

話題展開器を導入した外部知識に基づく ニューラル対話モデル

田中 涼太^{1,a)} 李 晃伸^{1,b)}

概要: ニューラル対話モデルの多くは、過度に一般的な応答を繰り返す現象が問題視されている。近年、この問題に対して、Web テキストを始めとする非構造化外部知識を対話モデルに導入するアプローチが盛んに行われている。外部知識を用いることで、入力発話における様々な話題に対する適応を可能にし、情報性の高い応答の生成が期待できる。一方で、一連の対話において、人間が日常的に行う話題を進展させることや関連する話題を扱うことは、話題を切り替える（話題展開）制御が明示的に行われていないため実現困難である。本研究は話題展開を制御する機構として Topic Drifter を導入した外部知識に基づくニューラル対話モデルを提案する。Topic Drifter により入力文中の話題を展開する単語を出力し、また、それらの単語をシステム応答において用いるか否かを予測する。提案モデルは対話履歴と外部知識および Topic Drifter の出力を基に応答を生成する。提案モデルの有効性を検証するために DSTC7 データセットを用いて評価実験を行った結果、多様性、一貫性、制御性における評価尺度において最先端のモデルを上回る性能を示した。

Knowledge-based Neural Conversational Model with Topic Drifter

1. はじめに

ニューラルネットの枠組みを用いた雑談対話システムの研究が SNS の普及や計算機技術の発展により、注目されている。特に、sequence-to-sequence (seq2seq) [23] は応答生成の研究分野において広く使用されており、流暢な応答文を生成できる利点がある。一方、‘I don’t know’ といった過度に一般化された応答を頻繁に出力してしまい、情報性が低い対話になる傾向にあることが問題視されている [24][26][7]。

近年、この問題に対して、モデルの入力として対話文以外に SNS の投稿文 [5] やペルソナ文 [28]、情報共有サイトの記事 [27] を始めとする非構造化テキストデータを外部知識として用いた対話モデルが多く提案されている。これらの入力を扱うモデルの例として、Memory Network [17] の記憶構造を利用したモデル [5] や機械読解モデルの枠組みを利用したモデル [15] などが挙げられる。また、対話モデルの性能を測る競技会 (DSTC7) では、文書要約タスク

表 1 対話例.

Dialogue Context	What is your favorite movie ? → I like to watch the Ironman. → (...) → OK ! Let’s change the topic a little.
Knowledge (Kg.)	Ironman is a hero (...) shot in NYC. The movie named Ironman is (...) in 2008.
Neural w/o Kg.	Yes. I think so too.
Neural w/ Kg.	Ironman was shot in NYC.
Human	Who is the Marvel Comics founded ?

で用いられている pointer generator [16] を利用したモデル [19] が情報性の高い応答生成に有効であることが報告されている [27]。これらのモデルは、外部知識を用いることで様々な話題に対する適応を可能にし、情報性の高い応答文の生成が期待できる。

一方、一連の対話において常に話題に基づいて応答を行うことは、話題の固定化を招き、ユーザの対話に対する興味を阻害してしまう可能性がある。そのため、表 1 の対話例で示すように、人間が日常的に行っている話題を進展させることや、関連する話題を扱うこと (e.g. *Ironman* → *Marvel*) は必要不可欠であると考えられるが、従来のモデルでは話題を切り替える（話題展開）制御が明示的に

¹ 名古屋工業大学
Nagoya Institute of Technology
a) rtanaka@slp.nitech.ac.jp
b) ri@nitech.ac.jp

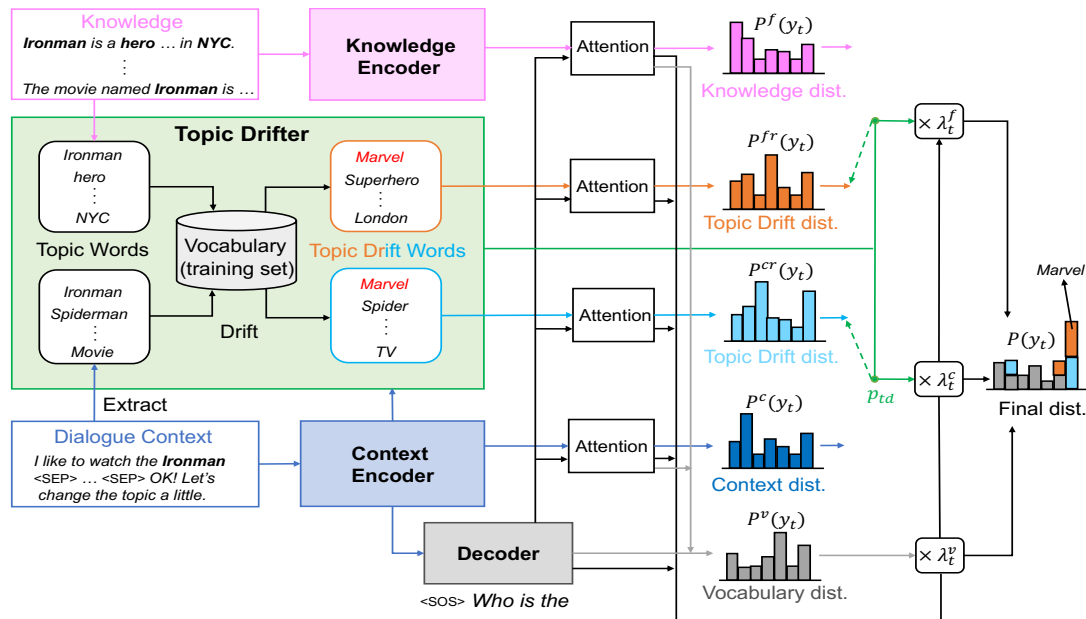


図 1 提案モデルの概要図. Topic Drifter によって入力文の話題を展開する単語を出力する. また, Topic Drifter から出力される単語を使うか否かを制御し, 最終的に入力文の話題に関連する単語 *Marvel* を出力している.

