

文書検索システムにおける ベイズリスクに基づく対話戦略のオンライン学習

翠 輝久[†] 河原 達也[†]

[†] 京都大学 情報学研究科
〒 606-8501 京都市左京区吉田二本松町

あらまし 自然言語テキストで記述された文書を検索・提示する音声対話システムにおける対話戦略のオンライン学習を用いた最適化・適応手法を提案する。このようなシステムでは、音声認識結果の N-best 候補やコンテキスト情報を適切に利用することで、音声認識誤りや発話中の省略表現に対処できる可能性がある。また応答方法に関しても、確認の生成条件や情報の提示方法において、いくつかの選択肢が考えられる。本研究では、これらの生成可能な応答候補の中から最適なものを選択する過程を、情報提示の報酬と情報提示に直接関係しない時間に基づくペナルティを用いて定義されるベイズリスクを最小化する枠組みとして定式化を行う。本手法はオンライン学習により、音声認識率や検索の成功率に応じて適切に対話戦略を適応させることが可能である。観光情報の検索・提示を行うシステム「京都版ダイアログナビ」において対話戦略の学習・適応の実験を行った。評価の結果、ランダムに与えた初期値から最適なパラメータを獲得したり、システム環境の変化に対して対話戦略を適切に変化させられることを確認した。

キーワード 音声対話システム、対話制御、機械学習、ベイズリスク

Online Learning of Bayes Risk-based Dialogue Strategy for Document Retrieval Systems

Teruhisa MISU[†] and Tatsuya KAWAHARA[†]

[†] School of Informatics, Kyoto University,
Sakyo-ku, Kyoto 606-8501, Japan

Abstract We propose an efficient dialogue management and its learning method for an information navigation system based on a document knowledge base. It is expected that incorporation of appropriate N-best candidates of ASR and contextual information will improve the system performance. The system also has several choices in generating responses or confirmations. In this paper, this selection is optimized as minimization of Bayes risk based on reward for correct information presentation and penalty for redundant turns. The proposed strategy is adaptively tuned by online learning, considering the ASR performance and the success rate of retrieval. We have evaluated this strategy with our spoken dialogue system "Dialogue Navigator for Kyoto City", which also has question-answering capability. Effectiveness of the proposed framework is confirmed through an experiment with a large amount of utterances of real users.

Key words spoken dialogue system, dialogue management, machine learning, Bayes risk

1. はじめに

音声対話システムの研究対象は、関係データベースから Web のテキストや新聞記事などの一般的な文書へと広がりつつある [1], [2]。これらのシステムでは、ユーザ発話の音声認識結果と文書のマッチングが行われ、その精度が高いものが提示される。これまで我々は文書検索タスクを対象に、検索要求のみではなく、特定の情報・事実を求める質問応答機能を利用することで、インタラクティブな情報提示を行う対話システム「京都版ダイアログナビ」を構築してきた [3], [4]。

音声対話システムにおいて、円滑な音声対話を実現するためには、音声認識誤りに対する確認が不可欠である。しかし、不必要的確認はユーザに対してわずらわしいものであり、必要最小限の回数にとどめることができることから、従来より確認の効率化を行う対話制御に関する研究が行われてきた [5]~[7]。しかし、これらは基本的に、SQL コマンドを用いたデータベース検索タスクを対象として定式化が行われている。そのため、キーワードの定義が明確ではなく、音声認識結果中の全ての内容語がマッチングに用いられる文書検索タスクに対して、これらの手法をそのまま適用することは難しい。コールルーティングタスクを対象に対話制御の最適化を扱った研究 [8], [9] も行われているが、これらの手法を情報案内のような複雑な対話制御を行う必要があるタスクに適用することは困難である。例えば、我々の構築した「京都版ダイアログナビ」では、ユーザの発話に対して検索要求・質問の判定を行い、それぞれに対応した応答を生成する。NTCIR, TREC [10] などの質問応答タスクとは異なり、実際のユーザの発話には検索要求か質問のいずれであるか判断が困難な場合も多く、また入力される質問の全てに対して、必ず回答が存在するとも限らない。そのため、ユーザの発話が質問である可能性が高い場合でも、質問の回答のみを提示するのが最適な応答であるとは限らない。

