

# 因果関係に基づくデータサンプリングを利用した雑談応答学習

佐藤 祥多<sup>†</sup>乾 健太郎<sup>† §</sup>
<sup>†</sup> 東北大学    <sup>§</sup> 理化学研究所 革新知能統合研究センター

{shota-s, inui}@ecei.tohoku.ac.jp

## 1 はじめに

非タスク指向型の対話応答文生成研究において、どのような応答文を生成すれば対話システムの利用者が満足するのかが様々考えられるが、その指標を考える上で徳久らの研究 [14] は重要な知見であると考えられる。徳久らは雑談における人間同士の対話について分析を行い、相手の発話に対し質問を行う問い返しと相手の発話に付加情報つけた応答を行う間接応答が雑談の継続性に寄与することを示した。加えて、問い返しと間接応答に対し先行発話との修辞関係を分析したところ、因果関係が多く出現することを示した。この知見を利用し下岡ら [12] は、Web 上で集めた事象間の因果関係知識をシステムの応答とする非タスク指向型の対話システムを開発した。例えば、人間の“風邪を引いたんだ”という発話に対し、その発話に最も関連した“風邪を引いた → 病院に行く”という事象間の因果関係知識を用いて“じゃあ病院に行くのね?”とテンプレートを利用した応答を生成するようなものである。

ところで、近年では非タスク指向型の対話研究において Sequence-to-sequence モデル [9] と呼ばれるニューラルネットワークモデル (seq2seq) が、応答文生成研究の基礎として広く利用されている [10, 8, 5, 7]。seq2seq は End-to-end で発話と応答の対応を学習できるため、学習が容易で規模をスケールさせやすく、人間にとって自然な応答文を生成することができる。

本研究では徳久らの研究と seq2seq を組み合わせることで、人間にとって自然な文と感じられる因果関係に基づいた応答を生成する手法を提案する。加えて、因果関係という外部知識を seq2seq に盛り込む新たな方法として、訓練データのサンプリングによる方法を試みる。先行研究では seq2seq に外部知識を入れる方法として文献 [11] のように、seq2seq のモデルネットワークと目的関数の改良を行うことが殆どである。しかし、外部知識に基づいた訓練データを用意できれば seq2seq は自動で外部知識の対応関係を学習し、それに基づいた自然な応答ができると考える。

そこで本研究では、因果関係の知識を訓練データをサンプリングするためのフィルタとして利用することで、大規模な発話対 (発話と応答の対) 集合から因果関係に基づいた発話対を大量に抽出し、それらを訓練データとして seq2seq に学習させた。そして訓練データサンプリングにより因果関係に基づいた応答が可能であることを定量的・定性的に評価した。その結果、提案手法

表 1: 因果関係知識の事例

前件	学校に行く	仕事が出る	投薬を続ける	デパートに行く
後件	友人に会う	帰りが遅い	病気が治る	親戚に会う

によって因果関係に基づく応答生成が可能であることを示すと同時に、通常の訓練データで学習した seq2seq よりも対話の継続性に優れた応答を生成できることを示した。

## 2 因果関係に基づく訓練データサンプリング

### 2.1 基本的なアプローチ

本研究では大規模な発話対集合に対し、因果関係知識をフィルタとして利用することで因果関係に基づいた訓練データをサンプリングする。図 1 に提案手法の概観を示す。具体的には、因果関係知識集合内の前件と後件に含まれるストップワード<sup>1</sup>を除いた内容語が発話対にそれぞれ出現した場合は因果関係に基づいた発話対であると判定するフィルタを作成し、それを大規模発話対データに適応する。例えば、図 1 の「発話: 最近うがいする習慣が身についてきた!」、「応答: 何喉が痛い?」という発話対ではそれぞれ文中に、“うがい”、“喉、痛い”という因果関係が含まれているためフィルタを通過させる。なお本研究では因果関係の前件・後件と発話対の発話・応答の対応関係はとらない。なぜならば人間の対話において、原因から結果を推測する応答を行うこともあれば、結果から原因を推測する応答を行うことがあるためである。また本研究では発話対中の因果関係の特定に、高速に探索可能なトライ木を利用した。

