

対話行為設計のための発話クラスタリング

Automatic Clustering of Utterances for a Dialogue Act Design

東中竜一郎^{1*} 川前徳章² 貞光九月¹ 南泰浩³ 目黒豊美³ 堂坂浩二³ 稲垣博人¹
Ryuichiro Higashinaka¹ Noriaki Kawamae² Kugatsu Sadamitsu¹ Yasuhiro Minami³
Toyomi Meguro³ Kohji Dohsaka³ Hirohito Inagaki¹

¹ NTT サイバースペース研究所

¹ NTT Cyber Space Laboratories

² NTT コムウェア

² NTT Comware Corporation

³ NTT コミュニケーション科学基礎研究所

³ NTT Communication Science Laboratories

Abstract: Automatic clustering of utterances can be useful for the modeling of dialogue acts for dialogue applications. Previously, the Chinese restaurant process (CRP), a non-parametric Bayesian method, has been introduced and has shown promising results for the clustering of utterances in dialogue. This paper introduces the infinite HMM, which is also a non-parametric Bayesian method, and verifies its effectiveness. We also analyze our clustering results to discuss how to derive useful insights for a better dialogue act design.

1 はじめに

特定の対話ドメイン（ここで、ドメインとは対話システムが扱う対話内容・分野・ジャンルを表す．たとえば、フライト予約や会議室予約、特定の話題における雑談などである．）における対話システムを構築する場合、そのドメインの対話データを、人同士の対話や、人とプロトタイプシステムとの対話を収録することで収集し、研究者や開発者が、そのドメインの対話をモデル化する必要がある．たとえば、語彙のセットは何かよいかといったものや、どのような種類の発話を扱うべきかといったことを決める．

対話システム構築において特に重要とされるのは、特に、後者の発話の種類（対話行為）を設計し、決定するフェーズである．対話行為が決定されると、対話におけるインタラクションの単位が決まり、システムの理解部や生成部の詳細を詰めることができる．対話行為とは、DAMSL (Dialog Act Markup in Several Layers) [2] に規定されるような対話行為のセットであり、文献 [9] や文献 [8] のように、想定されるドメインに応じて準備されることが一般的である．

もちろん、いくつかのスロットを埋めるだけの、非常に単純なタスク指向型の対話アプリケーションであれば、対話行為の定義は大きな問題にならないかもし

れない．しかし、それでも、ユーザの自由な発話を許すと、複数のスロットを組み合わせたような発話や、対話の目的に直接関係のない発話を扱うことが実際には必要となり、それらについても対話行為を準備しておく必要が生じることは多い．雑談のようにタスク制約がより少ない対話であれば、対話行為の定義はいっそう難しい．たとえば、著者らは、動物の好き嫌いについて雑談を行うシステム [4] や、ユーザの話を傾聴する聞き役対話システム [6] の研究を進めているが、これらの対話ドメインにおける対話行為の定義には、われわれは相当の時間を要したし、また、随時改訂を行っている．

このように、従来の対話システムの研究では対話行為の種類を人間が事前に決定している．一般に、どのような発話がドメインに存在し、どのくらいの対話行為数が必要かを決定するには、専門家の詳細な分析が必要で、コストが非常に高い．これが、現在の対話システム開発の大きな問題の一つである．

そこで、近年、発話を自動的にクラスタリングし、収集した対話データについて、どのような発話のまとまりがあるか、いくつくらいの対話行為数が必要かをデータから自動的に求める研究が見られるようになってきた [3]．Crook らの手法は、中華料理店過程 (Chinese Restaurant Process, CRP) と呼ばれる手法を用いて、発話のクラスタリングを行い、データから最も最適な対話行為数 (クラスタ数) を推定する．この手法を用い

*連絡先：NTT サイバースペース研究所
〒 239-0847 神奈川県横須賀市光の丘 1-1
E-mail: higashinaka.ryuichiro@lab.ntt.co.jp