我々はこれらの問題に対して、システムが生成可能な応答集合に対して、応答成功の際の報酬と冗長なターン数に基づくペイズリスクリスクを計算し、応答候補選択の最適化を行う手法を提案してきた [11]。しかし、この手法においては、大量の学習コーパスを用いて最適なパラメータを設定する必要があった。そこで本稿では、この手法を拡張したオンライン学習手法を提案する。提案する枠組みは、学習コーパスが収集できていない時点でのパラメータの最適化のみではなく、システムの利用環境の変化への適応にも用いることができる。

2. 情報検索システムにおける対話制御・応答生成

「京都版ダイアログナビ」は、音声入力による文書検索システムであり、質問応答機能を利用することで、単純な情報提示に加えて、ユーザの聞き逃しや関連情報に対する要求などに対処することができる。システムは、Wikipedia^(注1)の京都に關

U1 : 銀閣寺について教えてください。
S1 : 銀閣寺は京都市左京区にある東山文化を代表する臨済宗相国寺派の寺院です。
銀閣寺の歴史やみどころについて何か知りたいことはありますか？
U2 : いつ建てられましたか？
S2 : 銀閣寺の建立は1482年です。
U2 : じゃあ、庭園を説明して。
.....

図 1 「京都版ダイアログナビ」の対話例

する文書と京都市産業観光局が提供する京都情報データベース^(注2)を知識ベースとして、ユーザに京都の観光情報を提示する。このシステムにおける対話例を図 1 に示す。

2.1 解釈・応答生成において考慮する項目

我々は、このシステムを京都大学博物館の特別展示において、約3ヶ月間の運用を行った [4]。その結果、応答生成に際に以下の点を改良することにより、システムの性能の改善が得られる可能性があることがわかった。

(1) 音声認識の N-best 候補の利用

京都版ダイアログナビでは、音声認識の N-best 候補中の全ての単語を用いて検索クエリを作成している。しかし、ユーザが発話していない単語がクエリに含まれる可能性があり、その場合に検索性能の低下の原因となる。そのため、ユーザ発話の音声認識の N-best 候補から最適な候補を選択して検索を行うことがより望ましい [4]。

(2) コンテキスト情報の補完

一連の対話のコンテキストを考慮したマッチングを行うために、発話履歴中に含まれる単語を検索クエリに補完・追加している。しかし、この方法は、ユーザが話題を変えた場合に、直前の話題のコンテキストを引きずってしまい、誤った検索を行う可能性がある。そのため、発話内容に応じてコンテキストを利用するか判断することが望ましい。

(3) 確認・応答方法の決定

誤った内容の情報提示を避けるために音声認識やマッチングの精度が低い場合には、確認を行うことが望ましい。また、質問に対する回答抽出の確信度が低い場合には、質問の回答のみを提示するのではなく、文書全体を提示することが有効な場合もありうる。

我々は、ペイズリスクリスク最適化の枠組みの下でこれらの問題を統合的に扱い、最適な候補を選択・解釈し、応答生成を行う方法を提案した [11]。本稿では、この枠組みを拡張し、システムの運用を行いながら、音声認識率や検索の成功率を反映して、確認を生成する頻度を調整したり、質問の難易度の傾向に応じて、回答のみを提示するか文書全体を提示するかを自動で学習

(注1) : <http://ja.wikipedia.org/>

(注2) : <http://raku.city.kyoto.jp/sight.phml>

することを目指す。

2.2 応答候補の選択の概要

本研究で用いる対話制御は、検索クエリの生成方法や応答方法を変えることにより複数の応答候補を生成し、それらを比較・選択することにより実現される。

ここで、検索結果の文書 D を用いて生成する応答 $Act(D)$ は、以下の 3 つからなるものとする。一つ目は、文書の（確認なしでの）提示 $Pres(D)$ であり、文書 D を要約して応答を作成する。二つ目は文書 D を提示することに対する確認 $Conf(D)$ であり、文書のタイトルを基に「金閣寺でよろしいでしょうか？」のような確認を生成する。三つ目は、質問に対する回答の提示 $Ans(D)$ であり、文書 D を基に、ユーザの質問に対する回答を含む一文を提示する。

可能な応答候補に対して、それぞれ成功した場合の報酬と失敗した場合のペナルティ、及び成功する確率（＝信頼度により近似）に基づいて、ペイズリスクを定義し、これが最小になるものを選択する。

