

修士論文

encoder-decoder モデルによる
対話応答生成の特性分析

佐藤 祥多

2018年 2月 13日

東北大学 大学院
情報科学研究科 システム情報科学専攻

本論文は東北大学 大学院情報科学研究科 システム情報科学専攻に
修士(工学) 授与の要件として提出した修士論文である。

佐藤 祥多

審査委員：

乾 健太郎 教授 (主指導教員)

田中 和之 教授

周 暁 教授

岡崎 直観 教授 (副指導教員・東京工業大学)

encoder-decoder モデルによる 対話応答生成の特性分析*

佐藤 祥多

内容梗概

人間同士の対話において、因果関係に基づく発話応答が対話の継続性に寄与するという研究がある。本研究ではこの知見に基づき、Seq2seq モデルを利用して因果関係に基づいた雑談応答を行う手法を提案する。先行研究では、因果関係のような外部知識をモデルに組み込む方法はモデルネットワークと目的関数の改良が殆どである。しかし本研究では、外部知識をモデルに組み込む新たな手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。実験では、訓練データのサンプリングがモデルの応答特性にどのように影響するかを分析し、さらには、提案手法が因果関係に基づいた応答を生成できることと、対話の継続性に優れた応答を生成できることを示した。

キーワード

ニューラルネットワーク, encoder-decoder モデル, 雑談対話応答生成, 因果関係, 応答分析

*東北大学 大学院情報科学研究科 システム情報科学専攻 修士論文, B6IM2022, 2018年2月13日.

目次

1	はじめに	1
2	背景	3
2.1	LSTM	3
2.2	Seq2seq	5
2.3	Alvarez-Melis らの手法	6
3	因果関係知識を利用した訓練データのサンプリング	9
3.1	基本的なアプローチ	9
3.2	発話対中の因果関係知識の特定	9
3.3	因果関係知識の収集	10
4	実験	11
4.1	データセット	11
4.2	モデル設定	12
4.3	実験 1, データサンプリングの妥当性	13
4.4	実験 2, 提案手法の妥当性	18
5	おわりに	22
	謝辞	23
	付録	27
A	VRAE 学習の詳細	27

目 次

1	リカレントニューラルネットワークの構造	3
2	LSTM の構造	4
3	seq2seq の概観	6
4	VRAE を使った時系列データ出力の解釈手法の概観	8
5	因果関係に基づいた訓練データサンプリング	10
6	データセット作成概要 (a) と seq2seq に学習させるための前処理 (b)	12
7	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 “薬を飲む” → “効果が出る” が知 識として使われているはずだが, “効果” という応答のための重み は “平気” と “すぐ” に掛かっている.	18
8	学習中のカルバック・ライブラー情報量の様子	28

表 目 次

1	因果関係知識の事例	10
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	14
3	応答の破綻の判定結果	15
4	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	16
5	応答の対話の継続性の比較	19
6	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 の対話継続性判定の事例	21

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、どのように応答文を生成するかという応答指標は様々考えられるが、応答指標を考える上で徳久らの研究 [1] 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、人間の発話に対する質問を行う問い返しと人間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辭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 [2] 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 framework [3] と呼ばれるニューラルネットモデル (seq2seq) が、応答文生成研究の基礎として広く利用されている [4, 5, 6, 7, 8]。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、因果関係に基づいた応答を人間にとって自然な文で行う手法を提案する。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 [9, 10] 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、訓練データをサンプリングするために、因果関係の知識をフィルタとして利用することで、大規模な発話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。そして訓練データのサンプリングにより因果関係に基づいた応答ができるのかを定量的・定性的に評価した。その結果、提案手法による訓練データサンプリングによって

因果関係に基づく応答生成が可能であることを示すとともに、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。

本論文の構成は以下の通りである。まず 2 章において、本研究で利用する先行研究について概説する。次に 3 章において、本研究の提案手法である因果関係の知識を利用した訓練データのサンプリング手法について述べる。4 章では、提案手法が因果関係に基づいた応答を生成できているか、対話の継続性に優れた応答を生成できるかについて定量的・定性的に検証する。最後に 5 章にて、本研究のまとめを述べる。

2 背景

本章では本研究で利用した先行研究について概説する. まず, Long short-term memory (LSTM) [11] について概説する. 次に本研究で利用するフレームワークである seq2seq[3] について概説する. 最後に seq2seq の応答特性を分析するために利用した Alvarez-Melis ら [12] の手法について概説する.

2.1 LSTM

Long short-term memory (LSTM) とはリカレントニューラルネットワーク (RNN) の一種である. リカレントニューラルワークとはニューラルネットワークの一種で図1のような構造を持ち, 時系列データを扱う事ができる.