ることで、収集したデータから、おおよその発話のまとまりや対話行為数を自動的に求めることができ、対話行為の設計に役立てることができる。なお、文献 [7] や文献 [1] も、発話の自動クラスタリングを目的とした研究であるが、これらはあらかじめ対話行為数が決定されている手法である。

CRP を用いた手法にも欠点がある。それは発話をそれぞれ独立のものとしてクラスタリングしている点である。対話は発話の連続からなっており、この点を考慮せずにクラスタリングしたのでは、適切なクラスタリングとは言えないだろう。たとえば、「はい」は、「肯定」と「相槌」の両方の可能性があり、文脈からでないと判断できないが、従来技術では同じものとして扱ってしまう可能性がある。適切な対話行為設計のためには、対話行為数を決定しないクラスタリング手法であり、かつ、対話において特に重要な文脈を考慮できる手法が望ましい。

本研究報告では、無限隠れマルコフモデル（無限 HMM）を用いることで、文脈を考慮し、対話行為数をあらかじめ決定しない発話のクラスタリングを提案する。そして、二つのドメインの対話データにおいて、無限 HMM を用いた手法のクラスタリング精度を評価する。また、クラスタリング結果を対話行為の設計にどう役立てるのかについても考察する。

2 手法

無限 HMM はノンパラメトリックベイズの手法の一つであり、時系列的なデータを扱う HMM を無限の状態が扱えるようにしたものである。無限の状態が扱えるということの意味は、状態数が予め定まっていないうことを指し、状態数はデータ依存で決定される。無限 HMM の詳細は、文献 [10] を参照されたい。

本研究報告では、この無限 HMM を用いることで、文脈情報を用いた発話のクラスタリングを行い、同時に、対話行為数を推定する。われわれは、無限 HMM によって、発話のシーケンスをモデル化する。すなわち、各状態から発話が出力され、次の状態に遷移するようなモデルである。ここで、状態は対話行為にあたる。状態間の遷移（すなわち、対話行為間の遷移）を扱うため、文脈情報（特に、直前の対話行為）を用いていると考えることができる。なお、複数の状態が接続されているため、必ずしも直前の対話行為のみに依存してクラスタリングがされているわけではない。

本節では、まず先行研究であり、本研究でベースラインとして用いる、CRP を用いた手法について説明し、その後、無限 HMM を用いた手法について述べる。

2.1 CRP

CRP はデータから自動的にクラスタ数を決定する手法であり、下記の手続きでクラスタリングが行われる。

CRP において、データ（すなわち、発話）は客と呼ばれ、クラスタはテーブルと呼ばれる。最初の客は最初のテーブルに配置される。そして、次の客 (c_i) は、すでに客がついたテーブル (t_j) に座るか、新しいテーブル (t_{new} ; new は新しいテーブルのインデックス) に、次の確率で座る。

$$P(t_j|c_i) \propto \begin{cases} \frac{n(t_j)}{N + \alpha} \cdot P(c_i|t_j) & (\text{if } j \neq new) \\ \frac{1}{N + \alpha} \cdot P(c_i|t_j) & (\text{if } j = new), \end{cases}$$

ここで、 $n(t_j)$ は t_j についている客の数を返す関数であり、 N はこれまでにテーブルについている客の数であり、 α は客が新しいテーブルにつく度合いを示すハイパーパラメタである。これは、大きければ大きいほどクラスタ数が増えるパラメタである。 $P(c_i|t_j)$ は c_i が t_j から生成される確率である。この確率は以下のように計算する。

$$P(c_i|t_j) = \prod_{w \in W} P(w|t_j)^{\text{count}(c_i, w)},$$

$$P(w|t_j) = \frac{\text{count}(t_j, w) + \beta}{\sum_{w \in W} \text{count}(t_j, w) + |W| \cdot \beta}.$$