行われていないため実現が困難である. 近年の研究では, $\langle \text{entity}, \text{relation}, \text{entity} \rangle$ 形式の構造化知識を基に話題を展開するモデル [10] が提案されているが, 非構造化知識を対象とした対話モデルにおいて検討されていない. また, 対話において話題展開は常に行うべきではないが, ニューラル応答生成の統一的な枠組みにおいて適切な話題展開を行うタイミングについて検討されていない.

そこで, 本研究は話題展開を制御する機構 Topic Drifter を導入した外部知識に基づくニューラル対話モデルを提案する. Topic Drifter は二つの機能を持つ: 1) 入力文の話題を展開する単語を出力する, 2) 対話履歴が与えられた時にシステム応答において話題展開を行うか否かを予測する. 提案モデルは, 対話履歴と外部知識および Topic Drifter の出力を基に応答を生成する. 提案モデルの有効性を検証するために, DSTC7 データセットを用いて自動評価を行った結果, 提案モデルは多様性, 一貫性, 制御性におけるスコアにおいて従来法を大きく上回る結果を残した.

ここで, 本研究における貢献を以下に示す.

- 人間が日常的に行う話題展開の現象に言及し, 話題展開を制御する機構として Topic Drifter を提案した.
- Topic Drifter の出力を基に話題展開を行う非構造化知識に基づくニューラル対話モデルを提案した.
- 実験の結果, 提案モデルは複数の評価尺度において従来法を大きく上回る性能を残した.

2. アプローチ

2.1 問題定義

対話履歴 $X^c = \{x_1^c, \dots, x_T^c\}$ と K 個の対話履歴に関連する外部知識 $X^{fk} = \{x_1^{fk}, \dots, x_J^{fk}\} (k = 1, \dots, K)$ が与えられた時に, システムは入力に対して応答文 $Y = \{y_1, \dots, y_T\}$ を出力する. 対話履歴は最大過去 6 発話までとし, 発話の区切りを表す特殊記号 $\langle \text{SEP} \rangle$ によって結合した.

2.2 モデルの概要

提案モデルの概要を図 1 に示す. 本モデルは大きく分けて 3 つの以下のモジュールによって構成されている:

- **対話履歴・外部知識 Encoder**: 対話履歴 X^c と外部知識 X^{fk} を入力とし, 隠れ状態 H^c, H^{fk} を出力する (2.3 節).
- **Topic Drifter**: 我々が提案する対話展開を行うための機構であり, 二つの機能を持つ. 一つ目は, 入力文の話題を展開する単語 X^{cr}, X^{fr} の出力, 二つ目は, 次発話で話題が展開される確率 p_{td} の出力である. (2.4 節)
- **Decoder**: pointer generator [16] の枠組みを利用して, 語彙からの生成および対話履歴, 外部知識, 話題展開語のコピーを行うことで応答を生成する. また, p_{td} を用いて話題展開の制御を行う. (2.5 節)

2.3 対話履歴・外部知識 Encoder

対話履歴もしくは、 K 個の外部知識を入力とし、順方向と逆方向の Gated Recurrent Unit (GRU) [2] を適用して、隠れ状態 $H^c = \{H_1^c, \dots, H_I^c\}$ と $H^{fk} = \{H_1^{fk}, \dots, H_J^{fk}\} (k = 1, 2, \dots, K)$ を出力する。

$$H_i^c = [\text{GRU}(\overrightarrow{h_{i-1}^c}, e(x_i^c)); \text{GRU}(\overleftarrow{h_{i-1}^c}, e(x_i^c))], \quad (1)$$

$$H_j^{fk} = [\text{GRU}(\overrightarrow{h_{j-1}^{fk}}, e(x_j^{fk})); \text{GRU}(\overleftarrow{h_{j-1}^{fk}}, e(x_j^{fk}))], \quad (2)$$

ここで、 $H^c \in \mathbb{R}^{2d \times I}$, $H^{fk} \in \mathbb{R}^{2d \times J}$ (d は隠れ状態の次元数) は順方向および逆方向の全ての隠れ状態を連結 ($[\cdot; \cdot]$) したベクトルであり、 $e \in \mathbb{R}^{d_v \times |V|}$ ($|V|$ は語彙数、 d_v は単語分散表現の次元数) は事前学習で獲得された GloVe [14] から出力される単語分散表現である。パラメータ数削減のため、対話履歴 Encoder と外部知識 Encoder のパラメータは全て共有した。

2.4 Topic Drifter

Topic Drifter は、入力文の話題を展開する単語 (i.e. 話題展開語) の出力 (2.4.1 節)、および、次発話において話題展開を行う確率 p_{td} の予測 (2.4.2 節)、を行う。話題展開語は、表 1 で示した対話例において人間が行った応答に含まれている ‘Marvel’ に相当する。また、対話履歴における最終発話 ‘OK! Let’s change the topic a little.’ では、話題が収束し、次発話において話題展開を促す発話になっているため、Topic Drifter は $p_{td} \approx 1$ と予測することを期待する。

