

対話エージェントにおける不明確性を含む動作表現のモデル化の検討

橘 誠† 川島 啓吾† 小林 隆夫†

† 東京工業大学 大学院総合理工学研究科 物理情報システム専攻

〒 226-8502 横浜市緑区長津田町 4259-G2-4

E-mail: †{makoto.tachibana,takao.kobayashi}@ip.titech.ac.jp

あらまし 本論文では、対話システムにおいて不明確性を含んだ動作表現を状況に応じて適切に解釈するために、統計的な手法により動作表現をモデル化することを検討する。まず、不明確性を含んだ動作表現を収集し、言語情報と対応する動作や環境情報をデータベースに蓄積する。これらに対し、ノードの分割条件に言語表現に関する質問を用いた決定木を自動構築し、動作表現の統計的なモデル化を行う。また、動作表現モデルの評価を行い、人間同士の対話とほぼ同等の結果を得られることを示す。さらに、得られたモデルに対し強化学習を行うことで、モデルの改善や未知語への対応を行う。

キーワード マルチモーダル対話システム, 不明確性, 統計モデル, 決定木, 強化学習

A Study on Modeling Technique for Vague Expressions of Human Motion in Spoken Dialogue Agents

Makoto TACHIBANA†, Keigo KAWASHIMA†, and Takao KOBAYASHI†

† Interdisciplinary Graduate School of Science and Engineering, Tokyo Institute of Technology,

4259-G2-4, Nagatsuta-cho, Midori-ku, Yokohama-shi, 226-8502, Japan

E-mail: †{makoto.tachibana,takao.kobayashi}@ip.titech.ac.jp

Abstract This paper describes a statistical modeling technique for appropriately interpreting vague expressions that are appeared in human-computer interaction with spoken dialogue agents. Through human-human interactions, we collect many examples of human motion and their environments that are related to command words including vague expressions. In the statistical modeling of the vague expressions, the distributions which do not have enough training data are shared using decision-tree based context clustering technique. From experimental results, we show that the performance of the human-computer interaction using the proposed model is very similar to that of the human-human interaction. Furthermore, we apply reinforced learning to improve the model and respond to unknown command words.

Key words spoken dialogue agents, vague expressions, statistical model, decision tree, reinforced learning

1. はじめに

近年、自然言語処理や音声情報処理などの技術の発展に伴い、音声インタフェースやマルチモーダルインタフェースの研究・開発が盛んに行われている。その中でも、対話システムへの応用は機械を人間にとって使いやすいために期待されている技術の一つである。

本研究では対話システムとして、ユーザによって発話(入力)された自然言語による指示/要求を適切に解釈し、音声や画像、文字により応対するやり取りを繰り返して何らかの目標を達成するシステム [1] を考える。このような対話システムでは、人

間(ユーザ)がエージェントに対して、人間同士の対話と同様の自然で直観的な指示・要求を行えることが望ましく、様々な言語表現への応対が必要となる。例えば、「ペットボトルに1.5リットル水を注いで」や「地図を20%拡大して」といった指示は、「1.5リットル」・「20%」に関する知識さえあれば、応対することができ、エージェントの動作を一意に決定することができる。一方、「ペットボトルにもっと水を注いで」や「地図をもう少し拡大して」などの指示における、「もっと」、「もう少し」といった言葉は、ユーザや対話の流れやタスクなどによって意味が異なってしまう。しかしながら、これまでに報告されているシステムの一つ [2] では、「ちょっと」や「もっと」をある一定




図1 データ収集用ウィンドウ (左:ユーザー用 右:エージェント用)

Fig.1 Windows for data collection (left: for user, right: for agent).

