

実世界における人とロボットの共有信念に基づいた 相互適応的な発話生成

中村 慎也[†] 岩橋 直人^{††,†††} 長井 隆行[†]

[†] 電気通信大学電気通信学研究所電子工学専攻

^{††} 情報通信研究機構知識創成コミュニケーション研究センター

^{†††} 国際電気通信基礎技術研究所音声言語コミュニケーション研究所

E-mail: [†]about_love@apple.ee.uec.ac.jp, ^{††}naoto.iwahashi@atr.jp, ^{†††}tnagai@ee.uec.ac.jp

あらまし 本稿では、実世界状況において、ロボットが人との信念の一致度に応じて適切なコミュニケーションを行うための、発話生成手法を提案する。提案手法はロボットに、動作やオブジェクトの概念を表す共有信念モデルを学習させると同時に、対話者との信念の一致度を推定し表現する関数を学習させる。それぞれの概念を表す信念モデルは確率モデルで表現される。学習は、人とロボットによるオブジェクトを用いたインタラクションを通してオンラインで行われる。学習を通してロボットは、発話を対話者が正しく理解できる確率を推定することにより、対話者との共有信念の一致度に応じて単語数を増減させるなどの適応的な発話を行うことが可能となる。学習させる共有信念や誤った場合の正解の提示の有無など、様々な条件で実験を行い提案手法の有効性を評価した。

キーワード 発話生成, 共有信念, オンライン学習, 確率モデル

Mutually-Adaptive Generation of Utterances Based on Belief Shared by Human And Robots in Real World.

Shinya NAKAMURA[†], Naoto IWAHASHI^{††,†††}, and Takayuki NAGAI[†]

[†] Dept. of Electronic Engineering, The University of Electro-Communications

^{††} NICT Knowledge Creation communication Research Center

^{†††} ATR Spoken Language Communication Research Laboratories

E-mail: [†]about_love@apple.ee.uec.ac.jp, ^{††}naoto.iwahashi@atr.jp, ^{†††}tnagai@ee.uec.ac.jp

Abstract In this paper, an utterance generation method is proposed. Generated utterances are used to communicate with a user in real world depending on the degree of coincidence of belief, which shared by a user and the robot. The robot learns the belief model shared by a user and the robot, which represents the concepts such as motion and object, and the function, which expresses the degree of coincidence of beliefs, online, simultaneously, through Human-Robot interaction with objects. The robot's system of belief is represented by a probabilistic model. Through the learning, the robot acquires the performance to select some words and to change number of words of the utterance appropriately in order to convey the utterance correctly, depending on the shared belief. The validity of the proposed algorithm is shown through some experiments under various conditions.

Key words Utterance Generation, Shared Belief, Online Learning, Probabilistic Model

1. はじめに

科学技術の発展に伴い、ロボットなどの機械が、周囲の環境や人の行動を知覚することが可能となってきた。近い将来には、状況に応じて我々の生活を支援してくれるようなロボットがより身近な存在になると考えられる。その際にロボットは、人と

自然な言語コミュニケーションを行う能力を持つ必要がある。

こうした背景のもと、人とロボットの共有経験に基づく言語コミュニケーションの実現を目指して、ロボットや計算機による言語獲得や対話システムの研究が行われている。例えば筆者らは、人とロボットがぬいぐるみなどのオブジェクトを用いながら音声によるインタラクションを行うことで、ロボットが




図1 インタラクションの様子
Fig. 1 Examples of interaction.

言語コミュニケーション能力を獲得する計算機構を提案している [1]. [2] では、あらかじめオブジェクトの画像イメージをクラスタリングしておき、信念ネットワークにより、音声・単語・画像の情報を統合して、ロボットにオブジェクトを同定させる手法が提案されている。また [3] では、ユーザの発話から信念モデルを構築・更新し、ベイジアンネットワークを用いた確率的制約に基づいて発話を選択する枠組みを提案している。ここでは、常に効用が高い発話を行うというヒューリスティクスを導入して発話を選択している。