### 2.2 因果関係知識の収集

本研究では、下岡ら同様に事象間の因果関係を因果関係知識とする。事象間の因果関係とは、“風邪を引く” → “病院に行く” のような因果関係の認められる文と文の対である。また非タスク指向型の対話における因果関係の定義は様々考えられるが、本研究では佐藤らが定義した因果関係 [13] を利用する。佐藤らの研究で因果関係の種類には“習慣”や“目的”といった様々な関係が定義されており、この定義を利用してクラウドソーシングにて収集した。なお本研究では因果関係知識の収集はトヨタ自動車株式会社に行っていただき、その成果物を利用した。加えて本研究では因果関係の種類による違いを利用しないため、因果関係の種類を

<sup>1</sup>フィルタの条件を緩くするために、“父”、“母”などの人称代名詞や、“する”、“ある”といった因果に関係のない動詞など計 50 種を設定した。

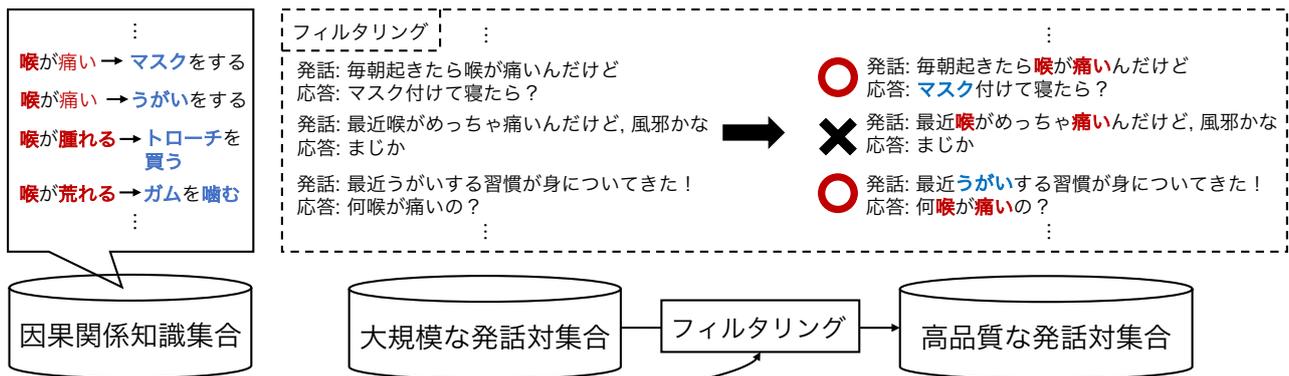


図 1: 因果関係に基づく訓練データサンプリングの概観

区別せずまとめて因果関係知識集合とした。提供していただいた因果関係知識の事例を表 1 に示す。また、因果関係知識の数は 49,815 個であった。

### 3 実験

実験では、因果関係に基づいた訓練データサンプリングの効果について以下の観点で検証する。

- (1). 訓練データサンプリングが seq2seq に対しどのように応答生成に影響するのか (データサンプリングの妥当性)
- (2). 徳久らの知見と同じく対話の継続性に優れた応答を提案手法によって生成できるか (提案手法の妥当性)

(1) と (2) について検証するために、本研究では提案手法で作成した訓練データ (提案訓練データ) と、ベースライン用の訓練データ (ベースライン訓練データ) でそれぞれ同パラメータの seq2seq モデルを学習し比較する。