図 1: リカレントニューラルネットワークの構造

長さ N の時系列データ $X = \{x_1, x_2, \dots, x_N\}$ (例えば文字列や単語列, 数字列など) のベクトルである $E = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x}_t \in \mathbb{R}^{d_1}$ に対し, 隠れ層 \mathbf{h}_t を以下の式で求める.

$$\mathbf{h}_t = f(\mathbf{W}\mathbf{x}_t + \mathbf{U}\mathbf{h}_{t-1} + \mathbf{b}_1) \quad (1)$$

また学習や推論のための各時系列の出力 \mathbf{y}_t は以下の式で求める.

$$\mathbf{y}_t = g(\mathbf{V}\mathbf{h}_t + \mathbf{b}_2) \quad (2)$$

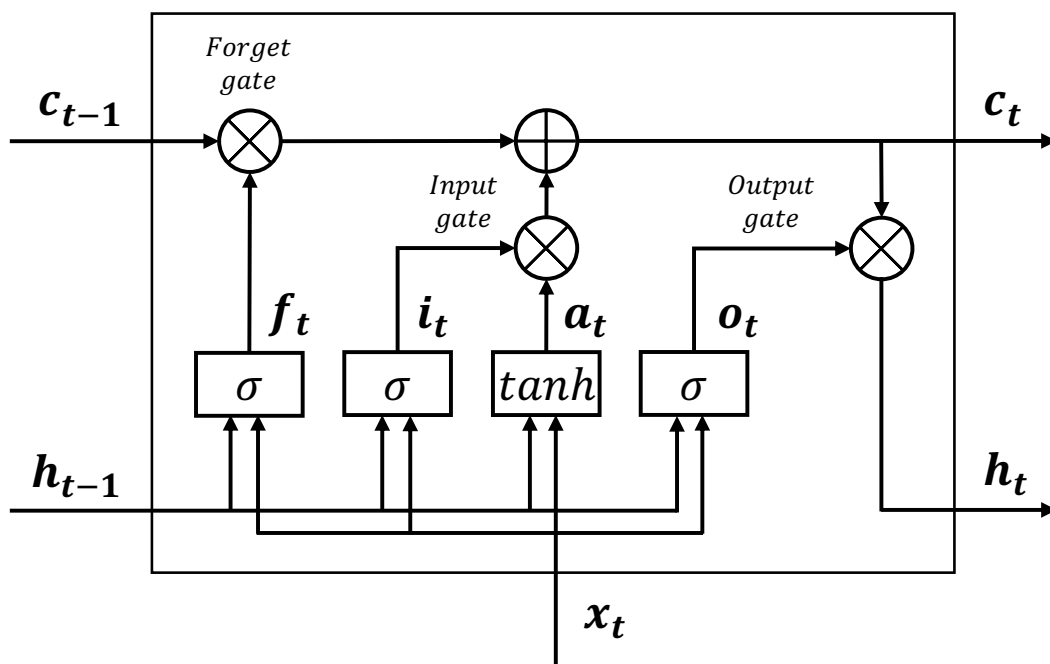


図 2: LSTM の構造

ただし $W \in \mathbb{R}^{d_2 \times d_1}$, $U \in \mathbb{R}^{d_2 \times d_2}$, $V \in \mathbb{R}^{d_3 \times d_2}$, $b_1 \in \mathbb{R}^{d_2}$, $b_2 \in \mathbb{R}^{d_3}$ であり, f と g は活性化関数と呼ばれる非線形関数である.

時系列データを扱うことができるリカレントニューラルネットワークは, 時系列データが長くなるとバックプロパゲーション法によって誤差をニューラルネットワークに伝搬させる際に, 勾配が爆発・消失してしまうという問題 [13, 11] があった. その解決策の 1 つが LSTM である.

LSTM は図 2 のような構造を持つリカレントニューラルネットワークである. Input gate, Output gate, Forget gate と呼ばれる入出力量を調整するゲートと時系列情報を保存するメモリセル c_t を利用することで時系列情報の長期保存が可能になる. 入力 x_t , 1step 前の隠れ層 h_{t-1} とメモリセル c_{t-1} から以下の式により現時刻の隠れ層 h_t を求める.

$$\mathbf{a}_t = \tanh(\mathbf{W}_a \mathbf{x}_t + \mathbf{U}_a \mathbf{h}_{t-1} + \mathbf{b}_a) \quad (3)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \mathbf{x}_t + \mathbf{U}_i \mathbf{h}_{t-1} + \mathbf{b}_i) \quad (4)$$

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{U}_f \mathbf{h}_{t-1} + \mathbf{b}_f) \quad (5)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{U}_o \mathbf{h}_{t-1} + \mathbf{b}_o) \quad (6)$$

$$\mathbf{c}_t = \mathbf{f}_t \odot \mathbf{c}_{t-1} + \mathbf{i}_t \odot \mathbf{a}_t \quad (7)$$

$$\mathbf{h}_t = \mathbf{o}_t \odot \mathbf{c}_t \quad (8)$$

ただし $\mathbf{W}_a, \mathbf{W}_i, \mathbf{W}_f, \mathbf{W}_o \in \mathbb{R}^{d_2 \times d_1}$, $\mathbf{U}_a, \mathbf{U}_i, \mathbf{U}_f, \mathbf{U}_o \in \mathbb{R}^{d_2 \times d_2}$, $\mathbf{b}_a, \mathbf{b}_i, \mathbf{b}_f, \mathbf{b}_o \in \mathbb{R}^{d_2}$ であり, σ はシグモイド関数である.