の値に設定し、エージェントはある決まった動作しか生成していない。

このような「少し」「非常に」といった表現を定量的に扱う方法として、ファジィ論理に基づくロボットの制御手法が実用化されているが(例えば文献[3])、ユーザや状況に応じた様々な不明確性を含む動作表現に対応できるファジィルールを自動的に作成することは容易ではないと考えられる。また、状況に応じた不明確性を含む行動命令をインタラクティブな学習によって解消する手法[4]も提案されているが、対象とする命令は「ちょっと」、「ほんのちょっと」などに限定されている。

それに対し、ユーザや状況を考慮し不明確性を含む動作表現をモデル化した先行研究[5]では、状況を表現するための決定木と統計的な確率分布を利用することで、各ユーザや状況に適した移動量の算出を可能とした。しかし、決定木は常にヒューリスティックに定められた単一の形状を用い、他のタスクへの応用が容易ではないエージェントとなっていた。

そこで本研究では、動作表現モデルのための決定木を言語情報および状況に関する分割条件を用いたクラスタリングにより自動構築することを検討する。また提案手法により学習された動作表現モデルを持つエージェントと人間とのシミュレーションにより、その有効性を評価する。さらに、強化学習を用いた対話を通してのモデルの改善についても検討を行う。

2. 不明確性を含む動作表現のモデル化

2.1 対象タスク

本研究では、不明確性を含む動作表現が得られる一例として、文献[6]と同様にユーザの音声を用いた指示に従って、コンピュータ上のエージェントがユーザの所望する位置に箱を移動させるタスクを考える。まず、学習用データとして不明確性を含む動作表現を収集するために、ユーザ(人間)がエージェント(人間)に箱をユーザの目的とする場所へ移動させるような指示を与え、その指示語及び移動量を収集した。なお、容易に指示内容に対応する移動量を得るために、2つのディスプレイ上のウィンドウ(図1)を用いた仮想的な環境での収集を行った。ユーザは箱の現在地(塗りつぶしの四角)と目的地(塗りつぶしなしの四角)が表示されたウィンドウを見ながらエージェントに対して、箱を目的地に到達できるような指示を口頭で行う。エージェントは箱の現在地のみが表示されたウィンドウを見ながら、ユーザの指示に従ってマウスで箱の位置を移動させる。ユーザが指示を開始してから箱を目的地まで移動させ

るまでを1試行とし、一回の指示毎に箱の位置情報、指示内容、のべ指示回数を収集した。また、収集したデータに対し、それぞれ以下の移動量の値を求めた。

- 相対値(移動量) 前回の移動量と今回の移動量の比
- 相対値(上限) 箱が机の領域を超えない移動量の上限値と今回の移動量との比
- 絶対値 前回の移動量と今回の移動量の差分

2.2 確率分布を用いた移動量のモデル化

本研究では、箱の移動量に関する値を正規分布又は対数正規分布と仮定してモデル化する。

あるデータの分布を正規分布と仮定した場合、確率密度関数は以下の式となる。

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp - \frac{(x-\mu)^2}{2\sigma^2} \quad (1)$$

ここでパラメータ μ , σ^2 の最尤推定値は、観測データ $\{x_1, x_2, \dots, x_n\}$ からそれぞれ以下の式により得られる。

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (2)$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \quad (3)$$

このときの観測データに対する分布の対数尤度は以下で与えられる。

$$\mathcal{L} = \log(2\pi\sigma^2)^{-\frac{n}{2}} + \left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right) \quad (4)$$

また、分布を対数正規分布と仮定した場合、確率密度関数は

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma x} \exp - \frac{(\log x - \mu)^2}{2\sigma^2} \quad (5)$$

となり、 μ , σ^2 の最尤推定値は、観測データからそれぞれ以下の式により得られる。

$$\mu = \frac{1}{n} \sum_{i=1}^n \log x_i \quad (6)$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (\log x_i - \mu)^2 \quad (7)$$

このときの観測データに対する分布の対数尤度は以下となる。

$$\mathcal{L} = \log(2\pi\sigma^2)^{-\frac{n}{2}} + \left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (\log x_i - \mu)^2\right) + \sum_{i=1}^n \log \frac{1}{x_i} \quad (8)$$

どちらの分布を用いるかは、得られたデータに対し正規分布に当てはめた場合の尤度と対数正規分布に当てはめた場合の尤度を求め、尤度の高い分布を用いることとする。図2に、指示「少し」の移動量の絶対値と出現回数のヒストグラムを示す。このデータに各分布を当てはめると、対数尤度は正規分布で-462.5、対数正規分布で-460.6となるため、対数正規分布を用いる。図中の点線は対数正規分布を当てはめた場合の分布である。




図2 指示“少し”の絶対値の出現回数のヒストグラム

Fig. 2 A histogram of absolute values for a vague expression “a little.”