状況に応じた適切な発話理解や生成のためには、状況に対する互いに共有する信念を持っていることが必要となる。コミュニケーションにおいて曖昧な発話を行うと、曖昧な発話の理解には共有信念をより多く利用する必要があるため、信念の共有が促進される。また、詳細な発話を行うことにより、正しく意味を伝達することができる。そこで本稿では、視聴覚機能及びアームを有するロボットを対象として、対話者との間で共有信念の一致度を逐次推定することで、発話の理解率を制御し適切な発話を選択する手法を提案する。提案手法では、オブジェクトを用いたインタラクション (図 1) を通じて、ロボットに共有信念を学習させると同時に、対話者との間での共有信念の一致度を推定する関数をオンラインで学習させる。

本稿は以下、次のように構成されている。次章ではまず、本研究で扱うロボットシステムとタスクを述べる。3. 章では、提案する共有信念を表す計算機構の概要を述べ、4. 章では、計算機構を用いた発話手法や学習手法を詳しく述べる。5. 章では、様々な条件の実験で提案手法の評価を行い、6. 章で、実験に関する全体的な考察を行う。最後に、7. 章で、全体をまとめる。

2. ロボットシステムとタスク

2.1 ロボットシステム概要

本研究で使用するロボットは、自由度 7 のアームと自由度 4 のハンド、マイクロフォン、及びステレオカメラを備えている (図 1 (a))。マイクロフォンは音声認識に使用され、音声の特徴量には MFCC を用いる。ロボットはステレオカメラから得られた映像情報からオブジェクトを抽出し、画像特徴量及び座標を取得する。画像特徴量としては、色 3 次元 ($L^*a^*b^*$)、大きさ 1 次元、形 1 次元を用いる。動作によるオブジェクトの軌道情報は、オブジェクトの座標の時系列ベクトルによって表される。

2.2 タスク

図 1 (a) のように人とロボットが向き合い、互いにテーブル

の上のオブジェクトを用いながら言語によるインタラクションを行う。ここでのインタラクションは、人とロボットのそれぞれが他方に対して、テーブルの上の 1 つのオブジェクトを動かすように指示する発話を行い、聞き手がその発話を理解して行動する、といったものである。このとき、ロボットは初期状態で、少数の語彙や文法といった言語的な知識を人と共有しており、簡単な発話が理解できる状態とする。一方が発話を行い他方が行動を終えるまでを、1 エピソードと呼ぶことにする。

ロボットによる発話生成と発話理解の具体例を以下に述べる。図 1 (b) のシーンにおいて、箱に乗っているオブジェクト (パーバズー) を矢印のように動かして、別の箱に乗せる行動を意図したとする。このときユーザがロボットに「パーバズー箱のせて」という発話を行うと、信念の一致度が低い場合には図中左のどちらの箱に乗せるべきか判断できないが、直前に動かした物体は次の発話において使用されやすいという信念を共有していれば、正しい行動を行うことができる。ロボットが人に対して指示を行う際にも、同様に共有信念が用いられる。このとき、人が正しく行動できれば、直前に乗せた箱が次の発話に利用されるという信念の共有が確かめられる。

3. 共有信念モデル

3.1 ロボットの信念モデル

3.1.1 レキシコン L

レキシコン L は、それぞれの単語に対応した音声 s の確率密度関数 $p(s|c_i)$ とオブジェクト o の確率密度関数 $p(o|c_i)$ の対で表される ($i = 1, \dots, N$)。 N は学習した単語数、 c_i は各単語のインデックスである。 $p(s|c_i)$ は HMM によって表され、 $p(o|c_i)$ はガウス分布で表現される。オブジェクトの軌道に関する概念は、動かされるオブジェクト t (トラジェクタ) と基準点となるオブジェクト l (ランドマーク) の、時間的な位置関係の変化で表される。単語 c_i 、トラジェクタの位置 $o_{t,p}$ 、ランドマークの位置 $o_{l,p}$ が与えられたときの軌道 u を表す確率密度関数は $p(u|o_{t,p}, o_{l,p}, c_i)$ で表され、HMM によって学習される。