2.4.1 話題展開語の出力

対話履歴と外部知識中の話題語に関連する単語を出力する。対話履歴だけでなく外部知識に対しても話題展開を考慮する理由として、対話履歴中に陽に出現しない話題から展開を行うためである。

はじめに、対話履歴および外部知識中の特定の品詞 (名詞、形容詞、動詞) を持つ単語を対象にし、話題語を抽出する。話題語抽出には、単語の重要度を測る指標として一般的に使用されている TF-IDF を用いてスコアを算出し、閾値 (各サンプルにおける上位 10%) を満たす単語を話題語とした。次に、ここで抽出したそれぞれの話題語に対して、GloVe 空間上におけるコサイン距離で最も近い N_{sim} 単語を学習コーパスから作成した語彙の中から出力する。これを対話履歴および外部知識中の全ての話題語に対して行うことで、 $N_{td}^c, N_{td}^f = (\text{話題語数} \times N_{sim})$ 個の話題展開語 $X^{cr} = \{x_1^{cr}, \dots, x_{N_{td}^c}^{cr}\}$, $X^{fr} = \{x_1^{fr}, \dots, x_{N_{td}^f}^{fr}\}$ を獲得する。ここで、 N_{sim} は話題の展開幅を表すハイパーパラメータとして見なすことができる。

2.4.2 話題展開予測

対話履歴が与えられた時、システム応答において話題が展開される確率 $p_{td} \in [0, 1]$ を出力する。具体的には、対話履歴 Encoder で得られた順方向の最終隠れ状態 $\overrightarrow{h_I^c}$ を入力

に以下の式を基に算出する。

$$p_{td} = \text{sigmoid}(W_{td}^T \overrightarrow{h_I^c} + b_{td}), \quad (3)$$

ここで、 $W_{td} \in \mathbb{R}^d$, $b_{td} \in \mathbb{R}^d$ は学習パラメータである。また、 $p_{td} = 1$ の時にシステム応答において話題展開、 $p_{td} = 0$ の時に話題継続を行うことを意味する。

2.5 Decoder

Decoder では pointer generator [16] の枠組みを利用して、Topic Drifter の出力を考慮した応答生成を目指す。はじめに、対話履歴 Encoder で得られた双方向の最終隠れ状態 H_I^c を初期状態 s_0 、初期入力単語 y_0 を開始記号を表す特殊記号 <SOS> とする順方向 GRU を用いて t 時刻における Decoder の隠れ状態 $s_t \in \mathbb{R}^{2d}$ を自己再帰的に算出する。

$$s_t = \text{GRU}(e(y_{t-1}), s_{t-1}). \quad (4)$$

2.5.1 Attention

本研究で用いる Attention 機構 [1] を定義する。Attention 機構を用いることで、入力のどの単語に着目するかを表す α と、 α を考慮した隠れ状態であるコンテキストベクトル \hat{s} を算出できる。系列ベクトルを $U = \{u_1, \dots, u_{|U|}\} \in \mathbb{R}^{d_{att} \times |U|}$ とクエリベクトルを $Q \in \mathbb{R}^{d_{att}}$ としたとき、Attention 機構 $\alpha \in \mathbb{R}^{|U|}$, $\hat{s} \in \mathbb{R}^d = \text{Attention}(U, Q)$ を以下で定義する。

$$g_m = W_{uq}^T \tanh(W_u u_m + W_q Q + b_{uq}), \quad (5)$$

$$\alpha_m = \text{softmax}([g_1, \dots, g_{|U|}]), \quad \hat{s} = \sum_{m=1}^{|U|} \alpha_m u_m,$$

ここで、 $W_{uq} \in \mathbb{R}^d$, $W_u, W_q \in \mathbb{R}^{d \times d_{att}}$, $b_{uq} \in \mathbb{R}^{d_{att}}$ は学習パラメータである。これらのパラメータは系列ベクトル U ごとに個別に用意することを留意されたい。

2.5.2 コピー分布

対話履歴、外部知識、話題展開語に対してそれぞれ 2.5.1 で定義した Attention 機構を用いて、コピー分布を算出する。

対話履歴に関しては、対話履歴 Encoder から出力された双方向の隠れ状態 H^c と t 時刻における Decoder の隠れ状態 s_t を入力として、attention 重み $\alpha_t^c \in \mathbb{R}^f$ とコンテキストベクトル $\hat{s}_t^c \in \mathbb{R}^{2d}$ を求める (式 6)。また、attention 重みを統合することでコピー分布 $P^c(y_t)$ を算出する (式 7)。

$$\alpha_t^c, \hat{s}_t^c = \text{Attention}(H^c, s_t), \quad (6)$$

$$P^c(y_t) = \sum_{\{i: x_i = y_t\}} \alpha_{t,i}^c. \quad (7)$$

外部知識に関しては、Yavuz らのアイデアを参考にし、単語単位と文単位の両者の Attention を考慮する階層型 Attention [25] を行う。これにより、応答文に無関係な

知識からの生成を回避することを期待する。まず、各外部知識中の単語に関して $\alpha_t^{fk} \in \mathbb{R}^J$ と $\hat{s}_t^{fk} \in \mathbb{R}^{2d}$ を計算し (式 8), 次に外部知識集合における各文に関して $\alpha_t^f \in \mathbb{R}^K$ と $\hat{s}_t^f \in \mathbb{R}^{2d}$ を計算する (式 9). コピー分布 $P^f(y_t)$ は単語単位の attention 重みと文単位の attention 重みを統合することで算出する (式 10).