表1 収集データに現われた不明確性を含む表現例

Table 1 Vague expression examples appeared in the collected data.

わずかに、ちよっぴり、ちよい、少し、ちよつと、やや、
まあまあ、けっこう、だいぶ、かなり、もっと、まだまだ、
少しだけ、ちよつとだけ、もうちよい、もう少し、あと少し、他

2.3 決定木に基づいた動作表現のクラスタリング

現実中出现しうる全ての動作表現に対して、モデル化を行うための十分な学習データを得ることは容易ではない。そこで、コンテキストに基づいたクラスタリングを行って決定木を自動構築し、学習データが十分に得られない動作表現は言葉の意味が近い動作表現と分布を共有する。

通常、人間が机上の箱の移動を指示する言葉は、“右端”などの机の上の位置を示す言語、“もう少しだけ”のような移動量の調整に関わる言語、“右奥”のような方向を示す言語に大別出来る。これらの言語において、不明確性を伴うと考えられる言語は移動量の調整に関わる言語である。表1にデータベースに出現した移動量の調整に関わる言語の一部を示す。様々な表現が用いられているが、本研究ではよりクラスタリングを行いやすくするために、さらに調整語を以下のように細分化する。

- 副詞部 程度を表す副詞やそれらと同等な言葉 (例：“少し”、“もっと”)
- 前置修飾部 副詞部に前置し、意味を付加する副詞や連体詞やそれらと同等な言葉 (例：“ほんの”、“もう”)
- 副助詞部 副詞部に後置し、意味を限定する副助詞やそれらと同等な言葉 (例：“だけ”、“ばかり”)

この分類をもとに、ユーザ及びエージェントのおかれている状況を記述した情報(コンテキスト情報)として言語情報とそれに対応する移動量、時間情報を与えた。コンテキストは現在の指示内容、前回の指示内容、移動量、のべ指示回数としている。コンテキスト中の指示内容は

【机上の位置、前置修飾部、副詞部、副助詞部、方向】

で表現し、該当する情報がない場合は“x”とする。以下に、データベースに出現する指示内容とコンテキスト例を挙げる。

- (1) 指示内容: 「箱を机の真ん中より少し上に置いて」
コンテキスト: [真ん中, x, 少し, x, 上],
[x, x, x, x, x], 移動量, 1




図3 コンテキストクラスタリングの例

Fig. 3 An example of context clustering.

- (2) 指示内容: 「もっと右上に置いて」

コンテキスト: [x, x, もっと, x, 右上],

[真ん中, x, 少し, x, 上], 移動量, 2

- (3) 指示内容: 「あとちよつとだけ左上」

コンテキスト: [x, あと, ちよつと, だけ, 左上],

[x, x, もっと, x, 右上], 移動量, 3

クラスタリングはコンテキストの時間情報・言語情報に関する条件文を用いて行う。この条件文として、時間情報では「1回目の指示であるかどうか?」といった指示回数に関する条件文を用いた。言語情報としては「副詞部が“少し”または“ちよつと”である」、「副助詞部が“だけ”である」などのデータベース上の各コンテキストにおける様々な言語の組合せを考慮した条件文を用いた。なお、「副詞部が“少し”または“かなり”である」など言語の意味が遠いもの同士が同じ分布を共有してしまう条件はあらかじめ除いている。さらに、「前回の指示内容に机上の位置を指定するものが含まれる」といった時間情報と言語情報を共に考慮した条件文も作成した。