3.1.2 文法 G

発話 s は、トラジェクタを表す文節 W_T とランドマークを表す文節 W_L 、及び動作を表す文節 W_M からなる概念構造 $z = (W_T, W_L, W_M)$ と対応付けて解釈される。文法 G は、発話 s における構成要素 z の出現順序の生起確率分布と、それぞれの文節を構成する単語のバイグラムによって表される。

3.1.3 行動コンテキスト効果 $B_H(i, q; H)$

コンテキスト q の下で、オブジェクト o が発話による指示対象になる信念を表す。 q は、シーン中の各オブジェクトが、直前の行動に関わったか、現在把持されているか、の 2 つの情報からなる。この信念は 2 つのパラメータ $H = h_c, h_g$ で表され、 q に応じてどちらかのパラメータ値、または 0 を出力する。

3.1.4 動作-オブジェクト関係 $B_R(o_{t,f}, o_{l,f}, W_M; R)$

ある動作に対して使用されたトラジェクタ t とランドマーク l が、その動作に使用されるオブジェクトとして適切であるかを表す信念である。この信念はガウス分布で表され ($p(o_{t,f}, o_{l,f}|W_M; R)$)、 R はそのパラメータ集合を表す。

3.2 決定関数

発話 s と行動 $a = (t, u)$ の対応の適切さを表すために、決定関数 Ψ を定義する (式 1)。これは、3.1 節で述べた各信念の重み付け和で表される。重み $\Gamma = \{\gamma_1, \dots, \gamma_6\}$ は、各信念が人とロボット間で共有されていることに対するロボットの確信度 (個別確信度: Local Confidence Value) を表す。

$$\begin{aligned} \Psi(s, a, O, q, L, G, R, H, \Gamma) &= \max_{t,z} \left(\gamma_1 \log p(s|z; L, G) \right. \\ &+ \gamma_2 \log p(u|o_{t,p}, o_{t,p}, W_M; L) \\ &+ \gamma_3 (\log p(o_{t,f}|W_T; L) + \log p(o_{t,f}|W_L; L)) \\ &+ \gamma_4 \log p(o_{t,f}, o_{t,f}|W_M; R) \\ &+ \gamma_5 (B_H(t, q; h_g) + B_H(l, q; h_g)) \\ &+ \left. \gamma_6 (B_H(t, q; h_c) + B_H(l, q; h_c)) \right) \quad (1) \end{aligned}$$

ここで、 $\{\gamma_1, \dots, \gamma_6\}$ はそれぞれ、音声、動作、オブジェクト概念、動作-オブジェクト間の関係、行動コンテキスト効果 (把持オブジェクト)、行動コンテキスト効果 (直前操作オブジェクト) に対する個別確信度である。

3.3 全体確信度関数

対話者間での共有信念の一致度を表すために、本稿では、全体確信度関数 (Global Confidence Function) $f(x)$ を提案する。全体確信度関数は、人あるいはロボットの発話が対話者に正しく理解される確率の推定値を出力するもので、次式で表される。

$$f(x) = \frac{1}{\pi} \arctan\left(\frac{x - \lambda_1}{\lambda_2}\right) + 0.5 \quad (2)$$

ここで、 λ_1, λ_2 は関数 $f(x)$ を表すパラメータである。この関数の入力 x として、情景 O とコンテキスト q の下で行動 a を表す発話 s を決定する際の、決定関数 Ψ の値のマージンを定義し、用いることとする (式 3)。

$$d(s, a, O, q) \equiv \Psi(s, a, O, q) - \max_{A \neq a} \Psi(s, A, O, q) \quad (3)$$

全体確信度関数は、マージン d が大きいほど、発話 s が正しく理解される確率が高くなることを前提としている。もし d が小さくても高い確率で正しく理解されるならば、発話者が想定する共有信念が、対話者のそれとよく一致していることを意味する。図 2 に $f(x)$ の形の例を示す。この図において、Strong で表されている曲線は共有信念がよく一致している状態を、Weak で表されている曲線はあまり一致していない状態を表している。

4. 全体確信度関数を用いた発話生成及び更新アルゴリズム

全体確信度関数 $f(x)$ が学習されると、発話の理解率が予測できるようになり、対話者との共有信念の一致度に応じた発話生成を行うことができる。また、発話を制御することにより信念の共有を促進させることが可能である。この章では、全体確信度関数による発話生成手法及び全体確信度関数の更新手法について述べる。




図 2 全体確信度関数 $f(x)$ の形の例

Fig. 2 Examples of shapes of Global Confidence Function.

