

B3TB2006

卒業論文

対話生成における応答のスタイル制御に関する研究

赤間怜奈

2017年 3月 31日

東北大学
工学部 情報知能システム総合学科

対話生成における応答のスタイル制御に関する研究*

赤間怜奈

内容梗概

本研究では、人手による規則の記述や特定の大量の対話データの収集を必要とせずに、特定の発話者のキャラクタを印象づける表層的な表現（スタイル）を持った応答を生成する手法として、sequence to sequence による応答生成モデルに転移学習を組み合わせた手法を提案する．具体的には、特にスタイルを制限しない大規模な対話データで事前に学習したモデルを用いて、特定のスタイルのみに制限した小規模な対話データを用いてさらに学習を行うことで、対話応答に一貫したスタイルの付与を試みる．提案手法の有効性を確かめるため、実際に入力を与えてそれに対する応答生成実験を行い、さらに生成された応答について人間の評価者によるスコア付けを実施した．実際に生成された応答や人手評価の結果より、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としての適切さを保持しつつ、一貫したスタイルの応答を生成することを確認した．

キーワード

応答生成，対話，スタイル制御，ニューラルネットワーク，転移学習

*東北大学 工学部 情報知能システム総合学科 卒業論文, B3TB2006, 2017年3月31日.

A Study on a Style Control for Dialogue Response Generation*

Reina Akama

Abstract

We propose a new dialogue response generation model combining sequence to sequence and metastasis learning for controlling a STYLE, which impresses a character of a specific speaker. To generate consistent style responses, most of previous works for collected text pairs by handmade rules or human annotation. However, their costs were too expensive to learn response generation models with a consistent style. In our methods, after learning pre-training model with a large-scale corpora without restriction styles, we learn a response generation model with a small-scale corpora with a style restriction and the pre-training model. Compared with responses between our proposed model and baseline models without metastasis learning, our model generated consistent style and appropriate responses to input texts.

Keywords:

response generation, dialog, style control, neural network, transfer learning

*Graduation Thesis, Department of Information and Intelligent Systems, Tohoku University, B3TB2006, March 31, 2017.

Contents

1	はじめに	1
2	関連研究	3
2.1	Sequence to sequence モデル	3
2.2	キャラクタ付与に関する研究	4
2.3	転移学習	5
3	提案手法	6
3.1	転移学習を用いた応答のスタイル付与	6
3.1.1	<i>Transfer</i> モデル	6
3.2	転移学習時の単語の扱いに関する問題と解決案	7
3.2.1	<i>Transfer+freq</i> モデル	7
3.2.2	<i>Transfer+sim</i> モデル	7
4	データセット	9
4.1	事前学習コーパス	9
4.2	スタイルコーパス	9
5	実験	11
5.1	モデル設定	11
5.1.1	提案手法モデル	11
5.1.2	ベースラインモデル	11
5.1.3	全てのモデルに共通の学習設定	13
5.2	結果	13
5.2.1	人手による評価	13
5.2.2	一貫したスタイルが付与された応答	14
6	おわりに	16
	謝辞	17

List of Figures

1	seq2seq による応答生成モデル	3
2	提案モデル	6
3	生成実験を行う 5 種のモデル	12

List of Tables

1	スタイルに一貫性のない対話システムの応答例	1
2	実験に使用したコーパス	9
3	スタイルコーパスの応答の例	10
4	黒柳徹子スタイルでの評価結果	14
5	おじゃる丸スタイルでの評価結果	14
6	黒柳徹子スタイルを付与した応答例	15
7	おじゃる丸スタイルを付与した応答例	15

1 はじめに

近年，Twitterを始めとするソーシャルネットワーキングサービス (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の1つ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 [18]．

しかし，SNS から獲得した対話データを seq2seq で学習させるだけでは，生成される応答に語尾など言葉遣いに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原因は，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手法 [19, 20]，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手法 [10] などが提案されているが，これらの手法には規則の記述やデータの作成にかかるコストが高い．