2.2 Seq2seq

Sequence-to-sequence framework[3] (seq2seq) は, encoder-decoder モデルと呼ばれるニューラルネットワークの一種で, 入力された時系列データからそれに対応する時系列データを出力するモデルである. seq2seq は図3のようにリカレントニューラルネットワークを2つ利用する. encoder と呼ばれるリカレントニューラルネットワークに入力時系列データを先頭から1つ1つ入力し, 最後の隠れ層 \mathbf{h}_N を求める. この \mathbf{h}_N を decoder と呼ばれるもう1つのリカレントニューラルネットワークの隠れ層の初期値とし, ある時系列の単語から次の単語を推論することを繰り返すことで時系列データを出力する. 例えば図3にあるように, “すごく” “良い” “天気” という時系列データを入力した後の隠れ層 \mathbf{h}_3 を利用して, ”eos” という単語列の区切りを表す特殊トークンから” いいね “を,” いいね “から” 散歩 “をと単語を推論していくことで,” すごく良い天気 “という文に対応する” いいね 散歩行く? “という時系列データを出力する.

学習は以下の式で表される入力時系列データ $X = \{x_1, x_2, \dots, x_N\}$ に対する出力時系列データ $Y = \{y_1, y_2, \dots, y_{N'}\}$ の尤度を最大化する.

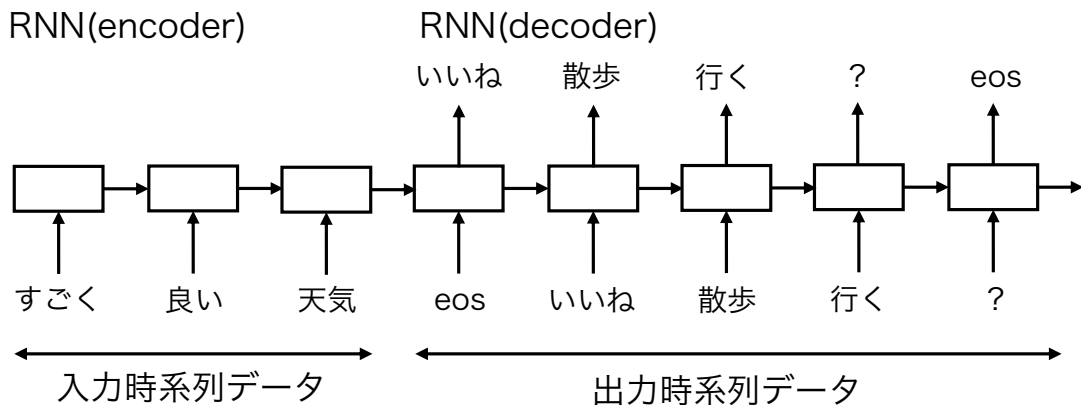


図 3: seq2seq の概観

$$p(y_1, y_2, \dots, y_{N'} | x_1, x_2, \dots, x_N) = \prod_{t=1}^{N'} p(y_t | x_1, x_2, \dots, x_N, y_1, y_2, \dots, y_{t-1}) \quad (9)$$

なお, $p(y_t | x_1, x_2, \dots, x_N, y_1, y_2, \dots, y_{t-1})$ は softmax 関数で求めた seq2seq が扱う語彙の確率分布である.

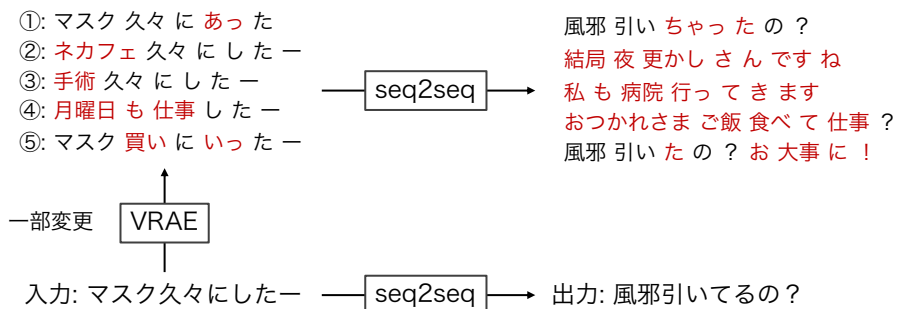
推論時には, encoder を用いて計算した隠れ層 h_N^1 を利用し, “eos” を decoder の先頭に入れることで, 出力時系列データ先頭の語彙の確率分布を推論する. decoder に推論した単語を入力し続け, (9) 式を最大化する単語列を推論結果とする. なお, 探索はすべての語彙に対し行うと時間が膨大にかかるため, ビームサーチで行う.

2.3 Alvarez-Melis らの手法

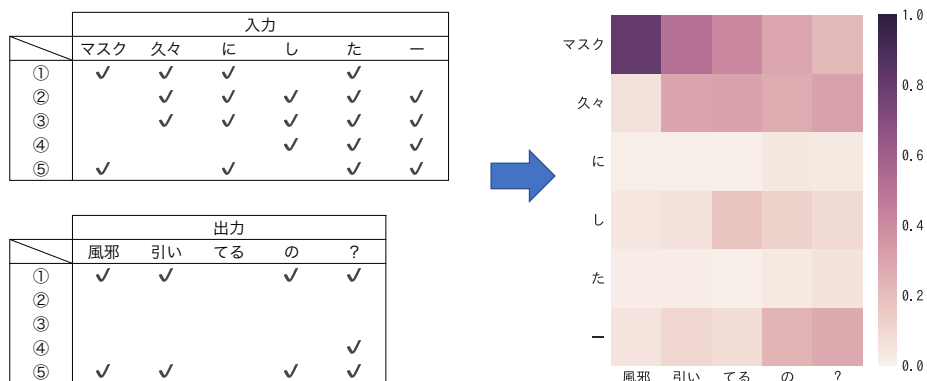
seq2seq のようなニューラルネットワークは, 入力から出力を説明できない Black-Box 化されたモデルである. そのため, ニューラルネットワークを用いた研究では, その入力に対しなぜその出力が生成されたのか分析するのが困難である. Alvarez-Melis ら [12] は, encoder-decoder モデルに対し, 入力に対する出力の解釈を行う手法の 1 つを提案した. 彼らは Variational Autoencoder (VAE) [14] を拡張した