表 1 単語数ごとの生成文の例

Table 1 Example of generated utterances and margins.

| word num | example | margin d |
|----------|-----------------|----------|
| 1 | のせて | 3.22 |
| 2 | 黄色いのせて | 8.75 |
| 3 | 黄色い緑のせて | 22.79 |
| 4 | パーパズー 緑箱 のせて | 32.04 |
| 5 | パーパズー 小さい緑箱 のせて | 36.92 |

4.1 全体確信度関数を用いた発話生成アルゴリズム

ロボットは、発話が相手に理解される確率の目標値 ξ と $f(d(s, a))$ の差が最小となる発話を選択する (式 4)。

$$\tilde{s} = \underset{s}{\operatorname{argmin}} \left| f(d(s, a)) - \xi \right| \quad (4)$$

具体的には、以下のアルゴリズムに従って発話が生成・決定される。なお、本アルゴリズムでは発話に使用する単語数は動詞を含めて 5 単語までとした。

[発話生成アルゴリズム]

- (1) シーン O を取得し、人に行わせる行動 a と使用するオブジェクト t, l を決定する
- (2) 発話の理解率の目標値 ξ を決定する
- (3) 使用するオブジェクトを表す単語を決定する
- (4) 決定した単語で、可能な組み合わせの文を全文生成する
- (5) 生成した全文でマージン d を計算する (式 3)
- (6) 単語数が等しい文ごとに d が最大のものを候補とする
- (7) それぞれの文の予測理解率 $f(d)$ を計算する (式 2)
- (8) 式 4 により、候補の文から発話 s を決定する

表 1 に、図 1 (b) に対して生成された発話文の例を示す。単語数が増加するにつれて、マージン d の値が大きくなる。

4.2 全体確信度関数の更新アルゴリズム

全体確信度関数 $f(x)$ は、様々なエピソードを繰り返すことでオンラインで学習される。各エピソードにおいて、発話生成に用いたマージン d の値に対して、その発話が対話者に正しく理解されたかどうかの情報 e が対応付けられ、これを学習サンプルとする。 e は、対話者が発話を正しく理解し意図された行動を取ったときには 1 を、誤ったときには 0 をとる。 n 番目のエピソードによる、 $f(x)$ の最適パラメータ $\tilde{\lambda}_{1,n}, \tilde{\lambda}_{2,n}$ の計算には、重み付きの最小二乗法を用いる (式 5)。ここで算出された最適パラメータを式 6 に当てはめることにより、パラメータの更新を行う。

Level1: 緑 箱 / 青い 箱 / とびこえさせて
 青い 箱 / カーミット / ちかづけて
 Level2: 黄色い / あげて
 パーパブライト / 箱 / のせて
 Level3: パーパズー / はなして
 さげて

図3 個別確信度の学習に使用した難易度の異なる発話の例
 Fig.3 Examples of utterances in some level interactions.

$$[\tilde{\lambda}_{1,n}, \tilde{\lambda}_{2,n}] = \underset{\lambda_{1,2}}{\operatorname{argmin}} \sum_{i=n-K}^n w_{n-i} (f(d_i; \lambda_1, \lambda_2) - e_i)^2 \quad (5)$$

$$[\lambda_{1,n}, \lambda_{2,n}] \leftarrow (1 - \delta) [\lambda_{1,n-1}, \lambda_{2,n-1}] + \delta [\tilde{\lambda}_{1,n}, \tilde{\lambda}_{2,n}] \quad (6)$$

ここで、 K は学習に使用する直近のサンプル数を表し、 w_{n-i} はそれぞれの学習サンプルに対する重みを表す。また、 δ は学習速度を決める値 (学習率) である。