$$\alpha_t^{fk}, \hat{s}_t^{fk} = \text{Attention}(H^{fk}, s_t), \quad (8)$$

$$\alpha_t^f, \hat{s}_t^f = \text{Attention}([\hat{s}_t^{f1}, \dots, \hat{s}_t^{fK}], s_t), \quad (9)$$

$$P^f(y_t) = \sum_{k=1}^K \alpha_{t,k}^f \sum_{\{j:\hat{s}_t^{fk}=y_t\}} \alpha_{t,j}^{fk}. \quad (10)$$

話題展開語に関しては, 系列ベクトル U を話題展開語 X^{cr}, X^{fr} を入力とした GloVe の単語分散表現として, attention 重み $\alpha_t^{cr} \in \mathbb{R}^{N_{td}^c}, \alpha_t^{fr} \in \mathbb{R}^{N_{td}^f}$ とコンテキストベクトル $\hat{s}_t^{cr}, \hat{s}_t^{fr} \in \mathbb{R}^{d_v}$ を計算する (式 11,12). さらに, attention 重みを基にコピー分布 $P^{cr}(y_t), P^{fr}(y_t)$ を算出する (式 13,14).

$$\alpha_t^{cr}, \hat{s}_t^{cr} = \text{Attention}([e(x_1^{cr}), \dots, e(x_{N_{td}^c}^{cr})], s_t), \quad (11)$$

$$\alpha_t^{fr}, \hat{s}_t^{fr} = \text{Attention}([e(x_1^{fr}), \dots, e(x_{N_{td}^f}^{fr})], s_t), \quad (12)$$

$$P^{cr}(y_t) = \sum_{\{l1:x_{l1}^{cr}=y_t\}} \alpha_{t,l1}^{cr}, \quad (13)$$

$$P^{fr}(y_t) = \sum_{\{l2:x_{l2}^{fr}=y_t\}} \alpha_{t,l2}^{fr}. \quad (14)$$

2.5.3 分布の統合

得られたコピー分布と Decoder における言語モデルから出力される語彙分布を統合する。ここで, 語彙分布は学習パラメータを $W_v \in \mathbb{R}^{6d \times |V|}$ としたとき, $P^v(y_t) = \text{softmax}(W_v^T [s_t; \hat{s}_t^c; \hat{s}_t^f])$ として求めることができる。分布の統合を行うために, Topic Drifter から出力された p_{td} と各ステップごとに分布を切り替える混合係数 $\lambda_t^v, \lambda_t^c, \lambda_t^f = \text{softmax}(W_\lambda^T [s_t; \hat{s}_t^c; \hat{s}_t^f; \hat{s}_t^{cr}; \hat{s}_t^{fr}])$ を用いる。ここで, $W_\lambda \in \mathbb{R}^{(6d+2d_v) \times 3}$ は学習パラメータである。応答文の単語 y_t における出力分布 $P(y_t)$ を以下の混合分布として定義する。

$$P(y_t) = \lambda_t^v P^v(y_t) + p_{td}(\lambda_t^c P^{cr}(y_t) + \lambda_t^f P^{fr}(y_t)) + (1 - p_{td})(\lambda_t^c P^c(y_t) + \lambda_t^f P^f(y_t)). \quad (15)$$

上記の混合分布は, p_{td} が大きくなるほど, 話題展開語のコピー分布を用いる傾向になる。そのため, Topic Drifter の話題展開予測結果に応じて話題展開の切り替えを行うことが期待できる。

2.6 モデルの学習

モデルの学習は, γ_{td}, γ_{sw} を損失関数の重みを調整するハイパパラメータとしたとき, 3つの損失関数を組み合わせた $\mathcal{L} = \mathcal{L}_{nll} + \gamma_{td}\mathcal{L}_{td} + \gamma_{sw}\mathcal{L}_{sw}$ を最小化する。

表 2 DSTC7 データセットの統計情報.

データ		train	dev	test
対話	対話数	1662093	110184	2208
	単語数/発話	20.50	21.89	19.64
外部知識	単語数/文	45.62	45.88	45.37

2.6.1 Negative Log-likelihood Loss

seq2seq の損失関数に一般的に用いられている応答文長で正規化した負の対数尤度損失を用いる。

$$\mathcal{L}_{nll} = -\frac{1}{T} \sum_{t=1}^T \log(P(y_t)). \quad (16)$$

2.6.2 Switch Loss

Decoder の各ステップにおいてコピー分布もしくは語彙分布を用いるかを制御するために Binary Cross Entropy (BCE) を用いた損失を導入する。t 時刻におけるコピー分布の混合係数を $\lambda_t^{ref} = \lambda_t^c + \lambda_t^f$ としたとき, 以下の損失を定義する。

$$\mathcal{L}_{sw} = -\frac{1}{T} \sum_{t=1}^T \{ \lambda_t \log(\lambda_t^{ref}) + (1 - \lambda_t) \log(1 - \lambda_t^{ref}) \}. \quad (17)$$

ここで, λ_t は Decoder の t 時刻における出力単語 y_t がコピー元に存在するときに 1, それ以外の場合を 0 とする正解ラベルである。

2.6.3 Topic Drift Loss

Topic Drifter における話題展開予測の学習を行うために BCE を用いた損失を導入する。

$$\mathcal{L}_{td} = -g_{td} \log p_{td} - (1 - g_{td}) \log(1 - p_{td}). \quad (18)$$