以上の手順の概要を以下にまとめる。また、処理の流れを図 2 に示す。

(1) ユーザの発話の音声認識結果の第 1・第 2・第 3 候補、第 1~3 候補をマージしたもの、それぞれにコンテキスト情報を加えたものの合計 8 個の検索クエリ $q_i (i = 1, \dots, 8)$ を作成する。

(2) 各クエリを用いて知識ベースの検索（マッチング）を行い、提示文書候補 D_i とその確信度 $P(D_i)$ を計算する。

(3) 検索された文書 D_i から、文書の提示 $Pres(D_i)$ 、確認 $Conf(D_i)$ 、質問の回答として提示 $Ans(D_i)$ の 3 種類の応答候補を作成する。

(4) 4(音声認識 N-best 候補)×2(コンテキスト情報の有無)×3(応答方法)+1(リジェクト)=25 の候補に対して、それぞれペイズリスクを計算し、これが最小となるものを選択してユーザに提示する。

3. 応答候補の生成方法

3.1 ベクトル空間モデルによる知識ベースの検索

ユーザの発話と知識ベース中の文書との類似度を計算するために、単語ベースのベクトル空間モデルを採用する。

ユーザ発話から作成する検索クエリベクトル q は、音声認識結果中の名詞に対して音声認識の信頼度で重み付けして作成する。コンテキスト情報を含むクエリは、現在のトピックに関する履歴中のユーザの発話中に含まれる単語も使用する。

知識ベースの文書も同様に、節を単位として、含まれる名詞に対して、タイトルに重み付けをした出現回数に基づく文書ベクトルを作成する。

以上の手順で作成したクエリベクトル q と、文書ベクトル D を用いて内積類似度 $Product(q, D)$ を計算する。この類似度が最大の文書 D_i をベクトル q による検索結果とする。類似度を

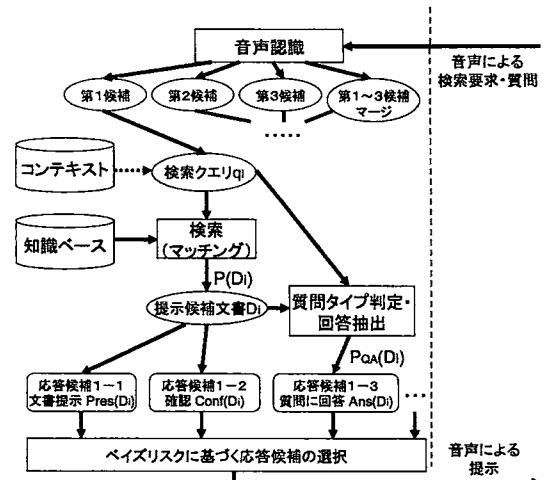


図 2 ベイズリスクに基づく応答候補選択の概要

(0~1 の値である) の確信度 $P(D)$ に変換するには以下のシグモイド関数を用いる。

$$P(D) = \frac{1}{1 + \alpha * \exp\{-1 * (Product(q, D) - \beta)\}}$$

ここで、 α 、 β は定数であり、 $\alpha = 2.2, \beta = 3.2$ とした。

3.2 検索要求に対する応答の生成

検索された文書の提示応答 $Pres(D)$ は、文書 D の概要の提示を行うものである。ユーザの理解のしやすさを考慮して、文書中での文の出現位置と文間のつながりを手がかりに、重要文抽出による要約を行い、その結果を読み上げる。

また、確認 $Conf(D)$ は、文書のタイトルや見出しを利用して、「金閣寺でよろしいでしょうか？」のような応答文を生成する。

3.3 質問に対する回答の生成

質問に対する回答 $Ans(D)$ の生成は、質問タイプの判定と回答抽出の 2 つのプロセスからなる。

ユーザ発話の質問タイプの判定には、人手によるヒューリスティックなルールを用いる。たとえば、認識結果中に「誰ですか」という表現が含まれる場合には、人名をたずねる質問であると判定し、「いくらですか」という表現が含まれる場合には、金額をたずねる質問であると判定する。このように用意したルールにより、6 種類の質問タイプに対応する。

回答抽出には、テキストベースの質問応答システムで利用される一般的な手法を実装した。具体的には、文書 D の中に含まれる質問タイプに対応する固有表現 (NE) ごとに、以下の特徴量を用いて回答抽出スコアを計算して、それが最大となる NE を含む文を回答とする。