具体的には、以下のアルゴリズムに従って学習される。

[全体確信度関数の更新アルゴリズム]

- (1) 話し手が聞き手に、オブジェクトを動かすことを表す発話を行う
- (2) 聞き手が発話を解釈し、そのとおりに行動する
- (3) 話し手が、聞き手の行動が正しいかどうかを判断する
- (4) 学習サンプル (d_n, e_n) を取得する
- (5) 式5から、最適なパラメータ $\tilde{\lambda}_{1,n}, \tilde{\lambda}_{2,n}$ を計算する
- (6) 式6によってパラメータを更新する

この更新アルゴリズムを、学習サンプルを取得するたびに実行し、全体確信度関数 $f(x)$ を更新する。

5. 決定関数及び全体確信度関数の学習実験

提案手法を評価するために、全体確信度関数 $f(x)$ の学習実験を行った。実験において、学習率 δ は0.25で固定とし、学習サンプル数 K は20とした。また、最小二乗法の重みは三角窓を使用し、直近のサンプルほど大きな重みとなるようにした。学習は64エピソードを通して行われ、これを1シナリオとした。

実験は、様々な条件で行われた。5.1節ではまず、実験に使用した2つのモデルについて述べる。5.2節では、全体確信度関数の学習の有効性を検証した実験について述べ、5.3節では、発話の理解率の目標値 ξ を3種類に変更した実験について述べる。5.2節と5.3節の実験では、各エピソードで人が行動を誤った場合でも正しい行動は提示されないこととした。そして5.4節では、誤ったときに正解を提示した実験について述べる。

5.1 実験に使用した2つのモデル

全体確信度関数の学習実験のためにまず、決定関数における個別確信度の値が異なる2つのモデルを用意した。個別確信度の学習は、人がロボットに対して発話によって行動を指示し、ロボットがその発話に従ってオブジェクトを動かすといったインタラクションを通じてオンラインで行った。

インタラクションは3段階の難易度 (Level1・2・3) で行い、難易度が高くなるにつれて発話時の単語の省略を増やした曖昧な発話を行った。図3に、それぞれの難易度の発話の例を示す。Level2では行動コンテキスト効果を、Level3では動作-オ

表2 2つのモデルの個別確信度 Γ の値
 Table 2 Local Confidence Values of two models.

| Local Confidence | modelA | modelB |
|---|--------|--------|
| speech (γ_1) | 1.000 | 1.000 |
| motion (γ_2) | 1.027 | 0.683 |
| static images of objects (γ_3) | 0.753 | 0.877 |
| motion-object relationship (γ_4) | 0.555 | 0.003 |
| behavioral context (Held) (γ_5) | 1.876 | 2.492 |
| behavioral context (Prev. Moved) (γ_6) | 1.498 | 1.954 |

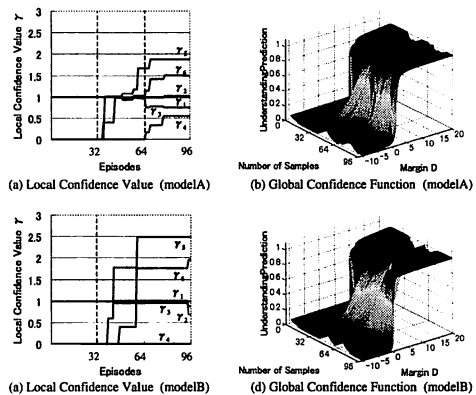


図4 2つのモデルの個別確信度の値と全体確信度関数の形状の変化
 Fig.4 Change in the Local Confidence Values and the Global Confidence Function of model A and B.