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

そこで本研究では、人手による規則の記述や大量のキャラクタ別の対話データの作成を必要とせず、従来よりも低いコストで生成される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、生成される応答に一貫したスタイルを付与することを目的として、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、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。提案手法の有効性を確かめるために、入力に対する応答生成実験と生成された応答についての手によるスコア付け評価を行ったところ、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としての適切さを保持しつつ、一貫したスタイルの応答を生成することを確認した。

2 関連研究

2.1 Sequence to sequence モデル

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 [4, 18] . 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。




Figure 1: seq2seq による応答生成モデル

seq2seq は RNN の枠組みを用いており、RNN は入力単語列 (x_1, \dots, x_T) が与えられると、時刻 t において式 (1) により隠れ層 h_t の状態を更新し、式 (2) により出力単語 y_t を計算する。これを時刻 T まで繰り返すことによって、最終的な出力単語列 (y_1, \dots, y_T) を得る。ここで、 W_{hx} 、 W_{hh} 、 W_{yh} はそれぞれ入力層から隠れ層、隠れ層から隠れ層、隠れ層から出力層への重み行列である。

$$h_t = \text{sigm}(W^{hx}x_t + W^{hh}h_{t-1}) \quad (1)$$

$$y_t = W^{yh}h_t \quad (2)$$

入力と出力の長さが一定でなく、複雑で非単調な関係がある場合、単純な RNN を適用することは難しい。このような場合は、まず任意の長さ T の入力単語列を RNN を用いて固定次元のベクトル v にマップし (エンコーダ)、その後マップしたベクトルと別の RNN で、任意の長さ T' の出力単語列にマップする (デコーダ)。さらに Seq2seq では、従来の RNN では学習することが困難であった長期依存関係を扱えるようにするため、Long Short-Term Memory (LSTM) [7] を利用することが多い。

Sutskever らの seq2seq 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 LSTM を持ち、入力単語列から固定次元のベクトルを生成し、そのベクトルを用いて出力単語列を 1 単語ずつ生成する。LSTM は式 (3) により、入力単語列

(x_1, \dots, x_T) から出力単語列 $(y_1, \dots, y_{T'})$ の条件付き確率 $p(y_1, \dots, y_{T'} | x_1, \dots, x_T)$ を算出する .

$$p(y_1, \dots, y_{T'} | x_1, \dots, x_T) = \prod_{t=1}^{T'} p(y_t | v, y_1, \dots, y_{t-1}) \quad (3)$$

v は入力単語列を固定次元で表したベクトルであり , エンコーダとしての LSTM の最終的な隠れ層の状態と与えられる . また , 1 つ目の出力単語 y_1 を生成する際には直前に生成された単語が存在しないため , デコーダとしての LSTM の最初の隠れ層に v のみを与える .

seq2seq を用いた生成は , 機械翻訳 [5, 18] や自動要約 [14] などのタスクで有効であることが報告されている . また , 対話における応答生成タスク [15] でも , seq2seq は入力発話に対して適切かつ言語的に流暢な応答を生成できることが確認されている . なお , seq2seq を用いて十分な精度の生成を行う場合 , 一般的には 100 万オダの大規模な学習データが必要とされており , 上述した生成に関する研究でも同様の規模の学習データが使用されている .

2.2 キャラクタ付与に関する研究

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試みとして , 特定のキャラクタの発話に見られる表層的な特徴をパラメータとして記述し , このパラメータを参照しつつルールベースに発話の生成を行うことで , 生成された発話に特定のキャラクタの特徴を再現するという Walker らの研究が存在する [19, 11, 12, 13] . たとえば , Walker らは映画字幕から各キャラクタの発話を収集した各コーパスを作成した後 , 心理学的知見をもとにした社会性や誠実さなどのキャラクタらしさを表す要素について , コーパス中のキャラクタの発話に見られる特定の特徴をパラメータとして表した . このパラメータに依存して , 生成された発話の表層的特徴が変化するような発話生成規則を記述した . 発話の生成は , 発話を通じて伝達することを内容を表現した「発話意図」をもとにルールベースで行う . 発話意図を満たすように発話の生成を行うが , このときに付与するキャラクタの特徴を表したパラメータを参照しつつ発話生成規則を適用することで , 生成される発話に特定のキャラクタ性を持たせることに成功した .