¹LSTM を利用する場合は c_N も必要

Variational Recurrent Autoencoder (VRAE) [15, 16] を利用して, 入力時系列データを破綻しない形で一部変更し, その変更による出力の変化を分析することで, 入力と出力の依存関係を可視化した. VRAE は入力された時系列データと同じ時系列データを出力するように学習することで, 時系列データの潜在的な意味空間を学習することができる. そのため学習済みの VRAE を利用し, 意味空間に写像された入力された時系列データの意味を空間上で少しずつらすことで, 破綻せずに入力と似た時系列データを生成できる. 図 4 に Alvarez-Melis らの手法の概観を示す.



(a) step1: VRAE を利用して入力時系列データの一部を変更した疑似入力の単語列を seq2seq に入力し、疑似出力の単語列を得る。疑似入力と疑似出力にある赤くならなかった単語は、元の入力と出力それぞれに対し異なる単語である。



(b) step2: 分析したい入力と出力に含まれる単語が、VRAE を使って生成された疑似入力とその疑似出力に出現しているかを求める。その後、疑似入力の入力単語の含有分布から疑似出力の出力単語の含有分布を予測するベイズロジスティック回帰モデルを学習する。そのモデルの重みベクトルの分布が出力に含まれる単語を予測するための重要度分布になる。その分布をヒートマップで可視化する。

図 4: VRAE を使った時系列データ出力の解釈手法の概観

3 因果関係知識を利用した訓練データのサンプリング

3.1 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5に提案手法の概観を示す。具体的には発話対に対して、因果関係知識集合内で前件と後件に含まれるストップワード²を除いた内容語³が発話文と応答文にそれぞれ出現した場合のみ因果関係に基づいているとするフィルタを作成し、大規模発話対データに適用する。例えば、図5の「発話: 最近うがいする習慣が身についてきた!」, 「応答: 何喉が痛いの?」という発話対ではそれぞれ文中に, “うがい”, “喉, 痛い” 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。

3.2 発話対中の因果関係知識の特定

発話対中の因果関係の特定方法は様々考えられるが, 本研究では大規模発話対集合に対し高速に特定を行うために, トライ木を利用して因果関係の特定を行う。具体的には, 因果関係知識の前件の内容語をノードとしたトライ木を作成し, 対応する後件を木の葉に紐付けする。この際, 因果関係知識の正規化のため, 前件の内容語についてそれぞれ単語によるソートを行う。なお, 単語の品詞の特定には, 形態素解析器 MeCab⁴⁵を利用する。実際の特定では, 発話文と応答文の内容語に対してトライ木の作成と同様に正規化を行い, その各単語列を利用してトライ木を探索する。発話対のどちらかが木の葉に到達した場合, 到達しなかった単語列に対し木の葉に紐付けられた後件の内容語が含まれるか線形探索を行う。

²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” といったフィルタに不要と考えられる動詞など計 50 種設定した。

³名詞, 動詞, 形容詞

⁴<http://taku910.github.io/mecab/>

⁵辞書は新語や固有表現に強い Neologd[17] を利用した。

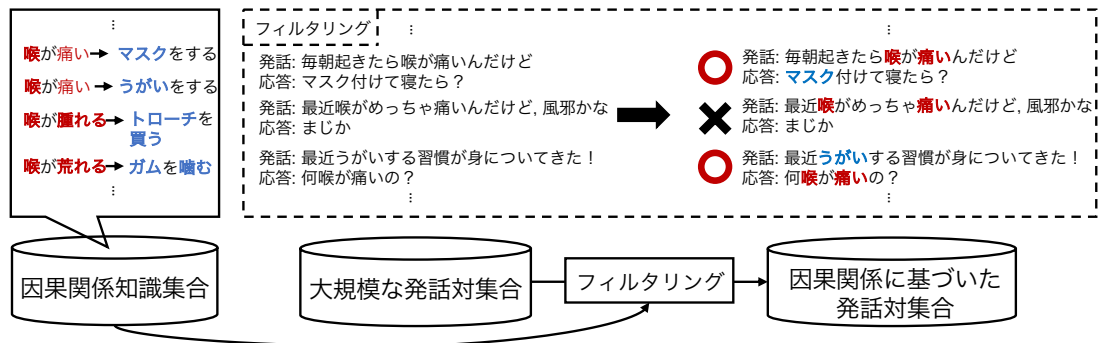


図 5: 因果関係に基づいた訓練データサンプリング

3.3 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 [18] 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。