- NE を含む文に検索クエリ中の名詞が含まれる個数
- NE を含む文節に係る文節、NE を含む文節が係る文節に検索クエリ中の名詞が含まれる個数

なお、質問に対する回答の確信度 $P_{QA}(D)$ は、発話タイプ判定の根拠となる語句の音声認識の信頼度と、回答抽出のスコアを用いて計算する。

4. ベイズリスクに基づく応答候補の選択

次に、システムの応答を決定するための基準としてベイズリスクを定義する。これは、ユーザに所望の情報を提示したときにシステムが得る報酬と、確認や誤った情報を提示することによるペナルティに基づいて定義する。すなわち、ユーザが要求している情報を正しく提示した場合には、応答内容に応じた報酬を与える。逆に、誤った内容を提示した場合や、候補のリジェクトを行った場合には、システムがその応答を行ったことにより、余分に費やす時間（＝ユーザが正しい回答を得られるまでに必要な文数で近似）に応じたペナルティを与える。ペナルティは正しい候補を提示した場合には 0 であるが、他の場合には応答内容に応じた正の値をとる。たとえば、確認を行う場合には、[システムの確認+ユーザの回答] の 2 発話分、誤った情報を提示した場合には、[情報提示(3 文) + ユーザの訂正 + システムの謝罪 + 再発話要求 + ユーザが再発話をしてからシステムが正しい回答を提示するまでの期待値文数] の 14 のペナルティが与えられる。なお、正解提示までに必要な文数の期待値 ($AddSent$) は、システムが正しい回答を提示できる確率を 60% とし、ユーザの所望の情報を提示するまでに必要な文数を求ることにより計算した。

システムが生成する各応答候補に対するベイズリスクは、文書検索の確信度 $P(D)$ 、ユーザの質問に対する回答の確信度 $P_{QA}(D)$ 、ターン毎のペナルティ $Penalty$ 、報酬 Rwd_{Ret} 、 Rwd_{QA} ($Rwd_{Ret} < Rwd_{QA}$) を用いて以下のように記述できる。

- 文書 D を確認なしで提示

$$\begin{aligned} Risk(Pres(D)) = & -Rwd_{Ret} * P(D) \\ & + ((6 + AddSent) * Penalty) \\ & * (1 - P(D)) \end{aligned}$$

- 文書 D を提示することに対する確認

$$\begin{aligned} Risk(Conf(D)) = & (-Rwd_{Ret} + 2 * Penalty) * P(D) \\ & + ((2 + AddSent) * Penalty) \\ & * (1 - P(D)) \end{aligned}$$

- 文書 D を用いてユーザの質問に回答

$$\begin{aligned} Risk(Ans(D)) = & -Rwd_{QA} * P_{QA}(D) * P(D) \\ & + ((4 + AddSent) * Penalty) \\ & * (1 - P_{QA}(D) * P(D)) \end{aligned}$$

- リジェクト

$$Risk(Reject) = (1 + AddSent) * Penalty$$

ユーザ発話: 「銀閣寺は誰が建てましたか？」

応答候補:

*コンテキスト情報なし

→ $P(\text{金閣寺の歴史}) = 0.2$

→ $P_{QA}(\text{金閣寺の歴史}) = 0.5; 1397 \text{ 年} ?$

- $Risk(Pres(\text{金閣寺の歴史})) = -1.0 + 11.2 = 10.2$

- $Risk(Conf(\text{金閣寺の歴史})) = -0.6 + 6.0 = 5.4$

- $Risk(Ans(\text{金閣寺の歴史}; 1397 \text{ 年})) = -4.0 + 9.0 = 6.0$

*コンテキスト情報利用

→ $P(\text{銀閣寺の歴史}) = 0.4$

→ $P_{QA}(\text{銀閣寺の歴史}) = 0.2; 1485 \text{ 年} ?$

- $Risk(Pres(\text{銀閣寺の歴史})) = -2.0 + 8.4 = 6.4$

- $Risk(Conf(\text{銀閣寺の歴史})) = -1.2 + 6.0 = 4.8$

- $Risk(Ans(\text{銀閣寺の歴史}; 1485 \text{ 年})) = -3.2 + 9.2 = 6.0$

・リジェクト

- $Risk(Reject) = 9.0$

↓

システムの応答:

銀閣寺の歴史を提示することの確認:

「銀閣寺の歴史を説明しましょうか？」

図 3 ベイズリスクの計算例

$Penalty = 1$, $Rwd_{Ret} = 5$, $Rwd_{QA} = 40$ とした場合のベイズリスクの計算例を図 3 に示す。

5. オンライン学習による対話戦略の最適化・適応

本研究で提案するオンライン学習手法は、過去の N 発話を学習窓に利用し、それらの発話に対する回答提示までの文数の期待値 ES の合計を最小化することにより実現される。なお、各発話毎のタスク達成に必要な文数の期待値 ES は、4. 節と同様の方法により計算される。すなわち、回答が存在する検索要求・質問に対しては、システムは可能な限り少ない文数で正しい回答を提示するための対話戦略を学習する。逆に、音声認識誤りやシステム想定外発話であるため回答が存在しない発話に対しては、システムは確認を生成したりできるだけ早く対話を切り上げて、再発話を促す対話戦略を学習する。(このような発話に対するシステムの最適な応答はリジェクトである。) このため、回答提示までの文数の期待値の合計を最適化することにより、音声認識精度や検索の成功率を考慮した最適な対話戦略を学習できると期待される。

また、提案手法ではパラメータの更新はユーザ発話が入力されることに行われるため、入力される発話の傾向の変化に適応できると期待される。この点が、従来研究で行われきた、応答の成功率を推定する識別器を学習して対話制御の最適化を行う手法 [8], [9] に対する、本手法の利点であるといえる。

4. 節において定義したリスク計算式中の $Penalty$ の値を 1 に固定し、 Rwd_{Ret} と Rwd_{QA} の報酬パラメータのペアを更新することにより対話戦略の最適化を行う。具体的な学習の手順

は以下の通りである。

(1) (t ステップ目において) 現在の報酬パラメータ Rwd_{Ret}^t, Rwd_{QA}^t を用いて、直近の N 発話の応答を生成し、正しい応答提示までに必要な文数の期待値 ($SumES^{tt}$) を計算する。

$$SumES^{tt} = \sum_{i=t-N+1}^t ES(Act_i(Rwd_{Ret}^t, Rwd_{QA}^t))$$

ここで、 $Act_i(Rwd_{Ret}, Rwd_{QA})$ は、報酬ペア Rwd_{Ret}, Rwd_{QA} を用いて生成される i 番目のユーザ発話に対するシステムの応答である。

(2) 現在の報酬パラメータを微少に増減させて、同様に ES を計算する。

$$SumES^{++} = \sum_{i=t-N+1}^t ES(Act_i(Rwd_{Ret}^+, Rwd_{QA}^+))$$

$$SumES^{+t} = \sum_{i=t-N+1}^t ES(Act_i(Rwd_{Ret}^+, Rwd_{QA}^t)) \dots$$

$$SumES^{--} = \sum_{i=t-N+1}^t ES(Act_i(Rwd_{Ret}^-, Rwd_{QA}^-))$$

$Rwd_{Ret}^+, Rwd_{Ret}^-, Rwd_{QA}^+, Rwd_{QA}^-$ は γ, δ を更新幅の定数として以下のように定める。

$$\begin{cases} Rwd_{Ret}^+ = Rwd_{Ret}^t + \gamma, & Rwd_{Ret}^- = Rwd_{Ret}^t - \gamma \\ Rwd_{QA}^+ = Rwd_{QA}^t + \delta, & Rwd_{QA}^- = Rwd_{QA}^t - \delta \end{cases}$$

(3) 最小の文数 $SumES^{**}$ で正しい応答を提示できる報酬ペア (Rwd_{Ret}^*, Rwd_{QA}^*) を選択する。

(4) パラメータを更新し、1. に戻る。

$$Rwd_{Ret}, Rwd_{QA} \leftarrow Rwd_{Ret}^*, Rwd_{QA}^*$$

$$t \leftarrow t + 1$$

なお、更新幅 γ, δ は経験的に定めた。

6. 提案手法の評価

提案する対話戦略を評価するために、「京都版ダイアログナビ」において収集されたユーザの発話データを用いる。企画展前半の 30 日間で収集された、ドメイン内の検索要求・質問 1416 発話（検索要求 1084 発話、質問 332 発話）を人手により書き起こし、回答となる文書・NE を付与した。