#### 3.1 データセット

実際に学習・比較評価に使用したデータの作成方法概要を図 2 に示す。

**大規模発話対データの収集:** 本研究では Twitter<sup>2</sup> で reply (応答文) が付いている tweet (発話文) をクロールして大規模発話対データを作成した。Twitter からクロールした tweet には、URL や hashtag が文中に含まれるもの、文中の殆どが絵文字や顔文字であるもの、tweet の文長が短い・長い・ため雑談に見えないものなどがある。本研究では、以下のルールを定めて tweet 集合をクリーニングした。クリーニング後の発話対は約 7 億 1,741 万対になった。

- 日本語が含まれない発話対は削除。
- 言外情報が含まれるため、URL や hashtag が含まれる発話対は削除。
- 数字表現の含まれる発話対は削除。
- 5 文字未満、31 文字以上の文を含む発話対の削除。
- 繰り返し文字の正規化。例えば、“wwwwwwww”、“wwwww” → “www” など。
- 記号や絵文字・顔文字の除去。

<sup>2</sup><https://twitter.com/>

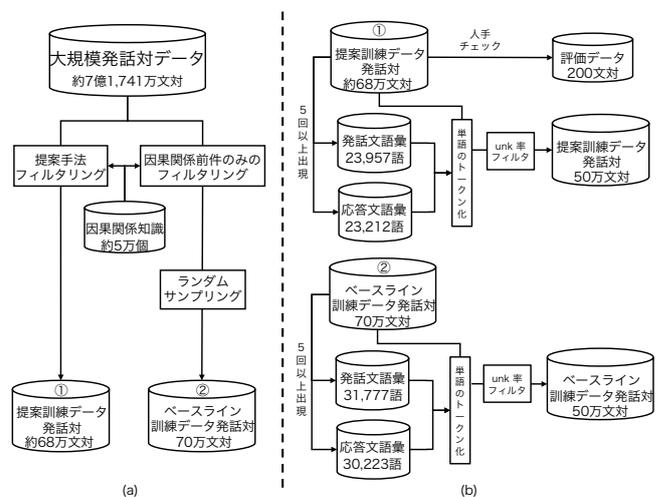


図 2: (a) データセット作成概要と (b) seq2seq に学習させるための前処理

**ベースライン訓練データ作成:** 比較対象であるベースライン訓練データは、提案訓練データのトピック分布と同じになるように、因果関係知識の前件だけが発話対に含まれるものを大規模発話対集合から抽出して作成した。

**評価用データの作成:** 評価用データは、提案訓練データには含まれないが、提案手法を使って大規模発話対集合から取得した発話対の一部に対し、人手によるクリーニングを行った発話対とした<sup>3</sup>。クリーニングを行う理由は、大規模発話対集合から取得した発話対の中には、言外知識がなければ応答出来ないようなものが存在するためである。

#### 3.2 モデル設定

比較実験で利用する seq2seq の設定は以下の通りである。単語ベクトル・隠れ層を 1024 次元、LSTM[3] を 2 層、Dropout 確率を 0.2、GradientClipping を 5.0 とした。最適化には Adam[4] を利用した。また、訓練データ中の発話文と応答文それぞれに対し単語の出現頻度を計算し、5 回以上出現した単語を seq2seq の語彙とした。語彙に含まれなかった訓練データ中の単語は “unk”

<sup>3</sup>実際に利用するのは発話文の部分だけである

表 2: 提案訓練データで学習した seq2seq とベースライン訓練データで学習した seq2seq の応答事例

入力発話文	提案訓練データ	ベースライン訓練データ
痒いーッ！しばらく、エビカニ食べませんってか、食べれません	えーッ！カニアレルギー！ (カニを食べる → アレルギーが出る)	でしょーやー (知識なし)
明日も頑張ります、応援宜しくお願ひ致します！	あーくん今週は試合も見ますね (試合を見る → 息子を応援, 試合を見る → 妹を応援)	よろしくです！ 体調に気を付けてください！ (知識なし)
風邪引いた	大丈夫ですか？お薬を飲んで無理をなさらずに早く寝てくださいね (兄が風邪を引く → 薬を飲む 夫が風邪を引く → 薬を飲む など)	俺のうつったのね (風邪を引く → 家族にうつる 家族が風邪を引く → 私がうつる)
はい寝ます薬飲んで寝ますノ眠くなってきた zzzZZ	おやすみなさい ゆっくりおやすみください。 (知識なし)	その方がよい！おやすみ！ (知識なし)
久々に体調崩した吐きそう	看病しに行かなくや (母が体調を崩す → 看病をする)	お大事にです！ (知識なし)