表 1: 因果関係知識の事例

前件	学校に行く	仕事出来る	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

4 実験

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

- (1). 訓練データのサンプリングが seq2seq に対しどのように応答制御に影響するのか (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 モデルで学習し比較する。

4.1 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の概要を図6に示す。

大規模発話対データの収集: 本研究では Twitter⁶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・長い場合雑談に見えるものなどがある。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、“wwwwwww”, “wwwww” → “www” など。
- 記号や絵文字・顔文字の除去。

⁶<https://twitter.com/>

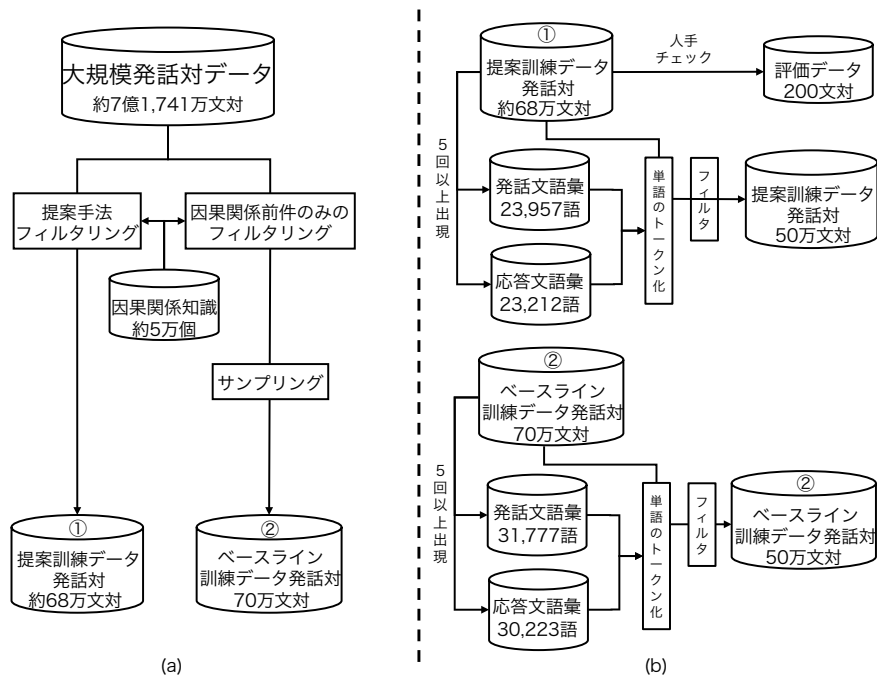


図 6: データセット作成概要 (a) と seq2seq に学習させるための前処理 (b)

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⁷。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。

4.2 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[11] を 2 層, Dropout 確率 [19] を 0.2, GradientClipping を

⁷実際に利用するのは発話文の部分だけである

5.0とした。最適化には Adam[20] 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” 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。また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[21] 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。

4.3 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、応答の破綻率はどうなるのか。
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、因果関係に基づいた応答を生成できていると解釈できる。

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	えっ！カニアレルギー！ (カニを食べる→アレルギーが出る)	でしよーやー (知識なし)
明日も頑張ります、 応援宜しくお願いします！	あくさ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)
はい寝ます薬飲んで寝ますノ	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)
眠くなってきた zzzZZ	病院行ったん？ (嫁が風邪を引く→病院に行く 息子が風邪を引く→病院に行くなど)	具合悪いの？ (知識なし)
とんでもない風邪を引いてしまった	焼肉食べよう (焼肉を食べる→焼肉をする)	焼き肉食べたいです！ (知識なし)
ごはんです！焼肉食べたい！	行きたいけど学校ない (学校に行く→息子が見せる)	しにが集まるといいと思うよ (知識なし)
教授に見せたら単位来る説	野菜食べよう (野菜を食べる→野菜を買う)	コンビニ行きましょー (コンビニに行く→自分が買う コンビニに行く→母に買う)
ヤオコーに野菜を大量に買わないと。 一緒に行こう。		

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、評価データと発話文と各モデルの応答文をそれぞれペアとして見せ、「1. 破綻なし/2. 文脈不一致/3. 非文」の 3 択から 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、「4. 判定不能」という判定した。各モデルの応答の破綻評価結果を表 3 に、破綻事例を表 4 に示す。表 3 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 3: 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
1. 破綻なし	129/200 0.65	116/200 0.58
2. 文脈不一致	62/200 0.31	64/200 0.32
3. 非文	1/200 0.01	11/200 0.06
4. 判定不能	8/200 0.04	9/200 0.05

表 4: 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
要約すると仕事は飽きた笑	ご飯 食べろ! (ご飯を食べる → 仕事を頑張る) 2. 文脈不一致	それな笑そーゆーこと言うの? 笑 (知識なし) 1. 破綻なし
マスク 欠々にしたー	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. 文脈不一致
とりあえず 洗い物 だけ すすませ ました! 掃除 やる 気 でない から お風呂 入る	夜中 掃除 は 大事 だ。 (母が風呂に入る → 掃除をする) 2. 文脈不一致	ほか てらー です (知識なし) 3. 非文
前は よく 風邪 も 引いて た よ、 イクシッ	体調 管理 大切 に! (風邪を引く → 管理をする) 1. 破綻なし	おも。まだ おおる ん? w (知識なし) 2. 文脈不一致
もう いろ んな 意味 で 頭痛 い よ	かき水 食べ たい (かき水を食べる → 頭が痛い) 2. 文脈不一致	次の イベント 行っ て くる (知識なし) 2. 文脈不一致
島根 帰っ て 日本 酒 の 飲み 比べ か お茶 した い ぞ	こんど 日本 酒 飲も う 酒 (知識なし) 1. 破綻なし	ウエルカム 姉 姉 (知識なし) 3. 非文