ブジェクト関係を共有信念とした発話を行った。実験者Aがロボットと、Level1・2・3の順に32エピソードずつインタラクションを行い、個別確信度を学習させた。これをモデルAとした。また、実験者Bが、Level1を32エピソード行った後、Level2を64エピソード行い、個別確信度を学習させた。これをモデルBとした。また、インタラクション中の人の発話からマージン d を計算し、人の発話を正しく理解できたかという情報を用いて、個別確信度の学習と同時に全体確信度関数も学習させた。

表2がそれぞれのモデルが学習した個別確信度の値である。また図4は、それぞれの個別確信度の値の変化と全体確信度関数の形状の変化を表した図である。以降の実験では、個別確信度の学習終了時の全体確信度関数の形を初期形状とした。上記の2つのモデルを用いて、全体確信度関数の学習実験を行った。

5.2 全体確信度関数の学習の有効性を検証した実験

対話者間では常に信念に差異が生じていると考えられるが、全体確信度関数を用いることで、対話者間での信念の一致度を推定することができる。一致度が低ければ、より詳しい発話を行うことで意味を正しく伝達することができる。逆に高い一致度の場合には曖昧な発話でも意味を伝達可能であり、さらにその曖昧な発話によってより詳細な信念の差を推測して、以降のインタラクションに反映させることができる。したがってこの実験では、1シナリオ中に全体確信度関数を学習する場合と学習しなかった場合の実験を行い、マージン d の平均と発話単語




図5 全体確信度関数の形状の変化 ($\xi = 0.75$)

Fig. 5 Change of shape of Global Confidence Functions ($\xi = 0.75$).

表3 全体確信度関数の学習あり/なしの結果 ($\xi = 0.75$)

Table 3 Results with learning and w/o learning of Global Confidence Function of two models. ($\xi = 0.75$)

| | modelA-subjectB | | modelB-subjectA | |
|-----------------------------|-----------------|-------|-----------------|-------|
| | yes | no | yes | no |
| with learning | yes | no | yes | no |
| margin d (*) | 27.83 | 21.75 | 30.86 | 21.43 |
| utterance word number (*) | 1.64 | 1.03 | 1.89 | 1.38 |
| UnderstandingPrediction (*) | 91.12 | 94.94 | 88.49 | 96.00 |
| accuracy rate | 81.25 | 73.44 | 90.63 | 87.50 |

(*average of 64 episodes)

数の平均、及び正解率を比較検討した。実験は、モデル A-実験者 A, モデル A-実験者 B, モデル B-実験者 A, モデル B-実験者 B の 4 パターンが行われた。発話の理解率の目標値 ξ は 0.75 とした。

実験結果は図 5, 表 3 のとおりである。表 3 において発話単語数の平均は、動詞を除いた単語数で算出した。図を見ると、対話者の行動の正否によって全体確信度関数が更新されている様子がわかる。しかし、図 5 (a) (d) のように、モデルを学習させた者が全体確信度関数の追加学習も行った場合、既に一致度が十分に高いことから、シナリオを通して変化があまり生じなかった。これに対して、図 5 (b) (c) のようにモデル学習者と実験者が異なる場合には、グラフが大きく変化した。また、モデル学習者と実験者が異なるときに、全体確信度関数を学習した場合としなかった場合では、学習した場合は正解率が上昇すると共に、正解率と予測理解率との差も小さくなった。これは、全体確信度関数を学習することにより、相手との信念の一致度に応じた発話を行ったためであると考えられる。これに対して、全体確信度関数を学習しなかった場合には、ロボットは対話者との共有信念の一致度を推定しないので、曖昧な発話を行い続けた結果、ロボットの予測理解率と実際の人の正解率の差が大きくなった。この実験の結果から、ロボットと人のインタラクションにおいて、全体確信度関数を学習することで対話者との信念の一致度を推定して発話単語数を制御し、予測理

表 4 3 種類の ξ での学習結果 (モデル A-実験者 B)

Table 4 Result of learnings in three values of ξ . (modelA-subjectB)

| utterance difficulty (ξ) | 0.50 | 0.75 | 0.95 |
|------------------------------------|-------|-------|-------|
| average of margin d | 9.91 | 27.83 | 21.57 |
| average of utterance word num | 1.13 | 1.64 | 1.78 |
| average of UnderstandingPrediction | 63.63 | 91.12 | 96.98 |
| accuracy rate | 65.63 | 81.25 | 92.19 |

表 5 3 種類の ξ での学習結果 (モデル B-実験者 A)