また宮崎らは , 一般的な発話を特定のキャラクタ性を持つ発話に書き換えることで , キャラクタ性を付与する手法を提案している [20] . 宮崎らは一般的な発話を収集してコーパスを作成し , コーパス中の発話文における各文節の機能表現部

分について、特定のキャラクタ性を持つ発話となるよう人手で書き換えを行うことで、通常の発話にキャラクタ性を付与する際の書き換え規則を抽出した。ここで抽出した書き換え規則を一般的な発話に適用することで、一般的な発話を特定のキャラクタが付与された発話へと変換する。この手法は、人手による書き換えにコストがかかるものの、言語的に流暢かつ内容に広いバリエーションを持った発話に特定のスタイルを付与することを可能にした。

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、対話データの発話者をベクトル空間上で表現し、seq2seq で対話データと発話者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 [10]。具体的には、Twitter から特定のユーザの発話データをそれぞれ収集し、学習時に発話データとその発話者を同時に学習する。この学習により、発話者情報をベクトル空間上にマッピングすることができ、各単語の生成時にこの発話者情報を単語ベクトルと同時に入力することで、その発話者らしい応答を生成する。この手法によって生成された応答は、発話者の出身地や職業などで表される人物像が一貫したものとなっており、特定のキャラクタ性が生成される発話の内容に反映されている。

2.3 転移学習

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 [1]。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 [2] や商品レビューの極性分類 [3]、機械翻訳 [9, 6] などのタスクで有効であることが確認されている [16]。また、GloVe [17] 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

3.1 転移学習を用いた応答のスタイル付与

図??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 [18] 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．

3.1.1 Transfer モデル

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．以降，事前学習コーパスに含まれる出現頻度上位 N_s 個の単語を用い，事前学習とスタイル付与のための転移学習を実施して作成したモデルを *Transfer* と呼ぶ．

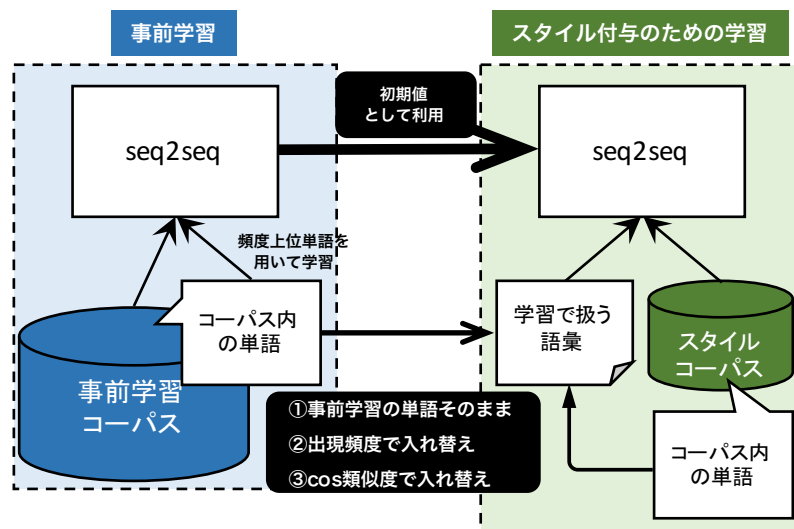


Figure 2: 提案モデル

3.2 転移学習時の単語の扱いに関する問題と解決案

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 特殊な記号 (たとえば, $\langle \text{unk} \rangle$) 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異な単語が扱えなくなる可能性が生じる．この問題を防ぐため，本研究ではスタイルコーパスを用いて転移学習を行う際に，2種類の方法で学習で扱う単語の再構築を行う．単語の再構築を行うことでスタイルコーパスにのみ出現する単語を扱うことを可能にし，特定のスタイルの模倣力の向上を図る．扱う単語の再構築手法の違いにより *Transfer+freq* と *Transfer+sim* の2つのモデルを作成した．