正解ラベル g_{td} を決定するために, 2.4.1 節で説明した方法で獲得した話題語と応答文との対応関係を用いたルールを設ける: 1) 対話履歴および外部知識中の話題語が応答文に存在する, 2) 話題展開語が応答文に含まれない, の 2 つの条件に対して 1) と 2) の両者が成り立つ場合を 0 (話題継続), 成り立たない場合を 1 (話題展開) とする。

3. 実験設定

3.1 データセット

DSTC7 データセット [27] を用いて学習・評価を行った。データセットは対話データと外部知識データの 2 種類で構成されている。対話データは reddit*1 で行われた 178 個の subreddit (特定トピックの議論を行う場) を限定して収集されている。また, 外部知識は各対話の URL に含まれる単語列を検索クエリとして, Wikipedia を始めとする 226 個の情報共有サイトを用いて収集されている。収集した外部知識はノイズが多く, 対話に関連しないデータが多く存在する。そのため, 我々は IDF をベースとする抽出器 [19]

*1 <https://www.reddit.com>

表 3 評価結果, **bold** が最も高いスコアを示している.

Model	BLEU-1	BLEU-2	BLEU-3	BLEU-4	dist-1	dist-2	Coh	F1	Accuracy
S2S	38.75	11.26	3.99	1.44	6.67	33.58	1.75	79.04	67.26
kgS2S	38.96	11.67	4.20	1.50	8.74	39.63	1.72	78.65	66.44
PGN	41.10	12.94	4.68	1.84	9.80	39.89	1.98	73.61	61.68
kgPGN	40.95	12.99	4.84	1.59	9.84	41.52	2.13	72.68	61.05
Ours	38.85	11.62	4.17	1.69	15.18	53.63	2.59	83.13	71.60

を用いて 1 対話ペアあたり最大 4 文を外部知識として取得した。対話データは 1 発話における最大長を 32, 外部知識は 1 文あたり最大長を 50 とした。実験で用いたデータセットの統計情報を表 2 に示す。

3.2 ベースラインモデル

以下のモデルを提案モデルの比較対象とする。

S2S 外部知識を持たない通常の Sequence-to-Sequence (seq2seq) [23].

kgS2S 入力に対話履歴と外部知識を用いる。外部知識を格納した Memory Networks [17] を持つ S2S [5].

PGN 文書要約タスクで一般的に用いられている pointer generator network [16]. 出力分布は語彙分布と対話履歴のコピー分布を統合することで求める。

kgPGN 対話履歴に加えて外部知識の単語からもコピー可能な PGN [19]. DSTC7 コンペティションにおいて state-of-the-art の結果を残している。

3.3 実装の詳細

モデルの実装には PyTorch^{*2}を用いて行った。Encoder は単層の双方向 GRU, Decoder には単層の順方向 GRU を用いた。また, GloVe の次元数 d_v は 300 とし, 隠れ状態の次元数 d は 128 とした。学習は, バッチサイズを 64 とするミニバッチ学習を採用し, Adam [8] (学習率: 0.0005) を用いて最適化を行った。また, 最大 10 epoch 学習を行い, 開発データにおける perplexity が最も低いモデルを採用した。語彙は対話データと外部知識から作成し, 語彙サイズは 30000 に設定した。また, 未知語は特殊記号 <UNK> に置き換えた。

評価時は, Topk-Decoding [3] ($k = 10$) を用いて応答生成を行った^{*3}。コピー機構を用いることで, 頻繁にコピー元の単語が出力される問題が知られている [16]。本実験では, この問題を解決するために, デコーディング時に既出の 2-gram を出力しないように制約を定めた。

提案モデルにおける損失関数の重み調整ハイパパラメータ γ_{td}, γ_{sw} はともに 1.0 とした。Topic Drifter における N_{sim} は 5 とした。過学習を抑制するために, BCE にお

^{*2} <https://pytorch.org>

^{*3} 予備実験では, Topk-Decoding の他に Beam Search, Greedy Search, Random Sampling を用いて同様に実験を行った結果, 全てのモデルにおいて Topk-Decoding を用いたモデルが最も高い性能であった。

ける正解ラベルに対して平滑化係数 $\epsilon = 0.9$ とする label smoothing [18] を用いて正則化を行った。

3.4 評価尺度

生成された応答文に対して以下の評価尺度を用いる。

BLEU (関連性) 生成された応答文と正解文との関連性を評価する。生成された応答文と正解文との N -gram ($N = 1, 2, 3, 4$) 一致率によって計算される (BLEU-1,2,3,4) [13].

Dist (多様性) 生成された応答文における N -gram ($N = 1, 2$) の多様性を評価する。生成文におけるユニークな N -gram の数を全ての N -gram の数で除算することで求める (dist-1,2) [9].