また表4からは、表4の2行目のように因果関係を利用し破綻せず応答できるものもあれば、1行目3行目のように、意図してない形で因果関係が利用され、破綻と判定された応答もあることがわかる。なぜ提案訓練データで学習した seq2seq が破綻した応答を出力したのかを検証したところ、seq2seq の性能限界を除き破綻の発生は次の2つのパターンに類型化できた。それは、1. 因果関係集合に該当する知識がなかったため、適切な因果関係を利用できず破綻した。2. 因果関係集合に該当する知識が存在し、訓練データに評価データに近い発話対を含んでいるにもかかわらず破綻した。の2点である。例えば、表4の1行目の“仕事”、“飽きる”には、因果関係知識集合内で関連した知識が存在しなかった。そのため、“仕事”という要素だけで因果関係に基づいた応答をして破綻した。また、表4の3行目の“風呂”、“入る”には、対応する因果関係が知識集合内で多く存在するにもかかわらず応答の破綻が起きた。これは、“風呂”、“入る”に対する因果関係知識が76種存在していたため、どの知識を利用すればいいか seq2seq が判断できなかったためだったと考える。まとめると応答の破綻の実験からは以下の3つのことがわかる。1. 提案手法によって応答の破綻に悪い影響は発生しない。2. 応答生成に因果関係知識集合にない知識が必要な場合は破綻しやすい。3. 因果関係知識は一对多の関係であることが多いが、多の部分が非常に多いと提案手法だけでは文脈に沿った応答を返すことができない。

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かを確認するために、2章で述べた Alvarez-Melis ら [12] 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。この手法による可視化の事例を図7に示す。図7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7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132個存在することがわかり、36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、ある程度までは因果関係の対応を seq2seq で学習できると考える。

以上の実験をまとめると、提案手法によるデータサンプリングによって因果関

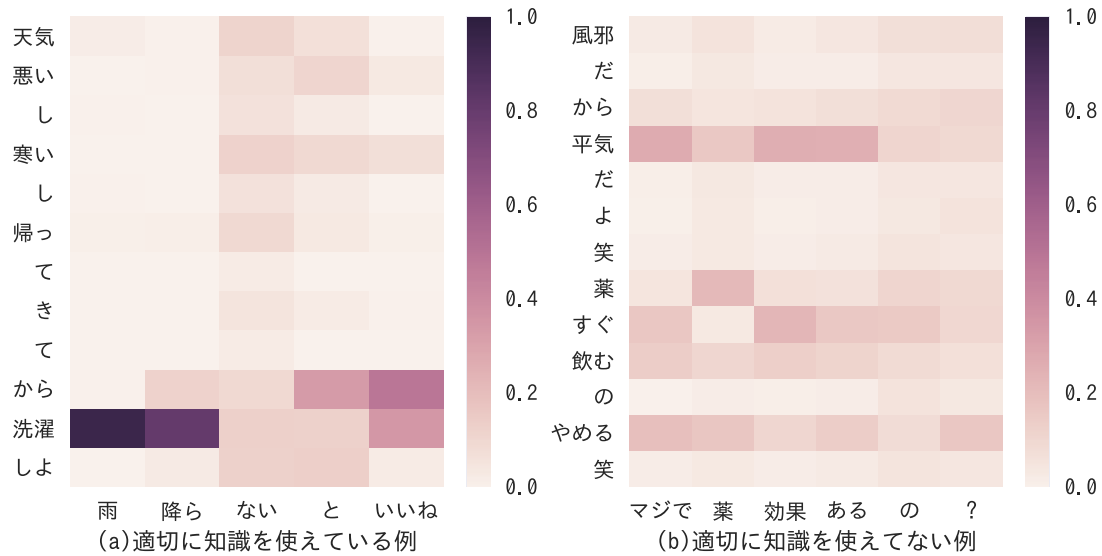


図 7: Alvarez-Melis らの手法による依存関係の可視化. 縦軸が発話文で横軸が応答文である. なお (a) では, “雨が降る” → “洗濯する” が知識として使われている. (b) では “薬を飲む” → “効果が出る” が知識として使われているはずだが, “効果” という応答のための重みは “平気” と “すぐ” に掛かっている.

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. しかし訓練データの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.