ここで、 W は特徴量の集合であり、 $\text{count}(*, w)$ は客またはテーブルにおいて、特徴量 w が何回生じたかを表す。 β は確率 0 を防ぐためのハイパーパラメタである。 $P(c_i|t_{new})$ には一様分布を用いる。

すべての客を順番に配置した後、ギブスサンプリングにより客を再配置していく。これは、客を一人そのテーブルから離し、上記処理によって別テーブル（新しいテーブルも含む）か、自分が元いたテーブルに再度配置させるものであり、これをすべての客について最適な配置が求まるまで何度も繰り返す。客の配置が変わらなくなるか、規定回数以上のサンプリングが行われたら、収束したとみなし、そのときの客のテーブルにおける配置をクラスタリング結果とする。

2.2 無限 HMM

無限 HMM は CRP に似た処理によってクラスタリングを行うため、ここでも、データは客、クラスタはテーブルと呼んで話を進める。無限 HMM では、客 c_i は、すでに客の着いているテーブル t_j か新しいテーブル ($t_{j=new}$) に以下の確率で座る。

$$P(t_j|c_i) \propto P(t_j|t_{c_{i-1}}) \cdot P(t_{c_{i+1}}|t_j) \cdot P(c_i|t_j),$$

ここで、 t_c は c の着席しているテーブルを表す。無限 HMM では、客には順序があり、 c_i の前と後の客を、それぞれ c_{i-1} と c_{i+1} とする。これは、対話データ中の発話に順序があることに該当する。 $P(t_k|t_j)$ はテーブル間の遷移確率であり、以下で求める。

$$P(t_k|t_j) = \frac{\text{transitions}(t_j, t_k) + \gamma}{\sum_{l=1}^K \text{transitions}(t_j, t_l) + K \cdot \gamma + \alpha},$$

ここで、 α は客が新しいテーブルに着く度合いを表すハイパーパラメタであり、 K はすでに客がいるテーブル数を表す。transitions(t_j, t_k) は t_j から t_k の遷移数であり、 γ は確率 0 を避けるためのハイパーパラメタである。客が新しいテーブルに着く確率は次のようになる。

$$P(t_{new}|t_{c_{i-1}}) \cdot P(t_{c_{i+1}}|t_{new}) \cdot P(c_i|t_{new}),$$

ここで、 $P(t_{new}|t_{c_{i-1}})$ と $P(t_{c_{i+1}}|t_{new})$ は以下で求める。

$$P(t_{new}|t_{c_{i-1}}) = \frac{\alpha}{\sum_{l=1}^K \text{transitions}(t_{c_{i-1}}, t_l) + \alpha},$$

$$P(t_{c_{i+1}}|t_{new}) = \frac{1}{K+1}.$$

ここで、 $P(c_i|t_{new})$ には一様分布を用いる。

CRP の時と同様、ギブスサンプリングを用いて客の配置を最適化し、最終的に得られた客の配置をクラスタリングの結果とする。客は、自分の前の客の着いているテーブルを見て自分の着くべきテーブルを決めており、文脈情報を用いてクラスタリングを行っていることが分かる。

3 実験

無限 HMM を用いた発話クラスタリングの有効性を確認するため、実験を行った。ここでは、まず、用いた対話データについて説明し、実験手順、ベースライン、評価尺度、そして、結果について述べる。なお、ここで用いる対話データはテキスト対話であり、対話ドメインは対話行為の設計が難しい雑談に近いものである。

3.1 対話データ

3.1.1 動物議論対話

動物議論対話のデータは、対話システムと人間との会話を収録したものであり、全部で 1000 対話ある。対話の中で、システムと人間は動物の好き嫌いについて議論している。このドメインを Animal Discussion (AD) ドメインと呼ぶ。総発話数は 57197 である。

対話例を図 1 に示す。本ドメインでは 29 の対話行為が人手によって定義されており、すべての発話に、人手によって対話行為がタグ付けされている。対話行為セットの詳細は文献 [4] を参照されたい。