6.1 初期値からの報酬ペアの学習

まず、ランダムに設定した報酬パラメータの初期値を、学習により最適化する実験を行った。報酬の初期値として、 $Rwd_{Ret}^{init} < Rwd_{QA}^{init}$ となるように 10 種類の報酬ペアを用意し、その値から最適化を行う 10 回の試行により評価を行った。なお、それぞれの学習において、発話データの 10-fold クロスバリデーションによる学習・評価を行った。

学習ステップ数と、その時点の報酬パラメータを用いて評価セットの応答を選択した場合に正しい応答を得られるまでの文

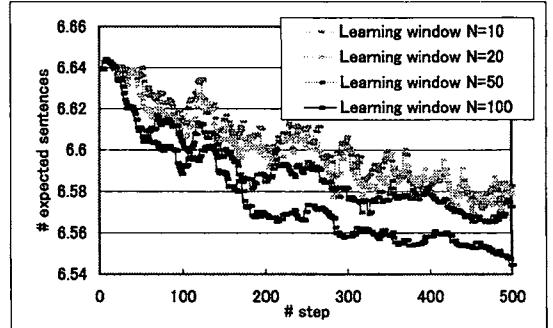


図 4 初期値からの報酬パラメータ学習

表 1 提案手法による応答生成結果

学習窓 (発話数)	初期値での 応答成功 rate	学習後の応答成功 rate (Outlier 1つを除く)
10	63.62%	63.64% (63.8%)
20		63.86% (64.1%)
50		64.18% (64.4%)
100		64.37% (64.6%)

数の期待値の関係を図 4 に示す。なお、文数の期待値は 10 回の試行の平均値である。500 ステップの学習により、提示に必要な文数は、おおむね収束していた。学習に用いる窓を大きくすることにより、改善幅が大きくなっている。ただし、大きな学習窓を利用する場合には、学習時間が増加するため、オンラインで動かす際にはあまり大きな値を用いることは実用的ではない。初期値からの学習により、学習窓として 100 を用いる場合で、回答提示までの文数を約 0.1 削減することができた。

この学習による検索成功率の変化を調べた。この結果を図 1 に示す。学習窓が 100 の場合で、検索成功率において、0.7% の改善が見られた。また、Outlier となる初期値 1 組を除いた、検索成功率の平均は、64.6% であり、これは、ほぼ最適値付近に収束していた。

6.2 オンライン学習による対話戦略の適応

次に、提案手法を用いて、音声認識率の変化に対して、対話戦略の適応を行う実験を行った。具体的な状況としては、駅などの公共スペースに設置されたシステムにおいて、人が多い時間帯と人が少ない時間帯で周辺の雑音の大きさが異なるために、音声認識率が変化するというケースを想定している。このような環境をシミュレートするために、対話コープスを音声認識精度の平均が 65% と 85% の 2 つのセットに分割して、学習の途中で入力するデータセットを変化させる。

それぞれのセットに対して 5-fold クロスバリデーションにより、評価を行った。なお、初期値には 6.1 節において学習された最適値付近のパラメータを利用した。評価データと平均音声認識率が異なるセットのデータで学習を行い（約 350 ステップ）、その後、評価データと音声認識率が同等の学習データセットに

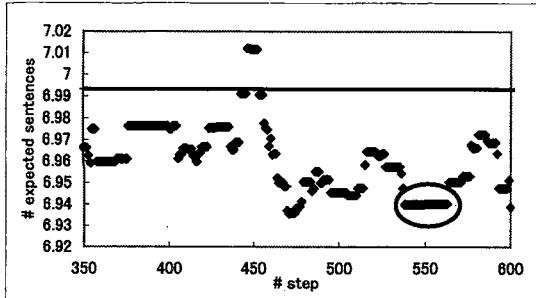


図 5 対話戦略の適応結果 (85% → 65%)

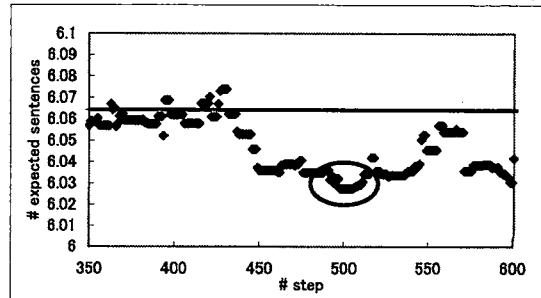


図 6 対話戦略の適応結果 (65% → 85%)