3.2.1 *Transfer+freq* モデル

Transfer+freq では，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，出現頻度上位 N_s 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．このモデルは図2において，スタイル付与のための学習で扱う語彙を構築する際にの処理を行なった場合である．この語彙再構築手法は，スタイルコーパスに特有かつ出現頻度上位である単語はそのスタイルをよく表現している，という仮定に基いて，スタイルをよく表現する単語を学習で扱えるようにすることを目的にしている．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．

3.2.2 *Transfer+sim* モデル

Transfer+sim では，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，Glove [17] で学習した単語ベクトル上で，事前学習コーパス内の単語と一定以上のコサイン類似度を持つ語をスタイルコーパスに出現する単語で置き換えを行う．このモデルは図2における語彙構築時に，の処理を行なった場合である．このとき，コサイン類似度の高い単語から優先して置き換えを行い、置き換えた単語は事前学習コーパスで学習した単語ベクトルを引き継いでス

タイル付与のための学習を行った。

4 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．使用した2種類のコーパスの内容を表2に示す．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て実験に用いた．

Table 2: 実験に使用したコーパス

	発話者	番組	発話-応答ペア数	語彙数
事前学習コーパス	-	-	3,688,162	591,880
スタイルコーパス	黒柳徹子	徹子の部屋	12,564	12,102
	おじゃる丸	おじゃる丸	1,476	2,137

4.1 事前学習コーパス

事前学習コーパスとして，Twitter から対話データを大規模に収集した．Twitter の対話データは，2015年1月から12月の間に投稿されたリプライ付きの投稿から，リプライとしてのツイートを〈応答〉，〈応答〉に先行するツイートを〈発話〉として発話-応答ペアを抜き出した．その後，抽出した発話-応答ペアにフィルタ処理を行い，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370万ペアを事前学習コーパスとして利用した．

4.2 スタイルコーパス

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・発話情報を抜き出したものである．本研究では，付与するスタイルとして，黒柳徹子とおじゃる丸の2種類の発話スタイルを採用した．表2該当する番組の字幕から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〉として発話-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，スタイルコーパスとして収集した発話-応答ペアのうち，黒柳徹子とおじゃる丸の応答の例をそれぞれ示す．

ここでスタイルコーパスのデータ量を事前学習コーパスと比較すると、黒柳徹子スタイルコーパスは事前学習コーパスの約 0.3%、おじゃる丸コーパスは約 0.04%と非常に小規模であることが分かる。

Table 3: スタイルコーパスの応答の例

(a) 黒柳徹子スタイルコーパス	(b) おじゃる丸スタイルコーパス
黒柳徹子の応答	おじゃる丸の応答
そうそうそうそう。	マロはぐうたらしておらぬ。
覚えていらした?	散歩でおじゃる。
召し上がるんですって?	教えてたも。
そうそうそうそう。	おじゃっおいしいでおじゃる!
お綺麗ね。	オホホソチらまだまだあまいの。

5 実験

5.1 モデル設定

5.1.1 提案手法モデル

3つの提案手法 *Transfer* (図3(c)), *Transfer+freq* (図3(d)), *Transfer+sim* (図3(e))では, 事前学習コーパス内の頻度上位 25,000 単語を用いて, 事前学習を実施した. 事前学習コーパスを 5 周学習した後, 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, *Transfer* モデルでは, 単語の入れ替えを行わずにスタイルコーパスで再度学習した. *Transfer+freq* モデルでは, 黒柳徹子スタイルコーパスでは頻度上位 1,000 単語, おじゃる丸スタイルコーパスでは頻度上位 500 単語を用いて単語の入れ替えを行い, *Transfer+sim* モデルでは, Twitter から抽出した発話を GloVe で学習した 128 次元の単語ベクトルを用いて, コサイン類似度が 0.6 以上の単語の置き換えを行った. 各モデルはそれぞれのスタイルコーパスを 10 周学習した後, 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.

