

統計的発話選択による非タスク指向型対話エージェントの設計

Designing a Non-task-oriented Dialogue Agent using Statistical Utterance Selection Method

稲葉 通将^{1*} 平井 尚樹¹ 鳥海 不二夫¹ 石井 健一郎¹

Michimasa INABA¹, Naoki HIRAI¹, Fujio TORIUMI¹, and Kenichiro ISHII¹

¹ 名古屋大学大学院情報科学研究科

¹ Graduate School of Information Science, Nagoya University

Abstract: Computerized dialogue agents have recently been actively investigated in various fields. There is a great demand for not only task-oriented dialogue agents such as reservation services but also non-task-oriented ones such as chatbots. We design a non-task-oriented dialogue agent using statistical method, i.e., learning to rank. Learning to rank is a statistical learning technology on creating a ranking model for sorting objects. The technology has been successfully applied to information retrieval. In order to develop a dialogue agent, we recognize a problem which the agent generates response as information retrieval.

1 はじめに

近年行われている対話エージェント研究は特定のタスク、例えば道案内や予約受付などの達成を目的としたタスク指向型対話エージェントに関するものが主流である。しかしながら、特定のタスク達成を目的とせず、雑談などを行う非タスク指向型対話エージェントの研究も少しずつではあるが活発になりつつある。

非タスク指向型対話エージェントは、対話を楽しむという娯楽の用途だけでなく、福祉の分野でも注目が集まっている。実際に、非タスク指向型対話エージェントを搭載したロボットと一人暮らしの高齢者が一緒に生活を行ったところ、高齢者の笑顔の増加や、表情が豊かになったことが報告されている [1]。加えて、対話による認知症の予防という観点からも期待が高まっている。また、今後ロボットが人間社会へますます進出していくことが期待されており、それらが社会に溶け込み、人間と良好な関係を形成するためには、非タスク指向型対話エージェントの研究は不可欠である。

2 対話エージェント KELDIC

我々は非タスク指向型対話エージェント KELDIC (Kens Laboratory Dialogue Computer) の設計を行なっている。

KELDIC は良い聞き手となることを目指した対話エージェントである。多くの非タスク指向型対話エージェントは「ユーザの発言に対して、いかに対話を破綻させることなく応答を行うか」ということを重視している。国際的な非タスク指向型対話エージェントのコンテストであるローブナー賞 [2] に出場する対話エージェントは、その最たる例である。これらのエージェントは、自分から話を盛り上げたり、ユーザを楽しませたりするといったことは基本的には行わない、極めて受動的な姿勢で対話に臨んでいる。

しかし、冒頭で述べた非タスク指向型対話エージェントの用途を考慮すると、むしろユーザがどれだけ気分よく対話ができるか、エージェントがユーザに良い印象を与えられるか、といった対話の質を重視すべきである。

そこで我々は「いかに対話を盛り上げるか」ということを重視している。そのために、KELDIC はトークショーにおけるインタビューを模し、エージェントが相手に応じた適切な話題を提供し、相手の話を引き出し、適切な反応を返すことによって対話を盛り上げることを目指す。

良い聞き手であるインタビューは、どのような話題で話を進めるか、どのような事を言うか、何を聞き出すかといったことをあらかじめ考え、周到に準備を重ねた上で対話に臨む。そこで、KELDIC でもその手法を模して対話を行う。つまり、KELDIC はあらかじめ発話候補を大量に用意しておき、その時々状況に応じて適切な発話を発話候補集から選択することで対話を進める。本研究では、その発話選択のために統計的

*連絡先：名古屋大学大学院情報科学研究科
〒464-8601 愛知県名古屋市千種区不老町
E-mail: inaba@kishii.ss.is.nagoya-u.ac.jp

手法を用いる。

なお、本研究では問題を言語処理に特化するため、テキスト対話を対象とし、音声対話は対象に含めないことにする。

本論文では、前述した発話候補集からの適切な発話に選択にランキング学習を用いた非タスク指向型対話エージェント KELDIC を構築する。ランキング学習とは、情報検索の分野で研究が進められている技術であり、ある複数のデータの中から目的のデータを求める際に、目的のデータが順位付けで上位に来るように学習を行う統計的機械学習手法である [3]。すなわち、KELDIC は、ランキング学習によって発話候補を順位付けし、最も上位に順位付けされた発話を選択することで対話を進める。なお、ランキング学習には様々なデータセットを用いた実験で、他のランキング学習手法と比べて高い性能が確認されている ListNet[4] を用いる。