3.1.2 聞き役対話

聞き役対話データは人間同士の聞き役対話を集めたものである。このドメインを Attentive Listening (AL) ドメインと呼ぶ。聞き役対話とは、二者が聞き役と話し役に分かれて、一方が聞き役となって話し役の話を聞くという対話である。このようなデータを我々は Web ベースのチャットシステムを用い、1260 対話収集した。総発話数は 56937 である。

S どうもです (GREETING)
 U どうもです (GREETING)
 S 好きな動物、嫌いな動物について話しましょう (OPEN-DIALOGUE)
 U コンチュウは好きですか (Q-DISC-P)
 S コンチュウは好きでしょうか (Q-DISC-P)
 U ホタルは好きです (DISC-P)
 S ホタルが好きなんですね (REPEAT)
 U ホタルは光るから好きです (DISC-P-R)
 S 私もとても好きなんです (DISC-AGREE-P)
 U ホタルのどんなところが好きですか (Q-DISR-R)
 S 私も好きなんですよ (DISC-AGREE-P)
 ホタルは儂いから (DISC-R)
 U ホタルはきれいだから好きです (DISC-P-R)
 S なるほどそうなんですね (EMP)

図 1: ユーザとシステムの対話例。U はユーザ発話、S はシステム発話を表す。括弧内は本ドメインにおける対話行為タイプである。

対話例を図 2 に示す。本ドメインには 38 の対話行為が人手によって定義されている。本データについても、すべての発話に対話行為がタグ付けされている。対話行為セットの詳細は文献 [6] を参照されたい。

3.2 実験手順

AD ドメインと AL ドメインのデータに対し、無限 HMM の手法でクラスタリングを行った。評価は手作業でタグ付けされたタグを正解と見なし、purity と F 値を算出することで行った (評価尺度については後述)。また、同データについて、CRP によるクラスタリングを適用し、クラスタリング精度を比較した。

クラスタリングを行う前に、発話を特徴量化する必要がある。ここでは、bag-of-words の特徴量を用いた。ChaSen により形態素解析を用い、各発話について、bag-of-words の特徴量を求めた。ただ、低頻度語はクラスタリングに悪影響を及ぼす可能性があるため、各ドメインの全データについて、トップ 5000 の頻度の単語のみを特徴量とした。単語には標準形を用いた。

クラスタリングはそれぞれのドメインの対話データすべて (AD ドメインは 57197 発話、AL ドメインは 56937 発話) について行い、CRP と無限 HMM におけるハイパーパラメタは α を 0.001, 0.01, 0.1, 1 の 4 通りを試した。 β, γ については、今回は 0.001 で固定した。ギブスサンプリングの回数は 100 回とした。CRP と無限 HMM は確率的に動作するため、本実験では、それぞれの手法で 20 回クラスタリングを試行し、その平均値を求めて、評価結果とした。

3.3 評価尺度

評価尺度には、purity と F 値を用いた。どちらもクラスタリング評価の一般的な指標である [5]。purity は一つのクラスタにどの程度同じ対話行為の発話が入っているかを表し、F 値は、データのペアに着目し、同じクラスタにあるべきペアがどの程度正しく同じクラス

S こんばんは (挨拶)
 L こんばんは (挨拶)
 S テーマは食事でお願します (挨拶)
 S 今夜の夕飯はカレーでした (自己開示_事実)
 S Lさんはカレーは好きですか? (質問_事実)
 L よろしくお願します。(挨拶)
 何カレー? (質問_事実)
 S 自宅カレーです (自己開示_事実)
 L カレー大好きです! (自己開示_事実)
 S 隠し味などナッスィングなカレーです (自己開示_事実)
 L ナッスィングなカレーですね! (繰り返し)
 具は何ですか? (質問_情報提供要求)
 S たまねぎ、にんじん、じゃがいも、お肉です (情報提供)
 S 我が家のカレーはそのように無個性ですが (自己開示_事実)
 S よそには個性バリバリなカレーがあるようで、むかし、旅行先ではトロピカルカレーなるものがでました (情報提供)