Coh (一貫性) 対話履歴・外部知識に対して生成文が一貫した応答になっているかを評価する。Tanaka らが用いた評価尺度 [21] を参考にして, 入力文と生成された応答文から算出される自己相互情報量 PMI を評価尺度として用いる。

$$\text{Coh} = \frac{1}{T} \sum_{t=1}^T \max_{x \in \{X^e, X^f\}} \text{PMI}(x, y_t) \quad (19)$$

ここで, 学習データにおいて単語 x が入力文中・応答文中に出現する確率を $P_{in}(x), P_{out}(x)$ としたとき, $\text{PMI}(x, y)$ は $\log_2\{P(x, y)/(P_{in}(x)P_{out}(y))\}$ で表される。

F1, Accuracy (制御性) 生成文が適切なタイミングで話題展開を行っているかについて評価する。対話履歴と生成された応答文に 2.6.3 節で示したルールを適用して得られたラベルと正解ラベルの一致率を算出する (F1, Accuracy)。

4. 評価結果

DSTC7 データセットにおける自動評価結果を表 3 に示す。提案モデルはベースラインモデルと比べて, 多様性 (dist-1,2) と一貫性 (Coh), 制御性 (F1, Accuracy) の 3 つの評価尺度においてスコアが大幅に向上し, 最も高い精度を達成した。S2S や kgS2S は, 明示的に入力文中の単語を応答文に含むことが困難なため, 多様性と一貫性が他のモデルに比べて低い値になっている。また, PGN や kgPGN は, 入力文中の単語を応答文にコピーすることで一貫性と多様性は向上する反面, 入力文中の話題に固定化されてし

表 4 Ablation Study. Topic Drifter を取り除く場合、常に $p_{td}, \gamma_{td} = 0$ とした。

Model	BLEU-1	BLEU-2	BLEU-3	BLEU-4	dist-1	dist-2	Coh	F1	Accuracy
Ours w/o \mathcal{L}_{td}	42.63	14.20	5.36	1.87	11.55	45.70	2.55	65.68	54.71
Ours w/o \mathcal{L}_{sw}	39.83	11.81	4.24	1.58	9.66	40.84	1.75	82.38	70.97
Ours w/o Topic Drifter	41.30	13.36	5.08	1.97	10.86	44.21	2.41	68.26	56.70
Ours	38.85	11.62	4.17	1.69	15.18	53.63	2.59	83.13	71.60

まい、話題展開の制御性が減少する。一方で、提案モデルでは Topic Drifter により話題展開を行うかの予測を行い、また、適切なタイミングで入力に関連する話題を含む話題展開語を応答文に出力することによって、性能が向上したと考えられる。一方、関連性 (BLEU) については向上を確認できなかった。これは、従来研究で報告されているように BLEU と Dist はトレードオフの関係 [12] になる場合があり、Dist の大幅な向上による代償が考えられる。また、多くの研究において BLEU は人手評価との相関が低いことが指摘されており [11][22][4]、今後は生成文に対して人手による評価を検討している。

5. 分析と考察

5.1 Ablation Study

提案モデルにおける各要素の有効性を検証するために、損失関数 $\mathcal{L}_{td}, \mathcal{L}_{sw}$ および Topic Drifter を取り除いた時の性能に関して分析を行った (表 4)。実験結果から分かるように BLEU 以外の指標において、全ての要素を含む提案手法が最も高い精度であった。また、 \mathcal{L}_{td} を取り除くと制御性に関するスコアが低下、 \mathcal{L}_{sw} を取り除くと多様性と一貫性に関するスコアが低下、Topic Drifter を取り除くと多様性と制御性に関するスコアが低下することが確認できる。BLEU の性能変動は先述したように BLEU と Dist の関係性が影響していると考えられる。以上のことから、これら全ての要素を組み合わせることは必要不可欠だと考えられる。

5.2 話題展開予測精度

表 5 話題展開予測精度

Model	F1	Accuracy
Ours w/o \mathcal{L}_{td}	40.62	25.49
Ours	80.27	68.59

4 章では、制御性の評価尺度において生成文が正しいタイミングで話題展開を行えるかについて評価した。本節では、Topic Drifter が正しいタイミングで話題展開を予測できているかについて調査するために、出力された話題展開予測結果と正解ラベルとの一致率 (F1, Accuracy) を算出する。比較対象を話題展開予測の学習に用いた損失 \mathcal{L}_{td} を除いたモデルとした。表 5 から分かるように、F1 で 39.65% の向上 (80.27%)、Accuracy で 43.1% の向上 (68.59%) を確

認できた。2 値分類にも関わらず \mathcal{L}_{td} を導入しない場合において非常に低い精度であった理由として、学習データにおいて話題展開語を用いる対話ペアが全体の約 1 割であったため、データの偏りによる学習の不安定化が原因だと推察される。

5.3 話題の展開幅ハイパパラメータ N_{sim} の影響

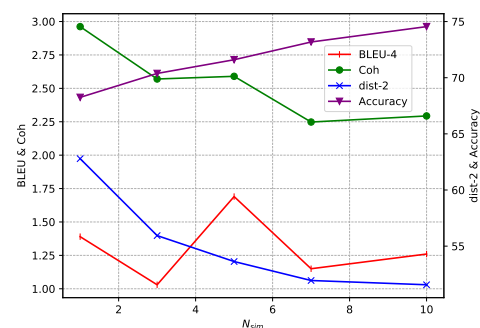


図 2 N_{sim} を動かした時の評価結果。

表 6 N_{sim} を動かした時の生成文あたりの話題展開語数。

N_{sim}	1	3	5	7	10
話題展開語数/応答文	1.57	1.44	1.45	1.37	1.38

2.4.1 節で述べた話題の展開幅を表すハイパパラメータ N_{sim} の影響を調査するために、 N_{sim} を {1,3,5,7,10} の範囲で変化させたときの各評価尺度の結果を示す (図 2)。 N_{sim} を大きくするほど、Dist と Coh は減少、Accuracy は増加をすることが確認できる。これは、表 6 から分かるように、 N_{sim} の増加により応答文に話題展開語が含まれにくくなっているため、Dist と Coh が減少したと考えられる。また、 N_{sim} が小さいほど、頻繁に話題展開語を出力してしまうため制御性 (Accuracy) を失ってしまった可能性が考えられる。BLEU に関しては、増減を繰り返すことから N_{sim} の影響を確認することができなかった。