3 統計的発話選択

3.1 発話選択の定義

本節では、ランキング学習を用いた発話選択手法について説明する。

発話選択とは、事前に生成した発話候補集の中から発話候補の一つを選択し、対話相手の発話に対して応答を行うものである。

まず、対話の1時点における状態を文脈と定義し、式 (1) で表す。

$$\mathbf{c} = \{u_1, u_2, \dots, u_l\} \quad (1)$$

式 (1) における各要素 $u_i (i = 1, 2, \dots, l)$ は、文脈中に出現した発話を示しており、 l は文脈中の発話数を示している。ただし、 u_1 は文脈 c における最後の発話を、 u_l は文脈における最初の発話を意味する。また、便宜上、 u_0 は文脈 c に対する応答として選択される発話を意味することとする。文脈 c の例を表 1 に示す。

次に、文脈 c に対して用意する発話候補集合を式 (2) で定義する。

$$\mathbf{A}_c = \{a_1^c, a_2^c, \dots, a_{|A_c|}^c\} \quad (2)$$

式 (2) における各要素 $a_i^c (i = 1, 2, \dots, |A_c|)$ は各発話候補を示し、文脈 c に対する応答として適切な発話 (正解発話) と、適切でない発話が混在している。また、 $|A_c|$ は文脈 c のときの発話候補数である。

ここで、正解発話集合を式 (3) で定義する。

$$\mathbf{R}_c = \{r_1^c, r_2^c, \dots, r_{|R_c|}^c\} \subseteq \mathbf{A}_c \quad (3)$$

表 1: 文脈 c の例

番号	話者	発話
u_6	KELDIC	英語は得意なほうですか？
u_5	人	英語は苦手です。 日本語大好きです。
u_4	KELDIC	苦手であれば、 ぜひ学生時代に マスターしてください。
u_3	人	どうやって勉強すれば いいですかね？
u_2	KELDIC	コミュニケーション能力を 磨くには、とにかく経験を 積むことだと言われます。
u_1	人	なるほど。では、夏休みは 海外に旅行に行ってみるの もいいかもしれませんね。
(u_0)	KELDIC	(発話を表 2) から選択

表 2: 発話候補の集合 A_c の例

発話番号	発話
a_1^c	英語は得意なほうですか？
$a_2^c(r_1^c)$	海外に行くならどこに 行ってみたいですか？
a_3^c	一人暮らしは楽しいですよ。 ぜひ挑戦してください。
$a_4^c(r_2^c)$	それもありませんね。
	...
$a_{20}^c(r_3^c)$	素晴らしい考えだと思います。
	...
a_{130}^c	講義中に、皆の前で質問する というのはどうですか？

式 (3) における各要素 $r_i^c (i = 1, 2, \dots, |R_c|)$ は各正解発話を示し、 A_c におけるいずれかの要素である。また、 $|R_c|$ は文脈 c のときの正解発話数である。

発話選択とは、ある文脈 c において、発話候補集合 A_c から正解発話集合 R_c を見出すことである。ただし、 c と A_c は以下を満たすものと仮定する。

- 全ての c について A_c は生成可能である
- c に対し、 A_c は 1 個以上の正解発話 r_i^c を含む

ここで、 c 、 A_c 、 R_c の例を表 1、表 2 に示す。ただし R_c は、表 2 において、網掛けをすることで示した。

表 1 の文脈 c の例では、発話選択箇所 u_0 に、 u_6 から u_1 までの発話系列に対して適切な発話が、表 2 の発話候補集合 $A_c (|A_c| = 130)$ から選択される。この例の

場合は、 u_0 として $R_c = \{a_3^c, a_4^c, a_{20}^c\}$ のいずれかが選択されることが望ましい。

本論文では、文脈 c とそれに対する各発話候補 a_i との関係を示す、以下で定義される n 次元の素性ベクトルで表現する。

$$\Phi(c, a_i) = (x_1(c, a_i), x_2(c, a_i), \dots, x_n(c, a_i)) \in \mathbb{R}^n \quad (4)$$

ここで、 $x_j(c, a_i) (j = 1, 2, \dots, n)$ は素性値を表す。実験では、素性値は全て $\{0, 1\}$ の 2 値とした。

提案手法では、得られた n 次元の素性ベクトルの集合から最適な発話を選択する手法として、ランキング学習手法の一つである ListNet を用いる。

3.2 ListNet

ListNet は順位のリストを確率分布で表現し、学習データとモデルの分布間の距離を最小化することで順位付けのための学習を行う。以下では、ListNet によるランキング学習の方法について説明する。

