 月から 2016 年 5 月の期間に放送されたテレビ番組の字幕から話者情報・発話情報を抜き出

表 2: 実験に使用したスタイルコーパス

発話者	番組	ジャンル	発話-応答ペア数
黒柳徹子	徹子の部屋	トーク番組	12,564
おじゃる丸	おじゃる丸	アニメ	1,476

表 3: スタイルコーパスの応答の例

黒柳徹子の応答	おじゃる丸の応答
そうそうそうそう。 覚えていらした? 召し上がるんですって? お綺麗ね。	マロはぐうたらしておらぬ。 散歩でおじゃる。 教えてたも。 オホホソチらまだまだあまいの。

したものである。本研究では、表 2 に示す 2 つの TV 番組字幕データを用いた。黒柳徹子やおじゃる丸の発言を〈応答〉、〈応答〉に先行する黒柳徹子やおじゃる丸以外の発言を〈発話〉とした発話-応答ペアを作成し、スタイルコーパスの対話データとして利用した。表 3 に黒柳徹子とおじゃる丸の応答の例を示す。なお、コーパス全体の 95% を学習データ、5% を開発用データとした。

4.2 モデル設定

提案手法では、まず事前学習として事前学習コーパス内の頻度上位 25,000 単語 ($N_p = 25,000$) を扱い、学習データを 5 周学習した。各週の学習終了時点のモデルに対して開発用データでパープレキシティを算出し、パープレキシティが最低値のモデルを、スタイルコーパス学習時の初期値として利用した。その後、スタイルコーパスの学習時には、黒柳徹子スタイルコーパスでは頻度上位 1,000 単語 ($N_s = 1,000$)、おじゃる丸スタイルコーパスでは頻度上位 500 単語 ($N_s = 500$) を用いて単語の入れ替えを行い、学習データを 10 周学習した。各週の学習終了時点のモデルに対して開発用データでパープレキシティを算出し、パープレキシティが最低値のモデルを提案手法のモデルとして評価に利用した。

提案手法との比較に用いるベースライン手法として、seq2seq を用い、転移学習を行わない 2 種類のモデル *Base*, *Mixed* を用意した。*Base* は、事前学習コーパスのみで学習した応答生成モデルである。*Base* の学習では、事前学習コーパス内の出現頻度上位 25,000 単語を扱った。この *Base* は、提案手法においてスタイルコーパスの学習の初期値として利用したモデルと同一である。*Mixed* は、事前学習コーパスとスタイルコーパスを混合したコーパスで学習した応答生成モデルである。*Mixed* の学習では、混合するスタイルコーパスとして黒柳徹子スタイルコーパスを採用した場合、事前学習コーパスとスタイルコーパスからそれぞれ頻度

表 4: 黒柳徹子スタイルを付与した応答例

対話例
1) <i>User</i> : こんにちは
2) <i>System</i> : こんにちは。
3) <i>User</i> : 今日は雪です
4) <i>System</i> : あらびっくりしました
5) <i>User</i> : 寒いです
6) <i>System</i> : そりゃそうですね

表 5: おじゃる丸スタイルを付与した応答例

対話例
1) <i>User</i> : こんにちは
2) <i>System</i> : おじゃ!
3) <i>User</i> : 今日は雪です
4) <i>System</i> : 寒いのかの?
5) <i>User</i> : 寒いです
6) <i>System</i> : そんな薄着してたのかの?

上位 24,000 単語と 1,000 単語、おじゃる丸スタイルコーパスを採用した場合、事前学習コーパスとスタイルコーパスからそれぞれ頻度上位 24,500 単語と 500 単語を扱った。*Base* と *Mixed* は、それぞれ学習データを 5 周学習した。各週の学習時点のモデルに対して開発用データでパープレキシティを算出し、パープレキシティが最低値のモデルを評価に利用した。

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とおりである。学習にはミニバッチ学習を採用し、ミニバッチサイズを 64 とした。Seq2seq による応答生成モデルは、単語ベクトルを 1024 次元、LSTM を 2 層、それらの隠れ層を 2048 次元、dropout rate を 0.2 とした。また、学習時のパラメータの最適化には、Adam [1] を利用した。なお転移学習の際には、スタイルコーパス時の学習速度を高めるため、Adam の全てのパラメータを引き継がずに学習した。

4.3 結果

提案手法を用いた対話システムの応答生成結果の一例を表 4 と表 5 に示す。システムへの入力、表 1 と同一のものを用いた。対話システムとして、応答に広いバリエーションを持たせるため、生成確率にもとづいてサンプリングすることで応答を生成した。このとき、非常に低い確率の単語列が偶然生成されることを防ぐため、幅 3 でビームサーチを行った。なお、1 章の表 1 は同様の設定を *Base* に適用した際の生成結果である。表 3 と比較すると、それぞれの発話スタイルが正しく付与されていることが分かる。特に、おじゃる丸スタイルを付与した場合を見ると、約 1,400 の発話-応答ペアしかないにも関わらず、おじゃる丸特有の「~の」などの語尾が付与されていることが確認できる。