コンテキストクラスタリング決定木は、ルートノードから順に、条件文の中から分割前から分割後への対数尤度の増加が最も大きい条件文を選択して分割を行い、トップダウンで構築する。図3にコンテキストクラスタリングの例を示す。また、似たようなコンテキスト同士を同じ分布で共有させるために、最小記述長 (MDL) 基準 [7] によって分割を停止する。

2.4 移動量の算出

決定木はデータ収集時に求めた相対値(移動量)、相対値(上限)、絶対値のそれぞれについて構築し、モデルから移動量を算出する際には、状況に応じて使用する決定木(移動量)を選択することとした。1回目の指示など前回の移動量がない場合には絶対値を用いた決定木を、それ以外は相対値(移動量)に関して構築された決定木を用いて移動量を算出した。例外的に、相対値(移動量)では、移動量が収束して動かなくなってしまう場合には絶対値を、また算出した移動量では机の領域を超えてしまう場合には相対値(上限)の決定木を用いた。なお決定木から移動量を算出する際には、現在のコンテキストに対応するリーフノードの分布のモードを用いている。

表 2 決定木のリーフノード数

Table 2 The numbers of leaf nodes of decision trees.

モデル	リーフノード数			コンテキスト数
	絶対値	相対値 (移動量)	相対値 (上限)	
A → F	6	4	4	51
B → F	14	6	10	89
C → F	9	6	7	31
D → F	11	7	7	71
E → F	7	7	6	57
D → A	8	5	6	86
F → C	15	7	10	87

3. 動作表現モデルの評価

3.1 動作表現データの収集

まず、エージェントが人間の場合において、7通りのユーザとエージェントの組合せでそれぞれ100試行のデータを収集し、モデルを構築した。表2に構築されたモデルの決定木のリーフノード数と学習データに現れた総コンテキスト数を示す。なお表中の“A → F”はユーザAがエージェントFに指示をして収集したデータの組合せを示している。

3.2 シミュレーションによるモデル評価

動作表現モデルの評価を図1のユーザ用ウィンドウと同様のインタフェースを用いたシミュレーションにより行った。評価は6名の人間のユーザ(A, B, C, D, F, G)と表2に示したモデルを持つ7種類のエージェント(コンピュータ)において、すべての組合せで行った。

シミュレーション10試行の平均指示回数を表3に示す。表中の()内にはそれぞれのモデルの学習データ収集時の最初の10試行の平均指示回数を示している。この結果より、各モデルとも概ね収集データの命令回数に近い結果となっていることがわかる。しかし一部のユーザとモデルの組合せにおいては、指示回数が多くなってしまっている。例えば、ユーザCにおいて“C → F”モデルの評価では2.9回とデータ収集時とほぼ同程度であるのに対し、“A → F”モデルではエージェントが同じFであるにも関わらず指示回数が5.5回と多くなっている。これは、データ収集時のユーザとエージェントの組合せによって使用されるコンテキストが異なってくるため、決定木の構造やリーフノードが持つ移動量が異なる動作表現モデルになっているためと考えられる。

なお、これらの評価結果は、木構造をヒューリスティックに構築した先行研究[5]と比較しても、概ね同程度にデータ収集時の指示回数に近づいていることが確認できた。

3.3 不特定ユーザモデルの評価

前節で示した通り、100試行の学習データを用いた動作表現モデルでは、モデル作成時のユーザとエージェントの組合せによって、ユーザの指示回数が多くなる場合があった。そこで、様々なユーザに対応するために、複数のユーザの組合せを学習に反映させた不特定ユーザモデルの評価を行った。エージェン

表 3 モデルの評価結果 (平均指示回数)

Table 3 Evaluation result (average number of directions).