ある m 個の文脈の集合 $C = \{c_1, c_2, \dots, c_m\}$ と、各文脈 $c_i (i = 1, 2, \dots, m)$ に対する発話候補の集合 $A_{c_i} = \{a_1^{c_i}, a_2^{c_i}, \dots, a_{|A_{c_i}|}^{c_i}\}$ が与えられているとする。ここで、ある発話候補集合 A_c に対して、評価 (スコア) のリスト y^c を式 (5) で定義する。スコア $y_j^c (j = 1, 2, \dots, |A_c|)$ は発話候補 a_j^c のスコアを表す。スコアとは、その発話候補の評価値である。例えば、対話の次の応答として自然であれば 3 点、やや不自然であれば 1 点、対話として破綻していれば 0 点というように、各発話候補に人手でスコアを付与する。

$$y^c = (y_1^c, y_2^c, \dots, y_{|A_c|}^c) \quad (5)$$

次に第 3.1 節の式 (4) で得られる素性ベクトル $\Phi(c, a_j)$ のリスト x^c を式 (6) で定義する。この x^c と y^c のペアを、正しい順位付けが行われている学習データとして用いる。

$$x^c = (\Phi(c, a_1), \Phi(c, a_2), \dots, \Phi(c, a_{|A_c|})) \quad (6)$$

ここで、順位付けを行うために素性ベクトル $\Phi(c, a_j)$ のスコア付けを行う関数 f を用意する。なお、以下 $\Phi(c, a_j)$ を \mathbf{a}_j と表記する。この関数により得られたスコア $f(\mathbf{a}_j)$ のリストを、式 (7) で定義する。

$$z^c = (f(\mathbf{a}_1), f(\mathbf{a}_2), \dots, f(\mathbf{a}_{|A_c|})) \quad (7)$$

正しく順位付けを行うということは、関数で求めたスコアリスト z^c における各ベクトル \mathbf{a}_j の順位を、人手で評価したスコアリスト y^c における各ベクトル \mathbf{a}_j の順位に近づけることである。これはすなわち、 y^c と z^c の間の差を小さくすることである。数式で表

現すると、式 (8) で定義される。この式 (8) の値を最小にすることが学習の目的となる。ただし、 L は listwise 損失関数である。

$$\sum_{c \in C} L(y^c, z^c) \quad (8)$$

ListNet では、listwise 損失関数 $L(y^c, z^c)$ としてクロスエントロピーを用いる。そのために、スコアリストを Plackett-Luce モデル [5][6] を用いて確率分布へと変換する。

離散確率変数の確率分布 p と q が存在する場合、クロスエントロピーは式 (9) で定義される。

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (9)$$

ここで、確率分布 $p(x)$ を、参照用の固定確率分布とする。すなわち、近づきたい目標となるスコアリスト y^c を確率分布に変換したものが、確率分布 $p(x)$ となる。一方、関数で求めたスコア z^c を確率分布に変換したものを、確率分布 $q(x)$ とする。確率分布 $p(x)$ と $q(x)$ を比較した際、 $p(x) = q(x)$ のときにクロスエントロピーは最小となる。すなわち、式 (9) の値を最小化することが、 y^c と z^c の間の差を小さくすることと等しい。

上位 1 件に対する Plackett-Luce モデルによるスコアリスト y^c の分布は、式 (10) で表される。この式 (10) は、ある発話が順位付けで 1 位になる確率の分布を意味する。

$$P_{y^c}(\mathbf{a}_j) = \frac{\exp(y_j^c)}{\sum_{k=1}^{|A_c|} \exp(y_k^c)} \quad (10)$$

式 (10) 中の y_k^c は、 \mathbf{a}_k のスコアを表す。スコアが高ければ高いほど、式 (10) の値、すなわち 1 位になる確率は大きくなる。例えば、ベクトルのリスト x^c が $(\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3)$ 、スコアリスト y^c が $(1, 0, 3)$ であるとする。順位付けの結果、1 位が \mathbf{a}_3 と正しく行われたとすると、式 (10) の値は、以下のように表される。

$$\begin{aligned} P_{y^c}(\mathbf{a}_3) &= \frac{\exp(y_3^c)}{\exp(y_1^c) + \exp(y_2^c) + \exp(y_3^c)} \\ &= \frac{\exp(3)}{\exp(1) + \exp(0) + \exp(3)} \\ &= 0.844 \end{aligned} \quad (11)$$