5.4 出力例

各モデルの出力例を 7 に示す。提案モデルは他のモデルよりも内容語が多く含まれ、情報性が高い応答になっている。対話履歴を見ると、最終発話 'helps being good looking' では話題語が含まれておらず話題が終了している可能性が高い。提案モデルは、kanye や pitbull といった

表 7 各モデルの出力例。下線は抽出された話題語を表す。

Dialogue Context	Before she was famous, <u>Nicki</u> Minaj was fired from approximately fifteen jobs. → So, she got hired 15 times. (...) → <u>Helps</u> being good looking.
Knowledge	In early 2013, <u>Minaj</u> fronted the viva <u>glam</u> campaign by herself, (...) accessories and housewares. (...)
$X^{cr} \cup X^{cf}$	<u>Pitbull</u> , <u>Kanye</u> , insensitivity ,(…), employment
S2S	Well i don't care what she thinks she looks like
kgS2S	She looks a little like a fish.
GTTP	I think i like that.
kgPGN	It's the best way to get a job.
Ours	I love <u>Kanye</u> and <u>Pitbull</u> ... and her sister is pretty hot.

入力文中に関連する話題語 (e.g. *nicki minaj*) を含んだ応答になっており、適切な話題展開が行われている。

6. 関連研究

Seq2seq の枠組みを用いた応答生成の品質向上に向けた様々な研究が行われている。例えば、相互情報量を損失関数に導入することによる応答文の多様性の向上 [9]、コピー機構を用いた未知語に対する対処 [6][16] が挙げられる。これらの貢献により、流暢な応答文の生成が実現されている。しかしながら、任意の状況で使用可能な一般化された応答を行ってしまい、情報性が低い対話になってしまう欠点がある [24][26][7]。

近年、この問題に対して非構造化知識を対話モデルに導入するアプローチが盛んに研究されている。Ghazvininejadらは外部知識のエンコーディングに Memory Networks[17]を用いて seq2seq の拡張を行った [5]。Tanakaらは、外部知識と長距離の対話履歴を考慮した階層型の対話モデルを提案した [20]。Zhangらは、ユーザ像を表すベルソナ文を Decoder に挿入したモデルを提案した [28]。Tamらは、文書要約タスクで用いられる pointer generator [16]を用いて外部知識中の単語を明示的に応答文にコピー可能なモデルを提案した [19]。我々の研究は、これらの研究とは話題展開を考慮している点で異なる。従来研究では、入力文中の話題に基づいて応答生成を行うため、話題の変化が少なく、ユーザの対話に対する興味を阻害する可能性が考えられる。我々のモデルは、話題の展開と非構造化知識を用いたニューラル応答生成を統一的な枠組みによってモデル化することでこの問題に取り組んだ初の研究である。

話題展開を行う応答生成の研究として、Liuらの研究が挙げられる [10]。この研究は、 $\langle \text{entity, relation, entity} \rangle$ 形式の構造化知識を持つ対話モデルによって、入力発話文中の entity にマッチする知識とそれに関連する知識を用いて話題展開を実現している。しかし、構築した知識ベースは単一のドメインに限定されており、オープンドメインの対話における適用が困難である。さらに、話題の展開タイミングに関して検討されていないため、話題の流れを組んだ応答を行うことが困難である。一方で、我々は外部知識

として近年公開された非常に幅広いドメインを扱う非構造化知識 [27] を用いた。また、話題の流れに関して理解を促進するために話題の展開予測を導入し、応答生成とのマルチタスク学習により有効性を検証した。

7. 結論と今後の予定

本研究では、話題展開を行うための機構として Topic Drifter を導入した外部知識に基づくニューラル対話システムを提案した。評価実験により、DSTC7 データセットにおいて多様性、一貫性、制御性に関する評価尺度で最先端のモデルを上回る性能であった。性能向上の要因として、Topic Drifter による話題展開語の出力および話題展開予測を応答生成の枠組みに統合した点が挙げられる。

本モデルでは、話題展開語を入力の話語に対して関連度の高い話語に限定したが、関連度の低い単語を用いることで無関係な話題遷移への拡張が可能である。また、話題語を広く扱うために外部知識を用いたが、外部知識を用いない対話モデルにも適用可能である。今後の予定として、拡張性に関する分析や人手評価の実施を検討している。