4.4 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「1. どちらの応答も返

表 5: 応答の対話の継続性の比較

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

答しやすい/2. 提案訓練データの方が返答しやすい/3. ベースライン訓練データの方が返答しやすい/4. どちらの応答も返答しにくい」の4択から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、「5. 判定不能」という判定にした。

表5に判定結果を、表6に判定事例を示す。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6の2行目の“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。また「3. ベースライン訓練データの方が返答を返しやすい」と評価された原因について分析すると、表6の3行目の事例にあるように、オウム返しを行った応答が原因であることがわかった⁸。これは、“ラーメンを食べる”という因果関係知識は大量にあったものの、それらの因果関係知識を利用して取得した訓練データの発話と応答のどちらともに“ラーメン”という単語含まれていることが多かったためである。例えば、“ラーメンを食べる”→“外出する”という因果関係知識に対応する提案訓練データの発話対には、「発話: ラーメンを食べるためだけに外出する事を決意しました」, 「応答: ラーメンを食べて圧倒的成長」というような事例が多くあった。そのため、発話に対する応答として“ラーメン”という繰り返しの単語が出現してしまったと考

⁸7/9の割合でオウム返しを行っていた

える。対策として Li ら [6] の発話文と自己相互情報量の最も多い応答文を生成する手法を本研究と組み合わせることが考えられる。

表 6: 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 の対話継続性判定の事例

判定結果	入力発話文	提案訓練データ	ベースライン訓練データ
1. どちらの応答も返答しやすい	頭痛いからロキソニン	薬飲んだの？ (頭が痛い→薬を飲む)	おい、大丈夫か？ (知識なし)
2. 提案訓練データの方が返答しやすい	久々に体調崩した吐きそう	看病しに行かなきや (母が体調を崩す→看病をする)	お大事にです！ (知識なし)
3. ベースライン訓練データの方が返答しやすい	ラーメン食べたい	わたしもラーメン食べたい (ラーメンを食べる →ラーメンが食べる)	弁慶行こうか (知識なし)
3. ベースライン訓練データの方が返答しやすい	ねえ、突然だけどさ。こんな時間にカレーを食べてもいいかな？	よし、カレー食べよう (カレーを食べる →カレーを食べる)	いいと思う！ 食べたいもんね！ (知識なし)
4. どちらの応答も返答しにくい	肉食いてえ	肉食うと病みます (肉が食う→肉を食う)	人肉は食いたくない (知識なし)
2. 提案訓練データの方が返答しやすい	みんなお昼ご飯何食べたの	生姜焼き定食食べた (息子がご飯を食べる→私が食べる)	お米いいですよね (知識なし)
3. ベースライン訓練データの方が返答しやすい	ご飯食べるか寝るかで迷うよね	ご飯食べて寝る (息子がご飯を食べる→私が食べる)	明日はお休み？ (知識なし)
2. 提案訓練データの方が返答しやすい	色々甘いもの食べたいぞ	コンビニ行ってきます！ (ものが食べる→コンビニに行く)	甘いもの食べたい (知識なし)

5 おわりに

本研究では、訓練データの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こと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の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の調査を行っていきたい。

謝辞

本研究を進めるにあたり、数多くのご協力・ご助言を皆様からいただきました。ここに心より感謝を申し上げます。

主指導教員である乾健太郎教授には、ご多忙の中、本研究の助言はもちろんのこと、研究の進め方や物事の考え方などの研究活動全般について温かく指導していただきました。また研究活動だけでなく様々な事に相談にのっていただき、自分の人生観の変わる研究生活を過ごすことができました。さらには本研究を進めるにあたり、根気強く親身に励ましていただきました。心より深謝を申し上げます。トヨタ自動車株式会社の渡部生聖氏、樋口佐和氏、堀達郎氏には、数多くのご助言やデータの提供など様々な支援をしていただきました。深く感謝を申し上げます。秘書である菅原真由美氏、井上幹子氏、技術補佐員である磯部順子氏には、本研究を進めるにあたり、数多くの支援や励ましをいただきました。また、研究員である松田耕史氏を始めとしたスタッフの方々にも多くの支援と励ましを頂きました。深く感謝を申し上げます。また、研究活動について指導していただいた井之上直也助教、稲田和明氏に深く感謝申し上げます。

最後になりましたが、学校生活におきまして関わっていただきましたすべての皆様と今まで支えてくれた家族に感謝いたします。

参考文献

- [1] 徳久良子, 寺嶋立太. 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.
- [2] 下岡和也, 徳久良子, 寺嶋立太. 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.
- [3] 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.
- [4] Oriol Vinyals and Quoc V. Le. A neural conversational model. *CoRR*, Vol. abs/1506.05869, , 2015.
- [5] Alessandro Sordoni, 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 2015, The 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Denver, Colorado, USA, May 31 - June 5, 2015*, pp. 196–205, 2015.
- [6] Jiwei Li, Michel Galley, Chris Brockett, Jianfeng Gao, and Bill Dolan. A diversity-promoting objective function for neural conversation models. In *NAACL HLT 2016, The 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, San Diego California, USA, June 12-17, 2016*, pp. 110–119, 2016.
- [7] Iulian Vlad Serban, Alessandro Sordoni, Ryan Lowe, Laurent Charlin, Joelle Pineau, Aaron C. Courville, and Yoshua Bengio. A hierarchical latent variable encoder-decoder model for generating dialogues. In *Proceedings of the*

Thirty-First AAAI Conference on Artificial Intelligence, February 4-9, 2017, San Francisco, California, USA., pp. 3295–3301, 2017.