一方、順位付けの結果、1 位が \mathbf{a}_1 と間違えて行われた場合、式 (10) の値は、0.114 と正しい順位付けの場合より小さくなる。そして、 \mathbf{a}_2 が 1 位となったときに最も値が小さく、0.042 となる。

スコア付けを行う関数 f には、式 (12) で定義される線形識別関数を用いる。式 (12) における ω はパラメータベクトルを表し、 $\langle \cdot, \cdot \rangle$ は内積を表す。

$$f(\mathbf{a}_j) = \langle \omega, \mathbf{a}_j \rangle \quad (12)$$

この関数 f を用いて求めたスコアリスト $z^c(f_\omega)$ を確率分布へ変換するための式を、式 (13) で定義する。

$$P_{z^c(f_\omega)}(\mathbf{a}_j) = \frac{\exp(f_\omega(\mathbf{a}_j))}{\sum_{k=1}^{|A_c|} \exp(f_\omega(\mathbf{a}_k))} \quad (13)$$

この式 (13) は、式 (10) 中のスコアリスト y^c を $z^c(f_\omega)$ に変換したものである。

式 (10) と式 (13) および式 (9) を用いると、式 (8) 中の損失関数 L は、次式で表される。

$$L(y^c, z^c(f_\omega)) = - \sum_{j=1}^{|A_c|} P_{y^c}(\mathbf{a}_j) \log(P_{z^c(f_\omega)}(\mathbf{a}_j)) \quad (14)$$

パラメータ ω は最急降下法により求めることができる。

発話候補の順位付けは、関数 $f_\omega(\mathbf{a}_j)$ と最終的に得られたパラメータ ω を用いて各発話候補をスコア付けすることにより行う。

3.3 使用した素性

本手法では、文脈 c とそれに対する各発話候補 a_i を素性ベクトルで表現し、順位付けを行う。素性は計 12 種類を用いた。本稿では、その一部について説明する。

3.3.1 単語 1-gram(名詞)

適切な選択を行うためには、発話候補と文脈の間の関係を捉える必要がある。そこで、文脈中の発話と発話候補における単語 1-gram のペアを素性として用いた。ただし、助詞などの組み合わせには意味が無いと思われるため、1-gram では名詞のみを対象とする。文脈中の発話は $u_1 \sim u_4$ を用い、発話間における名詞のペアが存在するかどうかを $0 \cdot 1$ で表す。素性抽出の例を図 1 に示す。図に示したように、文脈中の何番目の発話における名詞かということも考慮する。

3.3.2 単語 3-gram(末尾)

文脈中の発話の末尾 3-gram と発話候補における発話の末尾 3-gram のペアを素性として用いた。この素性により「思い/ます/か」(文脈)-「と/思い/ます」(発話候補) のような関係を捉えることが可能となる。

3.3.3 話題

各発話候補には、発話作成時に、その発話がどういった事柄について述べたものかという話題情報をあらかじめ付与する。話題情報は 1 発話に 2 個以上付与され

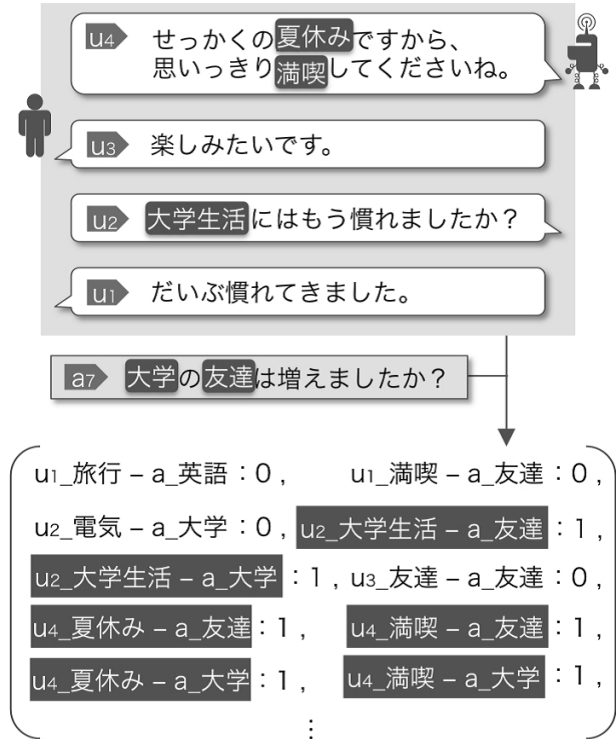


図 1: 素性抽出の例 (単語 1-gram)