ユーザ	モデル (ユーザ → エージェント)						
	A → F (2.7)	B → F (2.8)	C → F (2.8)	D → F (3.0)	E → F (3.5)	D → A (3.2)	F → C (2.9)
A	2.7	3.1	2.6	2.8	2.9	3.5	3.0
B	3.3	3.7	4.6	2.7	3.1	2.4	3.1
C	5.5	3.2	2.9	3.3	3.8	3.2	3.0
D	2.4	3.2	3.2	4.3	3.7	3.0	6.7
F	2.6	2.8	3.1	2.8	2.8	4.0	3.3
G	2.2	3.1	3.7	2.1	2.7	2.6	2.6

表 4 500 試行の学習データで構築した決定木のリーフノード数

Table 4 The numbers of leaf nodes of decision trees (500 trials).

モデル	リーフノード数			コンテキスト数
	絶対値	相対値 (移動量)	相対値 (上限)	
* → F	21	13	12	209
A → F	11	11	7	148

表 5 500 試行の学習モデルを用いた評価結果 (平均指示回数)

Table 5 Evaluation result for the models trained by 500 trials (average numbers of directions).

ユーザ	モデル (ユーザ → エージェント)	
	A → F (2.7)	* → F (3.0)
A	2.3	1.9
C	4.5	2.6
D	2.7	2.2
F	2.4	3.0
G	2.4	2.6

トFに対して5名のユーザ(A ~ E)が各々100試行の指示をしたデータをあわせて不特定ユーザモデル“* → F”を作成した。比較のため、“A → F”の組合せのみで500試行のデータを用いたモデルも作成した。表4に各モデルにおける決定木のリーフノード数を示す。表より、各モデルにおいてコンテキスト数が多いほどリーフノード数が多くなる傾向にあることがわかる。不特定ユーザモデルでは、表2の100試行の学習データを用いて作成したモデルに比べてデータ量が豊富になっているだけでなく、500試行の学習データを用いて作成した“A → F”と比べてもコンテキスト情報が豊富になっているため、リーフノード数が増えていることがわかる。

不特定ユーザモデル“* → F”を持つエージェントを用い、5名のユーザでシミュレーションを行った実験の10試行の平均指示回数を表5に示す。ユーザCの結果では、500試行のデータで学習した“A → F”モデルが平均試行回数が4.5回であるのに対し、不特定ユーザモデルでは2.6回に減少している。また不特定ユーザモデルは、特定ユーザのモデルを用いた場合(表3)に比べてユーザに依らず安定した結果が得られていることがわかる。これはモデルのリーフノード数が多く、より様々なコンテキストに対応できているためと考えられる。

表 6 各指示に対して設定した報酬値

Table 6 List of reward values for vague expressions.

副詞部

指示語	報酬
わずかに ちよびり ちよい 少し ちよつと 微妙に 気持ち	0
やや, まあまあ, わりと	-1
(なし)	-2
けっこう, だいぶ, かなり	-3
すごく, ものすごく, もっと, まだ, さらに	-4

前置修飾部

あとほんの, もう, あと	0
ほんの, 微妙に, 気持ち, やや, まあまあ, (なし)	-1
もっと, まだ, さらに	-2

副助詞部

だけ	0
(なし)	-1

4. 強化学習を利用したモデルの改善

実際の対話システムにおいては、ユーザに関するデータがあらかじめ存在するとは限らず、ユーザの個性が学習されたモデルと異なる場合に、ユーザの所望する動作を行うことが困難になる場合が考えられる。そこで、逐次学習の一つである強化学習 [8] を利用し、対話を通じた動作表現モデルの改善を検討する。

本研究の問題設定は、少ない回数で箱を目的地に移動させるのではなく、ユーザの指示に対する適切な移動量を求めることとし、強化学習の各要素を以下のように設定した。

- 状態 箱の位置およびそれに対して与えられた指示。
- 方策 与えられた状態からエージェントの行動 (箱の移動量) を得る。決定木におけるリーフノードに相当。
- 行動 箱の移動動作。
- 報酬関数 行動によって得られる状態の報酬。次の行動を得るための指示から当該状態の望ましさを推定し、報酬として得る。
- 価値関数 試行を通して得られる状態の価値。報酬を基に得る。