表 3: 提案訓練データで学習した seq2seq とベースライン訓練データで学習した seq2seq の応答破綻事例

入力発話文	提案訓練データ	ベースライン訓練データ
マスク久々にしたー	風邪引いてるの？ (家族が風邪を引く → マスクをする など) 1. 破綻なし	髪切った？ (知識なし) 2. 文脈不適合
服を買うために貰ったお金でゲーム買う話嫌い	一緒に遊ぼうな！ (ゲームを買う → 兄と遊ぶ など) 2. 文脈不適合	え、買わないの？ (知識なし)
もういろんな意味で頭痛いよ	かき氷食べたい (かき氷を食べる → 頭痛い) 2. 文脈不適合	次のイベント行ってくる (知識なし) 2. 文脈不適合

表 4: 応答の破綻の判定結果

評価指標	提案訓練データ	ベースライン訓練データ
A. 破綻なし	129/200 0.65	116/200 0.58
B. 文脈不適合	62/200 0.31	64/200 0.32
C. 非文	1/200 0.01	11/200 0.06
D. 判定不能	8/200 0.04	9/200 0.05

という特殊トークンに変換した。なお，“unk”が高頻度で出現する発話対は学習の妨げになるとして訓練データから削除した。さらには、学習スピードを速くするために、単語ベクトルの初期値として大規模発話対データから word2vec[6] で学習したベクトルを利用した。最後に、応答文生成時のビームサーチ幅は 20 とした。

### 3.3 実験 1, データサンプリングの妥当性

訓練データサンプリングによる seq2seq への影響を以下の観点で検証する。

1. 因果関係に基づいた応答をどの程度生成できるのか。
2. 訓練データサンプリングによって、応答の破綻率はどのようになるのか。
3. seq2seq は因果関係に基づいた応答をどのように生成しているのか。

まず、提案訓練データで学習した seq2seq とベースライン訓練データで学習した seq2seq それぞれの評価データに対する応答事例を表 2 に示す。表 2 からは、ベースライン訓練データで学習した seq2seq モデルに比べ、提案訓練データで学習した seq2seq モデルがより因果関係に基づいた応答を行っていることがわかる。実際に因果関係に基づいた応答数を調べたところ、ベースライン訓練データの seq2seq では評価データ 200 個中 21 個因果関係に基づいた応答を行っているのに対し、提案訓練データの seq2seq では 200 個中 168 個因果関係に基づいた応答を行っていた。これは提案手法により、因

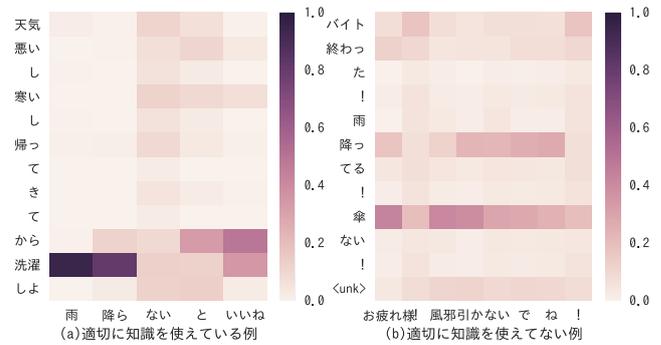


図 3: Alvarez-Melis らの手法による依存関係の可視化。縦軸が発話文で横軸が応答文である。なお (a) では、“雨が降る”→“洗濯する”が知識として使われている。(b) では“雨に降る”→“風邪を引く”が知識として使われているはずだが、“風邪を引く”という応答のための重みは“傘”に掛かっている。