Table 5 Result of learnings in three values of ξ . (modelB-subjectA)

| utterance difficulty (ξ) | 0.50 | 0.75 | 0.95 |
|------------------------------------|-------|-------|-------|
| average of margin d | 11.83 | 30.86 | 22.44 |
| average of utterance word num | 1.13 | 1.89 | 2.08 |
| average of UnderstandingPrediction | 76.87 | 88.49 | 98.11 |
| accuracy rate | 81.25 | 90.63 | 96.88 |

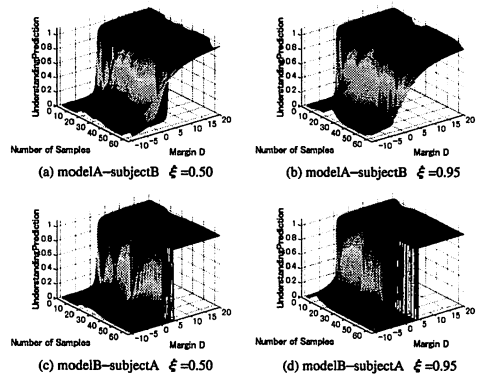


図 6 全体確信度関数の形状の変化 ($\xi = 0.5, 0.95$)

Fig. 6 Change of shape of Global Confidence Functions. ($\xi = 0.5, 0.95$)

解率と正解率の差を縮めることができることが示された。

5.3 発話の難易度パラメータを 3 種類に変更した実験

タスクにおいて発話する文の曖昧さは、式 4 のように発話の理解率の目標値 ξ によって決定される。前節の実験では ξ を 0.75 として実験を行ったが、この値が全体確信度関数の学習にとって適切な値かどうかを判断するために、この実験では 3 種類の ξ (0.5, 0.75, 0.95) で学習を行った。モデルと実験者の組み合わせは前節の実験と同様とし、シナリオは ξ ごとに異なるものを使用した。マージン d の平均と発話単語数の平均、及び正解率を比較検討した。

実験結果は表 4, 5 のとおりである。どちらの表でも、 ξ の値を大きくするにつれて発話単語数が増加している。また、図 6 は、 $\xi = 0.5, 0.95$ の場合の全体確信度関数の変化を表したものである (0.75 は図 5 を参照)。表を見ると、どちらのモデルでも、 $\xi = 0.95$ では高い正解率が得られているが、これは発話の理解率の目標値を高く設定したことで、発話があまり省略され

表 6 誤ったときに正解の提示あり／なしの実験結果

Table 6 Result of learning with answer and w/o answer.

| | modelA-subjectB | | modelB-subjectA | |
|-----------------------------|-----------------|-------|-----------------|-------|
| | yes | no | yes | no |
| present correct answer | yes | no | yes | no |
| margin d (*) | 22.17 | 27.83 | 23.56 | 30.86 |
| utterance word number (*) | 1.28 | 1.64 | 1.56 | 1.89 |
| UnderstandingPrediction (*) | 88.42 | 91.12 | 92.24 | 88.49 |
| accuracy rate | 84.36 | 81.25 | 95.31 | 90.63 |

(*average of 64 Episodes)

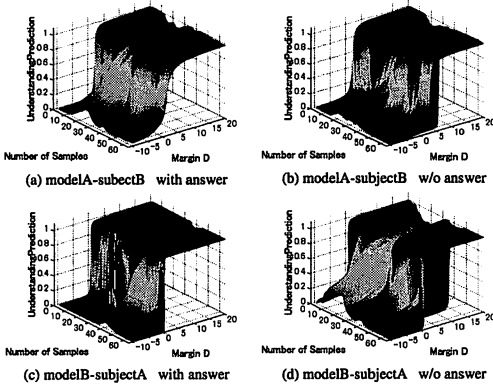


図 7 正解の提示あり／なしの場合の全体確信度関数の形状の変化
Fig.7 Results of learning of Global Confidence Function with answer and w/o answer.