5.1.2 ベースラインモデル

提案手法との比較に用いるベースライン手法として, 転移学習を行わない seq2seq のモデル *Base* (図3(a)), *Mixed* (図3(b)) の 2 種類のモデルを用意した. *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り, 事前学習コーパス内の出現頻度上位 25,000 単語を扱う. この *Base* は, 3つの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 単語を学習で扱う. 各モデルは, それぞれ学習データを 5 周学習した後, 各モデルについ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.

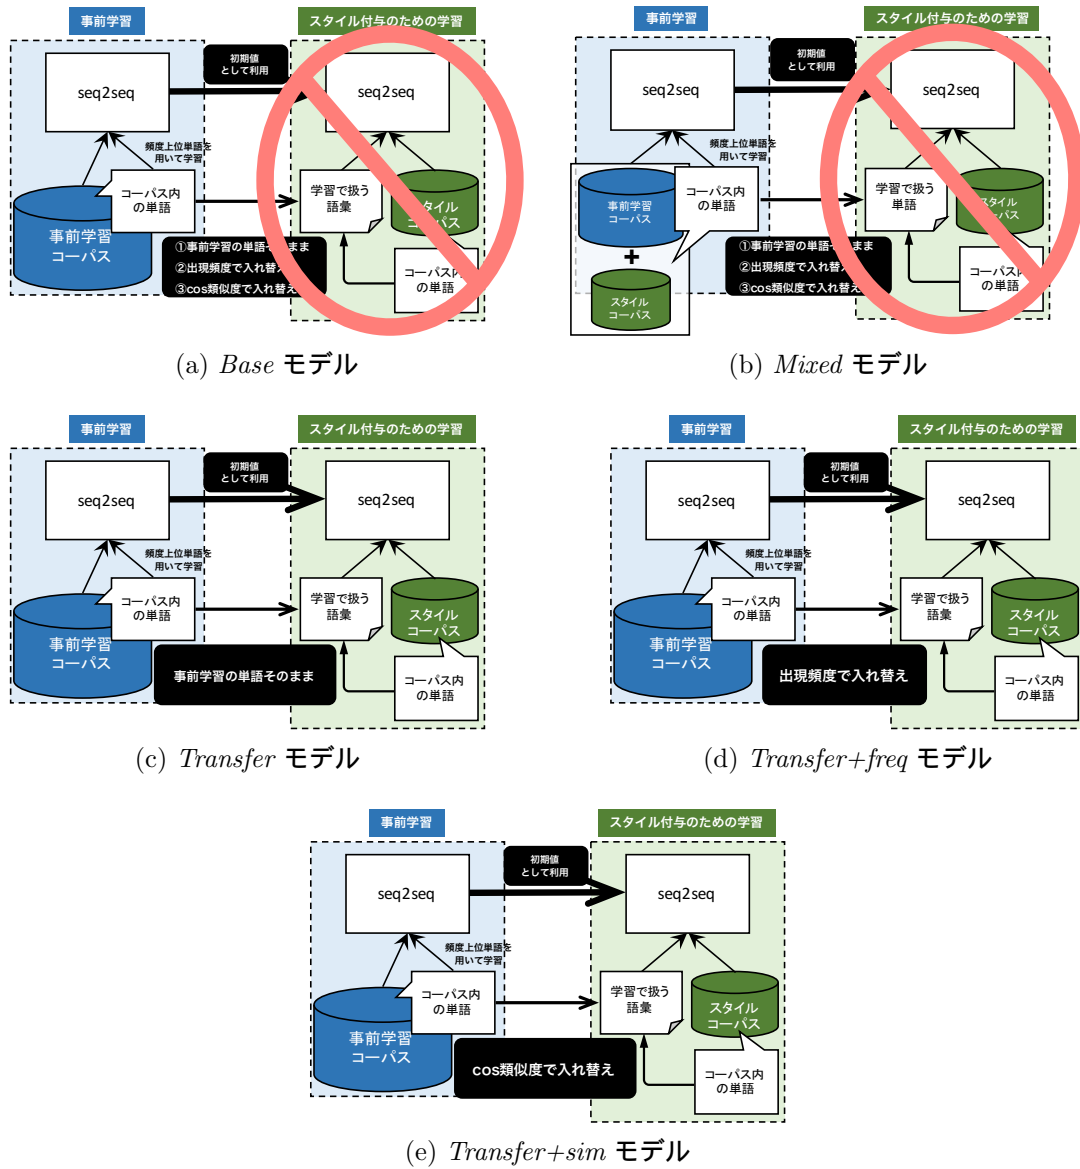


Figure 3: 生成実験を行う5種のモデル

5.1.3 全てのモデルに共通の学習設定

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 [8] 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効率を高めるため、Adam の全てのパラメータを引き継がずに学習した。

5.2 結果

5.2.1 人手による評価

各モデル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。評価者は、各応答を 1) 応答の適切さについては「入力に対して適切/不適切」の 2 値、2) スタイル付与については「成功/失敗」の 2 値に分類し、スコア付けを行った。なお、評価者が生成された応答と生成モデルとの対応を知らない状態で、評価を実施した。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 50 対の先行する発話部分を用いた。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 4 と表 5 に評価結果を示す。表中の数字は、評価者の過半数が「応答が適切」または「スタイル付与成功」と回答した応答の個数を表し、続く括弧内はその割合を表す。

表 4 より、黒柳徹子スタイルを付与した場合は、3 種の提案手法全てが *Base* と変わらず 80% 程度の精度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 3 種全てが 80% 程度の精度でスタイルの付与に成功した。*Transfer+freq* モデルは *Mixed* モデルと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であるにも関わらず、スタイルの付与に関する評価が *Mixed* モデルを上回る結果となったことから、転移学習を用いた提案手法は小規模な学習データでのスタイル付与に有効であるといえる。一方、表 5 より、おじゃる丸スタイルを付与した場合は、提案手法 *Transfer*、*Transfer+freq* はスタイルの付与の成功が 90% を超える