る場合もあり、相槌のような話題が特定できない発話には付与されない。

本素性は、同一の話題を続けるためだけでなく、ある話題から遷移しやすい話題や、遷移しにくい話題など話題間の意味的な距離を捉えるためにも有用である。考慮する文脈中の発話は $u_2 \sim u_{10}$ におけるエージェント側の発話 (ユーザ側の発話は用いない) であり、発話間における話題情報のペアが存在するかどうかを $0 \cdot 1$ で表す。

4 対話実験

4.1 概要

提案手法を用いた対話エージェント KELDIC を構築し、11 名の大学生の被験者との対話を行った。対話はチャットソフトを介して行った。以下では、提案手法の学習データ作成方法、および実験の詳細について述べる。

4.2 発話候補集の作成

KELDIC の発話候補は全て人手で作成した。

KELDIC は良い聞き手となることを目指していることから、発話候補は対話を盛り上げ、ユーザから話を

引き出すことを目指して発話を作成した。そのために、対談番組などのインタビューを意識して発話を作成した。具体的には、

- 相手が興味・関心を持つ話題を選ぶ
- 相手の発言に理解を示す
- 話の腰を折らない

といった点に注意して発話を作成した。

作成の際には、顔文字・絵文字および方言を用いないこと以外は、特に制限事項を設けることはしなかった。発話の内容は「大学生活」、「アルバイト」、「将来」、「英語」など、大学生が興味を持つと考えられるものとし、計 130 発話を作成した。

4.3 学習データの作成

ListNet の学習には文脈と、それに対する適切さに応じて点数が付与された複数の発話候補が必要である(すべての発話候補に点数を付与する必要はない)。本研究では、発話の適切さを「○：文脈に対して自然である」、「△：多少不自然であるが、その後の対話の上で継続が可能である」、「×：文脈に対して不自然である」の三段階で評価し、それぞれ 30 点、15 点、1 点とした。これらの点数は経験的に決定した。

学習データは以下の手順で作成した。

- (1) 任意の発話をユーザ側の発話として入力し、文脈に加える
- (2) 発話候補集からランダムで 10 発話を抽出し、それまでに入力された文脈に対する適切さを評価する
- (3) 適切な発話が存在しなければ (2) をもう一度行う
- (4) 適切な発話が存在すれば、その発話を文脈に加え、その文脈に対するユーザ側の発話を入力し、文脈に加える
- (5) 上記の (2)~(4) を繰り返す

学習データは、(2) で評価された複数の発話候補とその文脈を 1 データとする。したがって、実験で使用した学習データには、各文脈に対して 10 個以上の発話候補について点数が付与されており、そのうち少なくとも 1 個は「文脈に対して自然である」(30 点) と評価された発話が含まれていることになる。作成した学習データの例を表 3 に示す。表の上部が文脈であり、下部がその文脈に対する適切さに応じて点数が付与された発話候補である。このような文脈と点数が付与された発話候補を 1 個と数え、全部で 167 個の学習データを作成した。

表 3: 学習データの例

番号	話者	発話
u_9	人	こんにちは。
u_8	KELDIC	こんにちは。 夏休みの予定は何か立てていますか？
u_7	人	旅行に行こうと思っています。
u_6	KELDIC	どこか家族で旅行に行く予定はありますか？
u_5	人	特に家族で行く予定はありません。
u_4	KELDIC	せっかくの夏休みですから思いっきり満喫してくださいね。
u_3	人	楽しみたいです。
u_2	KELDIC	大学生活にはもう慣れましたか？
u_1	人	だいぶ慣れてきました。

点数	発話候補
30	まずは大学生活に慣れることが大切ですね。
30	順調に大学生活を送っているみたいですね。
30	大学では周りの人に話しかけるようにしていますか？
30	大学の友達は増えましたか？
15	英語は得意でしょうか、苦手でしょうか？
15	夏休みの思い出を教えてください。
1	それは今からとても楽しみです。
1	大学は自発的に動かないといけないところですね。
1	電気などインフラは、生活に不可欠なものになってしまっていますね。
1	言語はやはり習うより慣れるですね。