図 2: 聞き役と話し役の対話例。S は話し役, L は聞き役である。括弧内は本ドメインにおける対話行為タイプである。

タに入っているかを定量化する。purity は以下の式で計算される。

$$\text{purity}(\mathcal{C}, \mathcal{D}) = \frac{1}{N} \sum_{k=1}^K \max_j |c_k \cap d_j|,$$

ここで, $\mathcal{C} = \{c_1 \dots c_K\}$ はクラスタの集合であり, $\mathcal{D} = \{d_1 \dots d_N\}$ は対話行為の集合であり, N はデータ数 (発話数) である。F 値は次のように算出される。

$$\text{precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \quad \text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}},$$

$$F = \frac{2 \cdot \text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}},$$

ここで, TP, FP, FN はそれぞれ true positive, false positive, false negative を表す。true positive は、同じ対話行為である発話のペアが同じクラスタに入っている回数であり, false positive は異なる対話行為である発話のペアが同じクラスタに入っている回数であり, false negative は同じ対話行為である発話のペアが異なるクラスタに入っている回数である。

3.4 結果

表 1 と表 2 に AD ドメイン, AL ドメインの発話のクラスタリング結果をそれぞれ示す。全体的な傾向として, 無限 HMM は CRP よりもクラスタリング精度が高い。この傾向は AD ドメインでは特に顕著であり, purity と F 値とともに, 無限 HMM は CRP を大きく上回っている。AL ドメインでも, CRP と同等もしくは多少精度の改善が見られており, 無限 HMM を用いることで, 精度は一般的に改善することが分かる。このことは, 発話のクラスタリングに文脈情報を利用することが有用

表 1: AD ドメインの発話のクラスタリング結果。太字は最も良い値を表す。

	α	purity	F 値	状態数
CRP	0.001	0.570	0.423	57.65
	0.01	0.576	0.429	69.40
	0.1	0.583	0.439	84.55
	1	0.582	0.409	109.90
無限 HMM	0.001	0.643	0.555	62.80
	0.01	0.653	0.550	77.60
	0.1	0.656	0.564	99.25
	1	0.650	0.540	139.10

表 2: AL ドメインの発話のクラスタリング結果

	α	purity	F 値	状態数
CRP	0.001	0.331	0.179	31.00
	0.01	0.332	0.181	32.55
	0.1	0.337	0.177	35.70
	1	0.335	0.175	42.65
無限 HMM	0.001	0.347	0.179	30.00
	0.01	0.345	0.180	31.40
	0.1	0.348	0.180	37.10
	1	0.348	0.181	51.25

であることを示している。なお, AL ドメインにおいて, 精度の改善が限定的である理由は, そもそも人間同士の発話のクラスタリングは困難であるからだと考えられる。

新しいクラスタを作成しやすくするハイパーパラメタである α を変えたときの効果を見ると, 確かに α を大きくすることで, 状態数が増えている。しかし, 0.001 から 1 に増やしても, それほど極端に状態数が増えるわけではないようである。特に 0.1 以下であれば, それほど状態数が変わることはない。なお, 状態数が増えても, purity や F 値は大きな影響を受けていない。このことは, α を大きくすることで, クラスタを適切に細分化できることを表している。つまり, α を変えてクラスタリングすることで, さまざまな粒度の対話行為の検討が可能である。

なお, AD ドメインの状態数が AL ドメインのそれより多くなっているが, これは単語特徴量を上位 5000 に絞ったことによるところが大きいと思われる。AD ドメインの方が, AL ドメインに比べ, ユニーク単語数が少なく, 単語特徴量として比較的低頻度な単語も含まれてしまった。このため, 発話が細かな単語の違いで異なるクラスタに分類されやすくなったのだと思われる。実際, 単語特徴量を頻出 2000 単語に絞ると, 特徴量が粗くなったため, 精度が若干下がり, また, 状態数が若干減少した。