Table 4: 黒柳徹子スタイルでの評価結果

	1. 応答が適切	2. スタイル付与成功
<i>Base</i>	39 (78%)	18 (36%)
<i>Mixed</i>	39 (78%)	23 (46%)
<i>Transfer</i>	41 (82%)	39 (78%)
<i>Transfer+freq</i>	38 (76%)	39 (78%)
<i>Transfer+sim</i>	39 (78%)	38 (76%)

*評価者：4人

Table 5: おじゃる丸スタイルでの評価結果

	1. 応答が適切	2. スタイル付与成功
<i>Base</i>	43 (86%)	0 (0%)
<i>Mixed</i>	40 (80%)	16 (32%)
<i>Transfer</i>	29 (58%)	45 (90%)
<i>Transfer+freq</i>	31 (62%)	47 (94%)
<i>Transfer+sim</i>	32 (64%)	44 (88%)

*評価者：2人

結果となったが、応答の適切さは提案手法3種全てが60%程度と、*Base*を大きく下回る結果となった。入力に対して不適切と判断した応答として、*Transfer+freq*による実際の生成応答例を示した表7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、スタイルコーパスと事前学習コーパスの間に単語や対話内容の重複がほとんど存在しなかった可能性がある。その結果、事前学習で得た知識を十分に活用できずに、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。

5.2.2 一貫したスタイルが付与された応答

2種類のスタイルを高い精度で付与することに成功した提案手法 *Transfer+freq* を用いた対話システムの応答生成結果の一例を、表6と表7に示す。システムへの入力は、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、デコード時には生起確率をもとにした確率的な単語選択

により応答を生成した。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、スタイルコーパスとして約1,400の発話-応答ペアしかないにも関わらず、おじゃる丸特有の語尾「~かの」が付与されていることが確認できる。

Table 6: 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

Table 7: 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> : そんな薄着をしてたのかの?