果関係に基づいた応答を生成できていると解釈できる。

訓練データをサンプリングすることで因果関係に基づいた応答を生成できることを示せたが、破綻している応答が増えてしまっは意味がないので、次に応答の破綻率を検証する。本研究では、応答の破綻の判定にクラウドソーシングを利用した人手での評価を行った。具体的には、クラウドワーカー 10 人に対し、評価データの発話文と各モデルの応答文をそれぞれペアとして見せ、表 4 の選択肢 A～C から 1 つ直感で判定してもらった。最終的な応答の破綻の判定は、クラウドワーカー 10 人による多数決で行った。なお、多数決で結果が 1 つに決まらない場合は、「D. 判定不能」という判定した。

各モデルの応答破綻事例を表 3 に、破綻評価結果を表 4 に示す。表 4 からは、両訓練データともに破綻率は大きな違いがないことがわかる。ここから、提案手法は応答の破綻率の悪化に影響しないことがわかる。

表 5: 応答の対話継続性の比較

A. どちらの応答も返答しやすい	12/81
B. 提案訓練データの方が返答しやすい	44/81
C. ベースライン訓練データの方が返答しやすい	9/81
D. どちらの応答も返答しにくい	2/81
E. 判定不能	14/81

提案訓練データで学習した seq2seq の応答が破綻した原因を調査したところ、主たる原因として表 3 の下 2 つの例のように、文脈に関連した因果関係知識を利用できなかったことが確認できた。破綻の更なる調査は今後の課題とする。

最後に、提案訓練データで学習した seq2seq が因果関係に基づいた応答をどのように生成しているのかを確認するために、Alvarez-Melis ら [1] の手法を用いて提案訓練データで作成した seq2seq を分析した。Alvarez-Melis らは encoder-decoder モデルへの入力文の一部を VAE[2] を利用して破綻しない形に変更し、その変更によって encoder-decoder モデルの応答がどのように変化するかを分析することで、発話と応答の依存関係を可視化する手法を提案した。この手法による可視化の事例を図 3 に示す。図 3 からは、因果関係に応答できているものもあれば、できていないものもあることがわかる。実際に、実験 1 で因果関係に基づいて応答を生成していると判定された 168 個の応答について、表 3 の 2 つのパターンに該当する数をそれぞれ調べたところ、(a) のように明確に因果関係に重みが掛かっていた事例は 128 個存在することがわかり、40 個は (b) のように、因果関係に重みが掛かっていなかったことがわかった。つまり因果関係に基づく訓練データサンプリングでは、ある程度まで因果関係の対応を seq2seq で学習できると考える。

以上の実験をまとめると、提案手法によって因果関係に基づいた応答を破綻に影響なく生成できることがわかった。しかし訓練データサンプリングだけでは限界があり、seq2seq に因果関係を陽に盛り込むための改良が必要であることもわかった。

### 3.4 実験 2, 提案手法の妥当性

提案した因果関係に基づいた訓練データサンプリングは徳久らの知見を再現できているか確認する。再現出来ているならば、ベースライン訓練データと比較して提案訓練データの方が、より対話の継続性に優れた応答をしているはずである。

そこで本研究では、クラウドソーシングを利用した人手での評価を行った。具体的にはクラウドワーカー 10 人に対し、実験 1 で提案訓練データ、ベースライン訓練データ共に破綻なしと評価されたトリプル(発話, 提案訓練データの応答, ベースライン訓練データの応答)を見せ、対話の継続性について表 5 のように A~D の選択肢から 1 つ選択して判定してもらった。なお対話の継続性の判定は、「どちらの応答が簡単に返答を思いつくか」「どちらの応答が人間の発話をより親身に聞いているか」という指標を提示し、これに即して直感で評価を行ってもらった。実験 1 同様に、最終的な判定は多数決で行い、1 つに定まらない場合は、「E. 判定不能」と