表 6: 黒柳徹子スタイルでの評価結果

	1. 応答の適切さ		2. スタイル付与		
	適切	不適切	成功	失敗	変化なし
提案手法	53 (93.0%)	4 (7.0%)	47 (82.5%)	4 (7.0%)	6 (10.5%)
Mixed	48 (84.2%)	9 (15.8%)	13 (22.8%)	39 (68.4%)	5 (8.8%)
Base	52 (91.2%)	5 (8.8%)	-	-	-

* () 内は割合を表す

表 7: おじゃる丸スタイルでの評価結果

	1. 応答の適切さ		2. スタイル付与		
	適切	不適切	成功	失敗	変化なし
提案手法	23 (40.4%)	34 (59.6%)	50 (87.7%)	2 (3.5%)	5 (8.8%)
Mixed	52 (91.2%)	5 (8.8%)	11 (19.3%)	28 (49.1%)	18 (31.6%)
Base	52 (91.2%)	5 (8.8%)	-	-	-

* () 内は割合を表す

次に、提案手法と Base, Mixed それぞれの生成結果を比較するために、

1. 応答として言語的かつ内容的に適切であるか
2. 意図したスタイルが付与されているか

の 2 つの観点から人手による評価を実施した¹。1) 応答の適切さについては「適切/不適切」の 2 値、2) スタイル付与については「成功/失敗」の他に、生成結果が Base と同一だった場合の「変化なし」を加えた 3 値に分類した。各モデルへの入力には、学習データと重複しないように、Twitter から獲得した対話データのうち、ノイズとなる文字列を取り除いた 57 対の発話部分を用いた。なお、各モデルは幅 10 のビームサーチによって応答を生成した。

表 6 と表 7 に評価結果を示す。表 6 より、黒柳徹子スタイルを付与した場合は、提案手法は Base と同程度の 90% 以上で適切な応答を生成したことが確認できた。さらに、提案手法はスタイル付与の成功が 80% を超えており、提案手法と Mixed モデルは学習に使用したデータとスタイルコーパス内の単語が同じだが、Mixed モデルを上回る結果となった。一方、表 7 より、おじゃる丸スタイルを付与した場合は、提案手法はスタイルの付与の成功が 80% を超えたが、応答の適切さは 50% を下回る結果となった。不適切と判断した応答として、表 5 の 2) 「おじゃ!」のような相づちに相当する表現が多数見られた。この原因として、おじゃる丸という番組は、低年齢向けのアニメであり、使用される単語の種類が少ないため、おじゃる丸スタイル

¹ 各モデルと生成された応答の対応が分かる状態で評価した。

コーパスと事前学習コーパスとでは単語や対話内容の重複がほとんど存在しなかったことが挙げられる。その結果、事前学習で得た知識を十分に活用することができず、適切な応答が生成される割合が乏しかったと考えられる。

5 おわりに

本研究では、人手による規則の記述や特定の大量のデータを必要とせずに、特定のスタイルを持った対話応答を生成する手法として、従来の seq2seq を用いた応答生成モデルに転移学習を組み合わせる手法を提案した。提案手法は、転移学習を行わないベースライン手法と比較して、入力された発話に対する応答の適切さを保持しつつ、特定のスタイルを応答に付与することができた。

今後の課題として、提案手法に必要な学習データ量の調査、TV 番組以外のコーパスをスタイルコーパスとして用いての評価などが考えられ、将来的には、特定のスタイルを模倣するだけでなく、任意のスタイルを持った対話システムの実現を目指していきたい。

謝辞

本研究で使用した TV 番組字幕データは、豊田中央研究所の徳久良子氏からご提供頂きました。記して感謝致します。

参考文献

- [1] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. In *The International Conference on Learning Representations (ICLR)*, 2015.
- [2] Jiwei Li, Michel Galley, Chris Brockett, Georgios Spithourakis, Jianfeng Gao, and Bill Dolan. A persona-based neural conversation model. In *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*, pp. 994–1003, 2016.
- [3] Sinno Jialin Pan and Qiang Yang. A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, Vol. 22, No. 10, pp. 1345–1359, 2010.
- [4] Jeffrey Pennington, Richard Socher, and Christopher D. Manning. Glove: Global vectors for word representation. In *Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1532–1543, 2014.
- [5] Ilya Sutskever, Oriol Vinyals, and Quoc V Le. Sequence to sequence learning with neural networks. In *Advances in neural information processing systems*, pp. 3104–3112, 2014.
- [6] Marilyn A Walker, Grace I Lin, and Jennifer Sawyer. An annotated corpus of film dialogue for learning and characterizing character style. In *LREC*, pp. 1373–1378, 2012.
- [7] 宮崎千明, 平野徹, 東中竜一郎, 牧野俊朗, 松尾義博, 佐藤理史. 文節機能部の確率的書き換えによる言語表現のキャラクター性変換. *人工知能学会論文誌*, Vol. 31, No. 1, pp. DSF-E-1, 2016.