6 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，提案手法に必要となる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

本研究を進めるにあたり，ご指導，ご助言を頂いた乾健太郎教授，岡崎直観准教授に心より感謝致します．また，日頃より研究活動や論文執筆を直接指導してくださいました，稲田和明氏，株式会社 Preferred Networks の小林颯介氏に深く感謝致します．さらに，日々の議論の中で様々なご助言を頂いた乾・岡研究室の皆様に感謝致します．

なお，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．

References

- [1] Nips 2005 workshop inductive transfer: 10 years later. 2005. <http://iitrl.acadiau.ca/itws05/>.
- [2] Andrew Arnold, Ramesh Nallapati, and William W Cohen. A comparative study of methods for transductive transfer learning. In *Data Mining Workshops, 2007. ICDM Workshops 2007. Seventh IEEE International Conference on*, pp. 77–82. IEEE, 2007.
- [3] John Blitzer, Mark Dredze, Fernando Pereira, et al. Biographies, bollywood, boom-boxes and blenders: Domain adaptation for sentiment classification. In *ACL*, Vol. 7, pp. 440–447, 2007.
- [4] Kyunghyun Cho, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using rnn encoder-decoder for statistical machine translation. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Association for Computational Linguistics, 2014. <http://www.aclweb.org/anthology/D14-1179>.
- [5] Bahdanau Dzmitry, Cho Kyunghyun, and Bengio Yoshua. Neural machine translation by jointly learning to align and translate. In *The International Conference on Learning Representations (ICLR)*, 2015.
- [6] Almut Silja Hildebrand, Matthias Eck, Stephan Vogel, and Alex Waibel. Adaptation of the translation model for statistical machine translation based on information retrieval. In *Proceedings of EAMT*, Vol. 2005, pp. 133–142, 2005.
- [7] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, pp. 1735–1780, 1997.
- [8] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. In *The International Conference on Learning Representations (ICLR)*, 2015.

- [9] Philipp Koehn and Josh Schroeder. Experiments in domain adaptation for statistical machine translation. In *Proceedings of the second workshop on statistical machine translation*, pp. 224–227. Association for Computational Linguistics, 2007.
- [10] 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.
- [11] Grace I Lin and Marilyn A Walker. All the world’s a stage: Learning character models from film. In *AIIDE*, 2011.
- [12] François Mairesse and Marilyn A Walker. Towards personality-based user adaptation: psychologically informed stylistic language generation. *User Modeling and User-Adapted Interaction*, pp. 227–278, 2010.
- [13] François Mairesse and Marilyn A Walker. Controlling user perceptions of linguistic style: Trainable generation of personality traits. *Computational Linguistics*, pp. 455–488, 2011.
- [14] Ramesh Nallapati, Bowen Zhou, Cicero dos Santos, Caglar Gulcehre, and Bing Xiang. Abstractive text summarization using sequence-to-sequence rnns and beyond. In *Proceedings of The 20th SIGNLL Conference on Computational Natural Language Learning*, pp. 280–290. Association for Computational Linguistics, 2016.
- [15] Vinyals Oriol and Le Quoc. A neural conversational model. In *International Conference on Machine Learning(ICML) Deep Learning Workshop 2015*, 2015.
- [16] 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.
- [17] Jeffrey Pennington, Richard Socher, and Christopher D. Manning. Glove: Global vectors for word representation. In *Empirical Meth-*

ods in Natural Language Processing (EMNLP), pp. 1532–1543, 2014.
<http://www.aclweb.org/anthology/D14-1162>.

- [18] 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.
- [19] 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.
- [20] 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.