- [8] 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 *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, EMNLP 2017, Copenhagen, Denmark, September 9-11, 2017*, pp. 2210–2219, 2017.
- [9] 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 *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, EMNLP 2015, Lisbon, Portugal, September 17-21, 2015*, pp. 1711–1721, 2015.
- [10] Mihail Eric, Lakshmi Krishnan, Francois Charette, and Christopher D. Manning. Key-value retrieval networks for task-oriented dialogue. In *Proceedings of the 18th Annual SIGdial Meeting on Discourse and Dialogue, Saarbrücken, Germany, August 15-17, 2017*, pp. 37–49, 2017.
- [11] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
- [12] David Alvarez-Melis and Tommi S. Jaakkola. A causal framework for explaining the predictions of black-box sequence-to-sequence models. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, EMNLP 2017, Copenhagen, Denmark, September 9-11, 2017*, pp. 412–421, 2017.
- [13] Yoshua Bengio, Patrice Simard, and Paolo Frasconi. Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, Vol. 5, No. 2, pp. 157–166, 1994.

- [14] Diederik P Kingma and Max Welling. Auto-encoding variational bayes. *ICLR*, 2014.
- [15] Otto Fabius, Joost R. van Amersfoort, and Diederik P. Kingma. Variational recurrent auto-encoders. *CoRR*, Vol. abs/1412.6581, , 2014.
- [16] Samuel R. Bowman, Luke Vilnis, Oriol Vinyals, Andrew M. Dai, Rafal Józefowicz, and Samy Bengio. Generating sentences from a continuous space. In *Proceedings of the 20th SIGNLL Conference on Computational Natural Language Learning, CoNLL 2016, Berlin, Germany, August 11-12, 2016*, pp. 10–21, 2016.
- [17] Sato Toshinori. Neologism dictionary based on the language resources on the web for mecab, 2015.
- [18] 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.
- [19] Nitish Srivastava, Geoffrey E Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: a simple way to prevent neural networks from overfitting. *Journal of machine learning research*, Vol. 15, No. 1, pp. 1929–1958, 2014.
- [20] Diederik Kingma and Jimmy Ba. Adam: A method for stochastic optimization. In *ICLR*, 2015.
- [21] Tomas Mikolov, Ilya Sutskever, Kai Chen, Gregory S. Corrado, and Jeffrey Dean. Distributed representations of words and phrases and their compositionality. In *Advances in Neural Information Processing Systems 26: 27th Annual Conference on Neural Information Processing Systems 2013. Proceedings of a meeting held December 5-8, 2013, Lake Tahoe, Nevada, United States.*, pp. 3111–3119, 2013.

付録

A VRAE 学習の詳細

本研究の実験1で利用したVRAEは以下の設定で学習した.

- 訓練データはseq2seqを学習するのに利用した提案訓練データの発話文集合とした.
- 単語ベクトル・隠れ層1024次元, LSTMを4層, Dropout確率[19]を0.1, GradientClippingを5.0とした.
- バッチサイズは100とし, エポック数は60とした.
- 最適化にはAdam[20]を利用し, α を0.0001とし, 残りのパラメータはChainer⁹のAdamクラスの初期値を利用した.
- 単語ベクトルの初期値は, seq2seqの学習と同様にword2vecで学習したベクトルを利用した.
- encoderとdecoderの間にある潜在的意味空間の情報を保持する潜在意味ベクトル z は256次元とした. またseq2seqが4層であるため, 潜在意味ベクトル z は各層に1つ, 計4つ用意した.
- 潜在意味ベクトル z のサンプリング回数は, 1イタレーションにつき5回行った.
- VRAEの潜在意味空間が多変量正規分布に収まるように学習した. ただし, 学習初期は多変量正規分布の分散を 0^{10} とし, 4エポック終了時に1イタレーションごとに分散を0.0001ずつ増やした. これは分散が1になるまで続けた. 概観を図8に示す.

⁹<https://github.com/chainer/chainer>

¹⁰分散を0にするとカルバック・ライブラー情報量の計算が発散するので, 実際の実験では近似的に0.00001を初期値としている.

- 潜在意味空間を効率よく学習するために, Bowman ら [16] が提唱した, 目的関数に含まれる潜在意味空間と多変量正規分布とのカルバック・ライブラー情報量に対する焼きなましと decoder の単語削除を行った.
- カルバック・ライブラー情報量の焼きなましとは, VRAE の目的関数のカルバック・ライブラー情報量の項の重みを学習過程に応じて 0 から増やすことである. 本研究では, 12 エポック終了時にカルバック・ライブラー情報量の項の重みが 0.5 になるようにゲインが 0.001 であるシグモイド関数を利用して焼きなましを行った. 概観を図 8 に示す.
- decoder の単語削除とは, VRAE 学習時に decoder に入力する単語を確率的に “unk” に変更し, その “unk” で次の単語を予測するようにすることである. このことにより, decoder は入力された “unk” だけで次の単語を予測するのが難しくなるため, 潜在意味ベクトルの情報を利用するように学習される. 本研究では単語削除率を 0.5 とした.




図 8: 学習中のカルバック・ライブラー情報量の様子

発表文献一覧

受賞一覧

- 平成 27 年度東北大学工学部長賞

国内会議・研究会論文

- 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.
- 赤間怜奈, 稲田和明, 小林颯介, 佐藤祥多, 乾健太郎. 対話生成における転移学習を用いた応答のスタイル制御. 言語処理学会第 23 回年次大会, pp.338-341, March 2017.
- 佐藤祥多, 乾健太郎. 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. 言語処理学会第 24 回年次大会, to appear, March 2018.