強化学習では、これらの要素のうち相互学習により改善することができる要素は、方策と価値関数である。まず、指示内容から行動に関する望ましさを得るために、収集データに登場した各語を表 6 のように分類し、その報酬を、前回の指示による移動量が望んだ移動量に近いと考えられる指示内容を報酬 0 として、遠いと考えられる指示内容ほど低い報酬が得られるように設定した。なお、この分類は、3.1 で構築された相対値 (移動量) に関する決定木においてクラスタ化されやすかった分類である。

価値関数は、毎回目標となる移動量が変化することを考慮し、該当の状態のみを考慮し報酬をそのまま状態の価値とし、 t 回目の指示における状態 s_t の価値 $V(s_t)$ は当該状態の報酬 $r(s_t)$ と等しいと考える。 t 回目の指示における方策 π_t は、価値 $V(s_t)$ を利用し式 (9) で更新する。

$$\hat{\pi}_t = \alpha \frac{1}{M} \frac{|V(s_{t+1})|}{W} (\pi'_{t+1} - \pi_t) + \pi_t \quad (9)$$

M は方策に関するデータ量、 W は報酬の幅である。 π_t は t から $t+1$ への移動量つまり実際の移動量を示し、 π'_{t+1} は t から $t+2$ への移動距離つまり状態 s_{t+2} における π_t の望ましい値を示しており、二つの差分にデータ量の重みと報酬を考慮して方策を改善する。また、 α は学習率に影響するステップサイズパラメータ、であり、本研究では 1 に設定している。

これらの設定から以下の手順で相互学習を行う。

- (1) 方策 π の初期化を行う (決定木を用いた動作表現のモデル化)。
- (2) 各リーフノードに出現するコンテキストと出現回数をリスト化 (M の算出)。
- (3) 各状態に対して繰り返し：
 - 状態 s_t のとき行動 a (方策 $\pi(s_t)$ で与えられる) を決める。未知語・未出コンテキストはリストに加え、決定木から適当な移動量や報酬を与える。
 - 行動 a を取り、報酬 $r(s_t)$ と次の状態 s_{t+1} を観測する。
 - 方策 $\pi(s_t)$ を更新する。
 - $t \leftarrow t+1$
- (4) s_t が終状態なら繰り返しを終了。

4.1 強化学習の評価

3.3 で用いた “A → F” 500 試行モデルを用い、ユーザ C によるシミュレーション実験を行った。また、以下の 3 手法を比較し学習への影響を評価した。

- 強化学習なし 強化学習を行わず、決定木により作成された動作表現モデルを用いる。
- 強化学習 (知識重視) M の値を利用することで、学習データの知識を利用して強化学習を行い、学習の収束を重視する。
- 強化学習 (学習重視) M の初期値を全て 1 として強化学習を行うことで、環境への適応を重視する。

強化学習を行わない場合には、モデル更新は行わないが、比較のために各状態における報酬を計算する。

表 7 にシミュレーションにおける平均指示回数及び指示回数の分散を示す。強化学習を行うことで 1 回近く平均指示回数が減っていることがわかる。また、強化学習を行わなかった場合には、試行回数が増えても指示回数が多くなることがあったのに対し、強化学習を行った場合には、概ね指示回数が収集データに近づいて安定しており分散も低くなっている。図 4 に各手法のシミュレーションにおける各試行毎の総報酬の推移を示す。強化学習なしでは頻りに低い報酬を示す試行があることから、このような試行ではユーザの意図する行動が得られなかったと考えられる。一方、強化学習を行った場合には、低い報酬になる試行が減少しており、その効果を確認できる。

5. 音声対話システム


本研究で作成した動作表現モデルを音声対話システムでの動作に反映させた。対話システムは擬人化音声対話エージェントツールキット galatea [9] をプラットフォームとして利用し、タ

表 7 強化学習の評価結果


Table 7 Evaluation result of reinforced learning.