4.4 実験設定

被験者との対話は、以下の制約のもとで行った。

- KELDIC を試すような発話は避ける (時間を尋ねる、わざと意味不明なことを言う、など)
- 1 発話は 1 文とする
- 方言・顔文字などは使用しない
- 1 対話は 20 分

評価は、KELDIC との対話後のアンケートによって行う。アンケートは 2 種類の項目があり、対話の自然

表 4: 対話実験結果

	自然さ		盛り上がり	
	平均	標準偏差	平均	標準偏差
KELDIC	3.727	0.905	3.364	1.120
QKELDIC	2.273	1.135	2.455	1.076
WoZ	4.364	0.771	4.000	0.853

さと対話の盛り上がりのそれぞれについて1~5点(非常に悪い[1点]・悪い[2点]・どちらともいえない[3点]・良い[4点]・非常に良い[5点])で主観的に評価した。

比較のため対話エージェント QKELDIC と Wizard of Oz (WOZ) 法による対話も行った。QKELDIC は我々が以前提案した発話生成規則を用いて応答を行う非タスク指向型対話エージェントである(QKELDICの詳細は文献[7]参照)。WOZ法による対話はKELDICが用いたものと同じの発話候補集から人手で発話を選択することにより対話を進めた。ただし、文脈に対して適切な発話候補が存在しない場合に限り、発話を新たに作成し、それを発言してもよいこととした。

4.5 実験結果

実験の結果を表4に示した。QKELDICと比較すると、KELDICは自然さ・盛り上がりともQKELDICを上回った。一方、WoZ法と比較すると、自然さ・盛り上がり共に、WOZ法がKELDICを約0.65ポイント上回った。ただし、個別の点数を見ると、自然さではKELDICとWOZ法で同じ点数を付けた被験者が5名、KELDICのほうがWOZ法よりも高得点をつけた被験者が1名であった。また、盛り上がりでは、自然さではKELDICとWOZ法で同じ点数を付けた被験者が3名、KELDICのほうがWOZ法よりも高得点をつけた被験者が1名であった。したがって、約半数の被験者が、提案手法を用いた対話エージェントKELDICはWOZ法によって選択した場合と同程度の自然で盛り上がる対話が可能であると評価した。

自然さ・盛り上がり共にKELDICにWOZ法よりも高い点をつけた被験者との対話を表5に示した。対話ログを分析すると、この例のように、エージェント側が対話をリードすることができた場合に、自然な対話が成立することが多かった。

5 まとめ

本論文では、統計的発話選択手法を用いた非タスク指向型対話エージェントKELDICの設計を行った。統

表 5: 対話実験における実際の対話例

話者	発話
KELDIC	理科系ですと、膨大な量の論文を英語で読まなくてはなりません。
人	そうですね、英語はこれから必要になりますからね。
KELDIC	英語の勉強のために海外留学してみるのもいいかもしれませんね。
人	実は親にもそう進められてるんですよ。
KELDIC	社会勉強にもなるので、挑戦してみてくださいでしょうか。

計的機械学習手法であるランキング学習を用いて、あらかじめ用意した発話候補をそれまでの文脈に対する適切さに応じて順位付けすることにより統計的な応答を実現した。

実験では、対話エージェントKELDICと被験者対話を行い、制約付きの対話ではあるが、WOZ法による対話に近い自然な対話の実現できることが確認された。

今後は、さらなる性能向上を目指し、発話の意味を扱った新たな素性の導入や、非線形識別関数の適用などを含む学習機構の改良を行っていく予定である。

参考文献

- [1] 日本経済新聞, 2010.11.7, 夕刊.
- [2] “Home page of the Loebner prize ‘the first Turing test’”. <http://www.teu.ac.jp/media/earth/FK/>, 2003.
- [3] T.Y. Liu. Learning to rank for information retrieval. *Foundations and Trends in Information Retrieval*, Vol. 3, No. 3, pp. 225–331, 2009.
- [4] Z. Cao, T. Qin, T.Y. Liu, M.F. Tsai, and H. Li. Learning to rank: from pairwise approach to listwise approach. In *Proceedings of the 24th international conference on Machine learning*, pp. 129–136. ACM, 2007.
- [5] RL Plackett. The analysis of permutations. *Applied Statistics*, pp. 193–202, 1975.
- [6] R.D. Luce. *Individual choice behavior: A theoretical analysis*. New York: Wiley, 1959.
- [7] 岡田譲二, 鳥海不二夫, 石井健一郎. インタビューを模した対話エージェントのための質問文自動生成. *Proceedings of JAWS 2007*, 2007.