より学習を行うことにより、音声認識率の変化をシミュレートした。これらの結果を図 5、図 6 に示す。なお、図 5 は、音声認識精度を 85%から 65%に、図 6 は、65%から 85%に変化させた場合の回答提示までの文数の期待値である。図中の点線が 350 ステップ付近から評価データに適合したデータによって学習を行った場合である。また、参考として評価データと異なる音声認識率の学習データにより学習を続けた場合との比較を行った。認識率が適合しない学習データにより 500 ステップ学習を行った場合の文数の期待値を直線で示す。音声認識率が適合した学習データにより学習を行った場合に、認識率が適合しない学習データによって学習を続けた場合と比較して、おおむね少ない文数で正しい回答を提示できている。

さらに、具体的な対話戦略の変化を調べるために、適応前と適応後のシステムが選択した応答の比率を調べた。学習データの音声認識率を 85%から 65%に変化させた場合(図 5)において、評価データに適合した学習データで学習を始める直前(350 ステップ付近)の対話戦略では、評価データに対して確認を行った比率が 19.3%であったのに対して、550 ステップ付近のパラメータによって選択された応答では、この比率が 21.8%に増加していた。また、図 6 では、適合した学習データで学習を始める直前に、17.0%であったリジェクトの比率が 500 ステップ付近では 15.6%に低下していた。音声認識精度が改善した場合に、システムは確認を省いたり、質問の回答のみを提示する積極的な対話戦略をとることにより、回答提示までに必要な文数を削減できると考えられる。逆に、認識精度が低下した場合には慎重な対話戦略をとることが望ましい。この応答の比率の変化は、音声認識率の変化に対する対話戦略の適応がおおむね有効に機能していることを示している。

7. おわりに

音声入力により情報検索・質問応答を行う対話システムにおいて、ペイズリスクに基づいて最適な応答を生成する対話戦略のオンライン学習による最適化・適応手法を提案した。1416 発話による評価の結果、初期値からの学習において最適値に収束することが確認できた。また、環境の変化などにより平均音声

認識率が変化した場合にも対話戦略を適切に変化させられることを確認した。

文 献

- [1] A. Fujii and K. Itou. Building a test collection for speech-driven Web retrieval. In *Proc. Eurospeech*, 2003.
- [2] 西崎博光, 中川聖一. 音声認識誤りと未知語に頑健な音声文書検索手法. 電子情報通信学会論文誌, Vol. J86-DII, No. 10, pp. 1369-1381, 2003.
- [3] 翠輝久, 河原達也. 限定されたドメインにおける質問応答機能を備えた文書検索・提示型対話システム. 情報処理学会研究報告, 2006-SLP-62-13, 2006.
- [4] 翠輝久, 河原達也. 質問応答技術を利用したインタラクティブな音声対話システム. 人工知能学会研究会資料, SIG-SLUD-A602-6, 2006.
- [5] 新美康永, 小林豊. 音声認識の誤りを考慮した対話制御方式のモデル化. 情報処理学会研究報告, 95-SLP-5-7, 1995.
- [6] D. J. Litman, M. S. Kearns, S. Singh, and M. A. Walker. Automatic optimization of dialogue management. In *Proc. COLING*, pp. 502-508, 2000.
- [7] 堂坂浩二, 安田宜仁, 相川清明. システム知識制限下での効率的対話制御法. 自然言語処理, Vol. 9, No. 1, pp. 43-63, 2002.
- [8] E. Levin and R. Pieraccini. Value-based Optimal Decision for Dialog Systems. In *Proc. IEEE SLT*, pp. 198-201, 2006.
- [9] E. Horvitz and T. Paek. Complementary computing: Policies for transferring callers from dialog systems to human receptionists. *User Modeling and User Adapted Interaction*, Vol. 17, pp. 159 - 182, 2006.
- [10] NIST and DARPA. The twelfth Text REtrieval Conference (TREC 2003). In *NIST Special Publication SP 500-255*, 2003.
- [11] 翠輝久, 河原達也. 文書検索型音声対話システムにおけるペイズリスクに基づく対話制御の最適化. 情報処理学会研究報告, 2007-SLP-65-10, 2007.