4 対話行為設計の実践

発話のクラスタリングが本当に対話行為設計に役立つか, 実際に, 聞き役対話データに人手による対話行為タグがついていないと仮定し, その対話行為設計を通

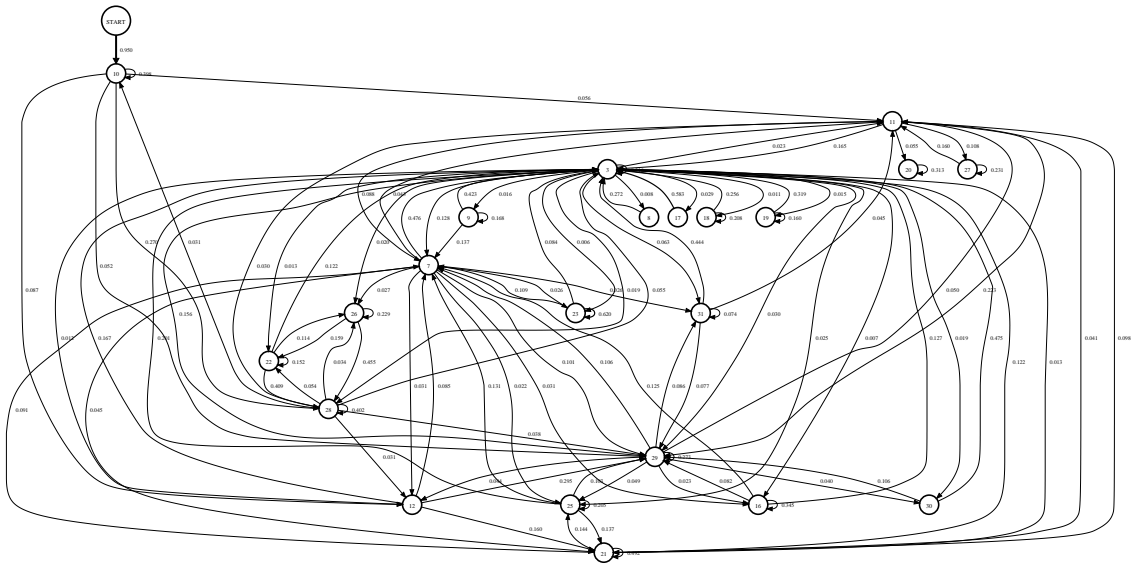


図 3: 学習された無限 HMM から得られたネットワーク図

して、検証してみる。

ここでは、 α が 0.001 で、単語特徴量に上位 5000 単語を使用して学習したモデルを用いる。まず、全体像を概観するため、構造をネットワーク (図 3) として表した。これは、モデルの学習データに対する最尤パスを求め、多く通過するパス (今回は 100 回以上) と、その関係する状態のみを可視化したものである。この図は、後段で対話行為を解釈する際に役に立つ。

次に、グラフに出現する各状態について、アサインされた発話中に含まれる単語で特に特徴的なもの (特徴語) を抽出した。表 3 は各状態で、他の状態に比べて、尤度比検定で有意 ($p < 0.0001$) に出現頻度が高い単語群と、アサインされた発話の例を示す。これを解釈することによって必要な対話行為を設計していく。

まず、状態 3 は意見 (推量)、状態 7 は相槌だと考えられる。状態 8 は「…」のような相手の心情を慮るような共感である。状態 9 は「～です」と事実を述べている。状態 10 は挨拶である。状態 11 は嗜好について、状態 12 は事実についての質問である。状態 16 は事実 (出来事) についての発話である。状態 17 は相手の肯定であり、状態 18 は、状態 11 と近いが、呼びかけがないため、文脈途中の追加質問だと思われる。状態 19 は具体的な事実の詳細を伝える発話であり、状態 20 は習慣についての発話である。状態 21 と状態 23 は食事とスポーツについての発話である。これは、対話のトピックが状態として現れたものと思われる、対話行為としての解釈は難しい。状態 22, 26, 28 は図 3 を見ると相互に結びついており、すべて対話終了のやりとりに関するものである。状態 25 は一般的な共感である。状態 27 は嗜好の伝達であり、状態 29 は自己についての情報の伝達である。状態 30 は確認発話であり、