なかったためであると考えられる。また、 $\xi = 0.50$ では、2つのモデルで発話単語数が等しくなっており、モデル A の動作-オブジェクト関係の信念が用いられていないにもかかわらず、単語が省略されているため、正解率が大きく低下していると考えられる。曖昧な発話が十分に行われないまたは発話が曖昧になりすぎると、信念の一致度の推定に際して好ましくないため、本研究における難易度パラメータ ξ の値は、0.75 が望ましいと考えられる。

5.4 正解を提示する実験

人同士のコミュニケーションでは通常、発話が誤って解釈された場合には訂正がなされ、話し手だけでなく聞き手も話し手の信念を推定できる。したがってこの節では、ロボットの発話に対し実験者が誤って行動した場合には正解の行動が提示されるようにし、実験者もロボットの信念を学習した実験について述べる。モデルと実験者の組み合わせは前述の実験と同様とし、 ξ は 0.75 とした。シナリオは前述の実験の、 $\xi = 0.75$ と同じものが用いられた。マージン d の平均と発話単語数の平均、及び正解率を、正解が提示されない場合の結果と比較検討した。

実験結果は表 6 及び図 7 のとおりである。どちらの組み合わせでも、正解を提示された学習では d の平均が小さくなり、正解率は高くなった。特に、実験者 B はモデル A がどのような動作-オブジェクト関係の信念を学習しているかは知らされなかったが、正解が提示されることによりロボットの信念を推測した結果、予想理解率と正解率の差が大きく縮まった。以上のことから、全体確信度関数の学習において正解が提示されることによって、人間がロボットの信念に適応できることが示された。

6. 考 察

実験の結果は、この計算機構が比較的少ないサンプルで学習を行えることを示している。ロボットが実際に日常生活を支援する身近な存在になったときに、少ないサンプルで信念の一致度を推定できることが重要となるため、この点においても全体確信度関数の有効性が見て取れる。

全ての実験で、発話の予測率の目標値 ξ を、実際に発話に用いられたマージン d から計算される予測理解率の平均値が上回っている。これは、全体確信度関数を学習したことで、共有信念の一致度を推定し正しく意味が伝わる発話と伝わらない発話が明確に判断できるようになり、タスク達成のためにより適切な発話を選択できたことを意味している。

本稿ではタスクとして、実時間で人とロボットのオブジェクトを用いたインタラクションを扱ったが、あらかじめ学習させる単語数やエピソードの複雑さなどの点においては、比較的簡単なタスクであったと考えられる。今後は、エピソード自体をより複雑にするなどして実験を行い、提案手法を検討する必要がある。

7. ま と め

本稿では、ロボットが人との信念の一致度に応じて適切なコミュニケーションを行うための、発話生成手法を提案した。発話の生成には、対話者間の信念の一致度を表す関数として全体確信度関数を提案し、インタラクションを通じて、全体確信度関数の学習をオンラインで行った。また、学習条件を様々に変更することで学習アルゴリズムを評価した。その結果、全体確信度関数を学習することで、人とロボットの信念の一致度に応じて発話理解率を推定・制御し、信念の共有を促進することが可能であることが示された。また、正しい行動が提示されることによって、相互に信念を一致させることができることも示された。今後、ロボットの持つ信念や扱うタスクを複雑にするなどして、提案手法をさらに評価する必要がある。

謝辞

本研究は、立石科学技術振興財団による助成（登録番号 1081004）、及び、科学研究費補助金 基盤研究 C 課題番号 20500239 の助成を受けて実施した。本研究において多大なる助力を頂いた、今木理英氏に心より感謝いたします。

文 献

- [1] Iwahashi, N., "Robots That Learn Language: A Developmental Approach to Situated Human-Robot Conversations", In Sankar, N. ed. Human-Robot Interaction, pp.95-118, I-Tech Education and Publishing, 2007.
- [2] 山肩洋子, 河原達也, 奥乃博, 美濃尊彦, "音声対話システムにおける物体指示のための信念ネットワークを用いた曖昧性の解消", 人工知能学会論文誌, Vol.19, No.1, pp.47-56, 2004.
- [3] 乾健太郎, 徳永健伸, 田中穂積, "確率的制約のもとづく発話プランニング", 情報処理学会研究報告, Vol.94, No.77, pp.25-32, 1994.