学習	0-10	11-20	21-30	31-40	41-50
強化学習なし	3.1	2.0	5.8	3.5	2.5
強化学習 (知識重視)	4.0	3.9	2.9	2.2	3.2
強化学習 (学習重視)	3.7	3.0	3.0	3.9	2.5


51-60	61-70	71-80	81-90	91-100	1-100	分散
2.7	2.6	6.4	5.4	4.2	3.80	14.5
2.4	2.7	2.3	3.2	1.8	2.74	3.7
2.6	2.4	2.4	4.3	2.8	3.02	3.8



(a) 強化学習なし, 平均 -13.0, 分散 296.9



(b) 強化学習 (知識重視), 平均 -9.9, 分散 75.1



(c) 強化学習 (学習重視), 平均 -8.5, 分散 49.9

図 4 総報酬の推移

Fig. 4 Transition of total reward.

スク管理, 音声認識などを行っている。また動作生成に関しては, 重回帰 HMM に基づく動作生成 [10] を行い, 動作生成時に制御因子として箱の現在位置の座標と目的地までの移動量を指定すれば, モーションキャプチャデータに含まれていない様々な箱の位置と移動量の動作についても自然な移動動作を生成可能となっている。図 5 に本システムでの動作生成例を示す。この例では, 3 回の命令で箱をユーザの所望する目的地まで移動させている。

1. 右に置いて



2. もっと手前



3. あとちょっとだけ手前



図 5 動作生成例

Fig. 5 Examples of generated human motion.

6. むすび

対話システムにおいて, 不明確性を含んだ動作表現を状況に応じて適切に解釈するために, 統計的な手法により動作表現をモデル化することを検討した。シミュレーションの実験の結果, 実際の間人同士の対話と同等の結果を得ることができた。さらに, 強化学習によるモデルの改善を検討し, その効果を確認した。

今後の課題は, 未知語を考慮した決定木の構築の検討や, 他のタスクへの応用などが挙げられる。

文 献

- [1] 田中: “自然言語処理 – 基礎と応用 –”, 電子情報通信学会 (1999).
- [2] 八木, 多胡, 峯松, 広瀬: “エージェント対話システムにおける対話管理と応答生成”, 情報処理学会研究報告, 2003-SLP-47, pp. 65-70 (2003).
- [3] M. Sugeno, H. Winston, I. Hirano and S. Kotsu: “Intelligent control of an unmanned helicopter based on fuzzy logic”, Proc. of American Helicopter Society 51st. annual Forum, pp. 791-803 (1995).
- [4] 徳永, 徳永, 田中: “インタラクティブな学習によるロボットの行動命令に含まれる不明確性の解消”, 人工知能学会研究報告, SIG-SLUD-A303, pp. 1-6 (2004).
- [5] 山崎, 小林: “不明確性を含む動作表現によるロボットの行動制御の検討”, 2007 信学総大 情報・システムソサイエティ総合大会特別号, ISS-P-48, p. 66 (2006).
- [6] 古宮, 庭瀬, 小林: “あいまい表現入力可能な音声対話エージェントシステムの検討”, 2005 信学総大, D-12-60, p. 210 (2005).
- [7] K. Shinoda and T. Watanabe: “MDL-based context-dependent subword modeling for speech recognition”, the Journal of the Acoustical Society of Japan(E), 21, pp. 79-86 (2000).
- [8] R. S. Sutton and A. G. Barto: “強化学習”, 森北出版 (2000). 三上 貞芳 (訳) and 皆川雅章 (訳).
- [9] 嵯峨山他: “擬人化音声対話エージェントツールキット galatea”, 情報処理学会研究報告, 2003-SLP-45-10, pp. 57-64 (2003).
- [10] N. Niwase, J. Yamagishi and T. Kobayashi: “Human walking motion synthesis having desired pace and stride length based on HMM”, IEICE Trans. Inf. & Syst., E88-D, 11, pp. 2492-2499 (2005).