状態 31 は賞賛である。図 3 を見ると、いくつか中心的な発話も分かる。たとえば、状態 3, 7, 29 の意見、相槌、自己についての情報伝達は、このドメインでは欠かせない対話行為であることが分かる。

このように解釈を進めていくと、聞き役対話において、必要な対話行為のセットが明らかになってくる。それらは以下の通りである: 伝達 (意見、事実、事実の詳細、自己情報、嗜好、習慣)、質問 (事実、嗜好、追加)、相槌、確認、共感、肯定、賞賛、挨拶、終了。これらは、実際に我々が手作業で作成した対話行為にかなり近いものであり (聞き役対話の対話行為については文献 [6] を参照されたい)、対話行為を設計するには、発話をクラスタリングする方法が有効であることが分かる。状態も、大きな重複がなく、データから最適なクラスタ数を決定する無限 HMM が、有効に機能していると言える。なお、「事実の詳細の伝達」や「追加質問」などは我々の対話行為セットになかったものである。このような発見は、対話行為セットを随時改訂する際に非常に有用な知見となりうる。

5 まとめ

本稿では、対話行為設計の効率化を目指して、発話の自動クラスタリングを行った。具体的には、無限 HMM を用い、先行研究である CRP による手法よりも高精度なクラスタリングができることを示した。また、得られたクラスタを分析することで、対話行為設計に役立つ可能性も示した。本稿では対話行為の設計についてのみ述べたが、本クラスタリングは他の用途に用いることも可能である。たとえば、特定のクラスタにアサインされた発話から生成テンプレートを作成したり、言語理解用の文法を作成したり、得られたモデルを対

表 3: 図 3 の各状態における特徴語と発話の例

状態	特徴語 および アサインされた発話の例
3	ない, と, て, が, に, ちゃう, けど, でも, かも, しれる, 手, なる, し, から, 言う, 思う (例) ネットで探したらあるかもしれないですね
7	そう, そうですね, , なるほど, です, はい, ん, !, ねー, か (例) あ、やっぱりそうですか
8	・, すみません, なかなか, ない, が, ん, あまり, 忙しい, だ, ほとんど (例) 働くって大変ですね...
9	花粉, 症, です, かわいい, じゃ, 春, 大丈夫, ね, 関係, もう (例) やっぱ日本人は米ですよ, 競技場の雨はきついですよ
10	・, ! (例) こんばんは, , はじめまして。
11	?, さん, か, T, は, どんな, 何, 好き, 2, いかが (例) T 2 0 さんはどんな映画が好きですか?
12	?, か, 何, れる, ます, 今日, どこ, を, 行く, た, 最近, どんな (例) きょうのお昼には何を食べましたか
16	見る, ドラマ, 野球, テレビ, 「, 」, ニュース, の, 大学, サッカー, 映画 (例) 最近、アメリカドラマにはまってまして今日も見てました。
17	確か, 。, わかる, よ, ね, そんな, それ, そう, ます, ある (例) 確かに。。。
18	?, か, 曲, です, と, とか, どの, どんな, つけ, や (例) お気に入りの曲はありますか?
19	0, 1, くらい, 2, 円, 5, 分, 年, 4, 3, 回 (例) もう4、5年前ぐらいかなあー
20	聴く, 見る, 曲, 聞く, 最近, 著, 読む, 小説, ・, 好き, いる, ます (例) ホラーやサスペンス以外なら割と何でも見ます。
21	食べる, カレー, 作る, 野菜, うどん, おいしい, スープ, 入れる, 美味しい, 豆腐 (例) 今日はパスタを食べましたよ
22	くださる, また, ぜひ, て, お話, !, では, 是非, みる, 頑張る, 今度 (例) またドラマの話をお聞かせください。
23	韓国, 勝つ, イチロー, 戦, キューバ, 日本, WBC, 試合, 強い, ね (例) 日本は順調のようでー安心です
25	です, ね, いい, おいしい, よ, !, 好き, お, だ, おお (例) おお、いっぱいあるのは楽しみです
26	時間, そろそろ, ね, よう, 。, 楽しい, もう, あ, です, 残念 (例) 時間なので失礼します。
27	好き, です, 。, 私, 映画, ほう, ね, も, いい, よ (例) こし派ですか?
28	ござる, ありがとう, お願い, よろしい, ます, さようなら, こそ, こちら (例) ありがとうございます!
29	行く, て, いる, た, に, 私, 実家, 飼う, くる (例) 学生なので、学校帰ります
30	?, か, です, どんな, う, どう, ん, え, だ, そう (例) ほんとはですか?
31	!, それ, はる, です, すごい, ね, おお, あ, 。, は (例) それは大変ですよ。