いう判定にした。

表 5 に判定結果を示す。表 5 からは、ベースライン訓練データで学習した seq2seq よりも提案訓練データで学習した seq2seq の方がより対話の継続性に優れた応答を生成できていることがわかる。表 2 の一番下の“看病しに行かなきゃ”という応答は、クラウドワーカーによって対話の継続性に優れていると判定された事例だが、この事例を見てもわかるように因果関係を用いて徳久らの言うところの間接応答を生成できている。

## 4 おわりに

本研究では、訓練データサンプリングという外部知識を seq2seq に盛り込む新たな方法で、因果関係に基づく雑談応答を行う手法を提案した。実験により提案手法は、因果関係に基づく応答ができると対話の継続性に優れた応答が生成できることを示した。

しかし本研究により訓練データサンプリングだけでは限界があることがわかったため、今後の課題として因果関係を盛り込んだモデルの開発、そして提案手法とモデルとの比較調査・組み合わせによる影響調査を行っていきたい。

## 謝辞

本研究で使用した因果関係知識をご提供いただいたトヨタ自動車株式会社に感謝いたします。本研究は JSPS 科研費 15H01702 の助成を受けました。

## 参考文献

- [1] David Alvarez-Melis and Tommi S. Jaakkola. A causal framework for explaining the predictions of black-box sequence-to-sequence models. In *EMNLP*, pp. 412–421, 2017.
- [2] Samuel R. Bowman, Luke Vilnis, Oriol Vinyals, Andrew Dai, Rafal Jozefowicz, and Samy Bengio. Generating sentences from a continuous space. In *CoNLL*, pp. 10–21, 2016.
- [3] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
- [4] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. In *ICLR*, 2015.
- [5] Jiwei Li, Michel Galley, Chris Brockett, Jianfeng Gao, and Bill Dolan. A diversity-promoting objective function for neural conversation models. In *NAACL-HLT*, pp. 110–119, 2016.
- [6] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean. Distributed representations of words and phrases and their compositionality. In *NIPS*, pp. 3111–3119, 2013.
- [7] Yuanlong Shao, Stephan Gouws, Denny Britz, Anna Goldie, Brian Strope, and Ray Kurzweil. Generating high-quality and informative conversation responses with sequence-to-sequence models. In *EMNLP*, pp. 2210–2219, 2017.
- [8] Alessandro Sordani, Michel Galley, Michael Auli, Chris Brockett, Yangfeng Ji, Margaret Mitchell, Jian-Yun Nie, Jianfeng Gao, and Bill Dolan. A neural network approach to context-sensitive generation of conversational responses. In *NAACL-HLT*, pp. 196–205, 2015.
- [9] Ilya Sutskever, Oriol Vinyals, and Quoc V Le. Sequence to sequence learning with neural networks. In *NIPS*, pp. 3104–3112, 2014.
- [10] Oriol Vinyals and Quoc V. Le. A neural conversational model. *CoRR*, Vol. abs/1506.05869, , 2015.
- [11] Tsung-Hsien Wen, Milica Gasic, Nikola Mrksic, Pei-hao Su, David Vandyke, and Steve J. Young. Semantically conditioned lstm-based natural language generation for spoken dialogue systems. In *EMNLP*, pp. 1711–1721, 2015.
- [12] 下岡和也, 徳久良子, 寺島立太. 雑談対話システム構築に向けた事態間の因果関係知識を用いた応答生成. 言語・音声理解と対話処理研究会, Vol. 50, pp. 77–82, 2007.
- [13] 佐藤祥多, 井之上直也, 乾健太郎, 樋口佐和, 渡部生聖. 因果関係に基づく雑談対話発話生成の試み. 人工知能学会全国大会, 2016.
- [14] 徳久良子, 寺島立太. 非課題遂行対話における発話の特徴とその分析. 人工知能学会論文誌, Vol. 22, No. 4, pp. 425–435, 2007.