参考文献

- [1] Bahdanau, D., Cho, K. and Bengio, Y.: Neural Machine Translation by Jointly Learning to Align and Translate, *ICLR 2015* (2015).
- [2] Chung, J., Gülçehre, Ç., Cho, K. and Bengio, Y.: Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, *CoRR*, Vol. abs/1412.3555 (2014).
- [3] Fan, A., Lewis, M. and Dauphin, Y. N.: Hierarchical Neural Story Generation, *ACL 2018*, pp. 889–898 (2018).
- [4] Ghazarian, S., Wei, J. T., Galstyan, A. and Peng, N.: Better Automatic Evaluation of Open-Domain Dialogue Systems with Contextualized Embeddings, *CoRR*, Vol. abs/1904.10635 (2019).
- [5] Ghazvininejad, M., Brockett, C., Chang, M., Dolan, B., Gao, J., Yih, W. and Galley, M.: A Knowledge-Grounded Neural Conversation Model, *AAAI 2018*, pp. 5110–5117 (2018).
- [6] Gu, J., Lu, Z., Li, H. and Li, V. O. K.: Incorporating Copying Mechanism in Sequence-to-Sequence Learning, *ACL 2016*, pp. 1631–1640 (2016).
- [7] Ke, P., Guan, J., Huang, M. and Zhu, X.: Generating Informative Responses with Controlled Sentence Function, *ACL 2018*, pp. 1499–1508 (2018).
- [8] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *CoRR*, Vol. abs/1412.6980 (2014).
- [9] Li, J., Galley, M., Brockett, C., Gao, J. and Dolan, B.: A Diversity-Promoting Objective Function for Neural Conversation Models, *NAACL-HLT 2016*, pp. 110–119 (2016).
- [10] Liu, S., Chen, H., Ren, Z., Feng, Y., Liu, Q. and Yin, D.: Knowledge Diffusion for Neural Dialogue Generation, *ACL 2018*, pp. 1489–1498 (2018).
- [11] Lowe, R., Noseworthy, M., Serban, I. V., Angelard-Gontier, N., Bengio, Y. and Pineau, J.: Towards an

- Automatic Turing Test: Learning to Evaluate Dialogue Responses, *ACL 2017*, pp. 1116–1126 (2017).
- [12] Nakamura, R., Sudoh, K., Yoshino, K. and Nakamura, S.: Another Diversity-Promoting Objective Function for Neural Dialogue Generation, *CoRR*, Vol. abs/1811.08100 (2018).
- [13] Papineni, K., Roukos, S., Ward, T. and Zhu, W.-J.: Bleu: a Method for Automatic Evaluation of Machine Translation, *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics* (2002).
- [14] Pennington, J., Socher, R. and Manning, C. D.: Glove: Global Vectors for Word Representation, *EMNLP 2014*, pp. 1532–1543 (2014).
- [15] Qin, L., Galley, M., Brockett, C., Liu, X., Gao, X., Dolan, B., Choi, Y. and Gao, J.: Conversing by Reading: Contentful Neural Conversation with On-demand Machine Reading, *ACL 2019*, pp. 5427–5436 (2019).
- [16] See, A., Liu, P. J. and Manning, C. D.: Get To The Point: Summarization with Pointer-Generator Networks, *ACL 2017*, pp. 1073–1083 (2017).
- [17] Sukhbaatar, S., Szlam, A., Weston, J. and Fergus, R.: End-To-End Memory Networks, *Advances in Neural Information Processing Systems 28*, 2015, pp. 2440–2448 (2015).
- [18] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z.: Rethinking the Inception Architecture for Computer Vision, *CVPR 2016*, pp. 2818–2826 (2016).
- [19] Tam, Y.-C., Ding, J., Niu, C. and Zhou, J.: Cluster-based Beam Search for Pointer-Generator Chatbot Grounded by Knowledge, *DSTC7* (2019).
- [20] Tanaka, R., Ozeki, A., Kato, S. and Lee, A.: An Ensemble Dialogue System for Facts-Based Sentence Generation, *CoRR*, Vol. abs/1902.01529 (2019).
- [21] Tanaka, S., Yoshino, K., Sudoh, K. and Nakamura, S.: Conversational Response Re-ranking Based on Event Causality and Role Factored Tensor Event Embedding, *CoRR*, Vol. abs/1906.09795 (2019).
- [22] Tao, C., Mou, L., Zhao, D. and Yan, R.: RUBER: An Unsupervised Method for Automatic Evaluation of Open-Domain Dialog Systems, *AAAI 2018*, pp. 722–729 (2018).
- [23] Vinyals, O. and Le, Q.: A Neural Conversational Model, *ICML, Deep Learning Workshop* (2015).
- [24] Vougiouklis, P., Hare, J. S. and Simperl, E.: A Neural Network Approach for Knowledge-Driven Response Generation, *COLING 2016, 26th International Conference on Computational Linguistics, Proceedings of the Conference: Technical Papers, December 11-16, 2016, Osaka, Japan*, pp. 3370–3380 (2016).
- [25] Yavuz, S., Rastogi, A., Chao, G. and Hakkani-Tür, D.: DeepCopy: Grounded Response Generation with Hierarchical Pointer Networks, *CoRR*, Vol. abs/1908.10731 (online), available from <http://arxiv.org/abs/1908.10731> (2019).
- [26] Ye, Z., Cai, R., Liao, Z., Hao, Z. and Li, J.: Generating Natural Answers on Knowledge Bases and Text by Sequence-to-Sequence Learning, *Artificial Neural Networks and Machine Learning - ICANN 2018 - 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4-7, 2018, Proceedings, Part I*, pp. 447–455 (2018).
- [27] Yoshino, K., Hori, C., Perez, J., D’Haro, L. F., Polymenakos, L., Gunasekara, C., Lasecki, W. S., Kummerfeld, J., Galley, M., Brockett, C., Gao, J., Dolan, B., Gao, S., Marks, T. K., Parikh, D. and Batra, D.: The 7th dialog system technology challenge, *arXiv preprint* (2018).
- [28] Zhang, S., Dinan, E., Urbanek, J., Szlam, A., Kiela, D. and Weston, J.: Personalizing Dialogue Agents: I have a dog, do you have pets too?, *ACL 2018*, pp. 2204–2213 (2018).