話制御に役立てることも可能であると思われる。今後は、本手法を、新しいドメインにおける対話行為設計の手助けとするとともに、対話システム構築の一助となるよう検討を重ねていく予定である。

参考文献

- [1] Toine Andernach, Mannes Poel, and Etto Salomons. Finding classes of dialogue utterances with Kohonen networks. In *Proc. the ECML/MLnet Workshop on Empirical Learning of Natural Language Processing Tasks*, pp. 85–94, 1997.
- [2] M. Core and J. Allen. Coding dialogs with the DAMSL annotation scheme. In *Proc. AAAI Fall Symposium on Communicative Action in Humans and Machines*, pp. 28–35, 1997.
- [3] Nigel Crook, Ramon Granell, and Stephen Pulman. Unsupervised classification of dialogue acts using a Dirichlet process mixture model. In *Proc. SIGDIAL*, pp. 341–348, 2009.
- [4] Ryuichiro Higashinaka, Kohji Dohsaka, and Hideki Isozaki. Effects of self-disclosure and empathy in human-computer dialogue. In *Proc. SLT*, pp. 109–112, 2008.
- [5] Christopher D. Manning, Prabhakar Raghavan, and Hinrich Schütze. *Introduction to Information Retrieval*. Cambridge University Press, 2008. (Chapter16: Flat clustering).
- [6] Toyomi Meguro, Ryuichiro Higashinaka, Yasuhiro Minami, and Kohji Dohsaka. Controlling listening-oriented dialogue using partially observable Markov decision processes. In *Proc. COLING*, pp. 761–769, 2010.
- [7] Kiyonori Ohtake. Unsupervised approach for dialogue act classification. In *Proc. PACLIC-22*, pp. 445–451, 2008.
- [8] Elizabeth Shriberg, Raj Dhillon, Sonali Bhagat, Jeremy Ang, and Hannah Carvey. The ICSI Meeting Recorder Dialog Act (MRDA) Corpus. In *Proc. SIGDIAL*, pp. 97–100, 2004.
- [9] Andreas Stolcke, Noah Coccaro, Rebecca Bates, Paul Taylor, Carol Van Ess-Dykema, Klaus Ries, Elizabeth Shriberg, Daniel Jurafsky, Rachel Martin, and Marie Meteer. Dialogue act modeling for automatic tagging and recognition of conversational speech. *Computational Linguistics*, Vol. 26, No. 3, pp. 339–373, 2000.
- [10] Y.W. Teh, M.I. Jordan, M.J. Beal, and D.M. Blei. Sharing clusters among related groups: Hierarchical Dirichlet processes. In *Proc. NIPS*, 2004.