

# Web 上の質問応答対の自動抽出に有用な表現

工藤智佳\* 辻慶太†

## Abstract

Web 上の質問応答対を集めたデータベースの自動構築を目指し、それら質問応答対をサーチエンジンでヒットさせるのに有用な言語表現を同定した。まず質問応答サイトと FAQ ページに挙げられている質問応答対を調べ、質問・応答それぞれに偏って出現する表現を特定し、それらを組み合わせて Google での検索精度が高い組合せを同定した。調査の結果、「方が」「できます」といった応答に特徴的な表現を、「どなたか」「あるのですか」といった質問に特徴的な表現と組み合わせる有効性が示された。

## 1 はじめに

Web 上の質問応答対を集めたデータベースの自動構築を目指し、それら質問応答対をサーチエンジンでヒットさせるのに有用な言語表現を同定した。Web 上の質問応答対は、大きく分けて掲示板、ブログ、質問応答サイト、FAQ ページという4種類のサイトに存在している。前3者における質問は、実際に一人の質問者が答えを欲したという点で、また FAQ における質問は、潜在的に多くの者が答えを求めているという点で、一定の価値がある質問であり、その応答との対はニーズのある情報と考えることができる。それらを集めて提供する質問応答対データベースは有用であろう。

質問応答対データベースでは、同一の、あるいは類似した質問とその応答達を一括して表示し、利用者に吟味・検討させることが比較的容易に実現できる。また近年 FAQ 等の質問応答対を利用して応答を行う手法・システムがいくつか提案されているが、本研究が目指すデータベースはそうした質問応答システムの情報源として利用することができる。さらにこのデータベースは、質問応答の実際に関する計量言語学的研究の基盤コーパスとしても利用することができるだろう。<sup>1</sup> 本研究はそうした質問応答対データベースの自動構築に向けた第一歩として、Web 上に分散して存在している質問応答対を、サーチエンジンで効果的にヒットさせるのに有用な検索キーワードの同定を目指すものである。

本研究では、まず一定量の質問応答対を手作業で収集し、そこに含まれる表現のうち、主に頻度の点において、一般の Web ページのテキストに比べて、特徴的なものを同定する。次にそれら特徴的表現の組合せをサーチエンジンにかけて、Web 上の質問応答対を高い精度でヒットさせる組合せを同定する。手作業で収集する質問応答対は、(a) 質問応答サイト、(b) FAQ ページ、の2つから抽出した。(a) の利用は質問応答サイト、掲示板、ブログ

における対話的な質問応答対の抽出を目的とし、(b) の利用は整理して書かれたモノログ的質問応答対の抽出を目的とする。

## 2 先行研究

近年質問応答に関しては様々な研究が行われている。その中には FAQ などの質問応答対を用いて、質問応答を行う手法を提案するものもある (Hammond et al. (1995), Burke et al. (1997), 堤 & 牛島 (1997), Sneider (1999), 松村ら (1999), 陳ら (2005))。本研究が目指す質問応答対データベースは、そうした質問応答手法の情報源として有用であろう。また横田ら (2006) は掲示板から質問記事を自動抽出する手法を提案している。横田ら (2006) の抽出対象は質問であり、また抽出の手がかりは文末の表現である。それに対して本研究手法は、質問と応答を対で抽出することを目指し、文末に限らない特徴的表現を用いるものである。

## 3 抽出手法

本研究では、質問応答対を含むページを高精度でヒットさせる「質問応答対自動抽出に有用な表現」を、以下の手法で抽出する。なお以下の説明では質問応答サイトを取り上げているが、FAQ ページの場合も同様である：

- (1) 質問応答対に特徴的な表現の抽出：
  - (a) 質問応答サイトから質問のテキストと応答のテキストを抽出する。
  - (b) Web からテキストを無作為に抽出する。
  - (c) 上記3つのテキストを構文解析して句単位の言語表現に分割する。
  - (d) 上記3つのテキストにおける各句に関して、後述の特徴度  $C_Q$ ,  $C_A$  を算出し、これらが高い句をそれぞれ質問・応答に特徴的な表現とする。
- (2) 「質問応答対自動抽出に有用な表現」の抽出：
  - (a) 質問・応答それぞれに特徴的な表現上位 10 句計 20 句を選ぶ。
  - (b) 20 句それぞれを Google で検索し精度を算出し、精度が高い上位 15 句を選ぶ。

\*筑波大学 図書館情報専門学群  
s0312144@ipe.tsukuba.ac.jp

†筑波大学大学院 図書館情報メディア研究科  
keita@slis.tsukuba.ac.jp

<sup>1</sup> 図書館のレファレンスデータベースは実際ニーズのあった質問を収めているという点で本研究が目指すデータベースに似ている。また応答は専門の図書館員によるもので信頼できる内容である。だが質問のテーマは比較的狭い。それに対して本研究が目指すデータベースは、回答の質は保証されていないものの、幅広いテーマを扱うことになる。

- (c) 15 句から 2 句の組み合わせ計 105 個を作り、それぞれの精度を調べる。
- (d) 高精度の組合せ上位 20 組を選んで、共通の 1 句を含む 2 句の組合せから 3 句の組合せを作り、それぞれの精度を調べる (例えば、「教えて下さい。 / 宜しく」という組合せと「教えて下さい。 / ご存知の」という組合せから、「教えて下さい。 / 宜しく / ご存知の」という組合せを作る)
- (e) 高精度の組合せ上位 30 組を選んで、共通の 2 句を含む 3 句の組合せから 4 句の組合せを作り、それぞれの精度を調査する。

上記のような句の組合せを用いるのは、組合せ爆発を防ぐ為である。本研究では「精度の低い組合せを含む組合せの精度は低い」ことを仮定し、データマイニングにおけるアプリアルゴリズムのアナロジで、上記のように句を組み合わせた。

先ほどの特徴度  $C_Q$ 、 $C_A$  は以下のように定義した。まず  $m(x, S)$  はテキスト  $S$  における句  $x$  の出現頻度、 $N(S)$  はテキスト  $S$  の延べ句数とする。また  $Q$  は質問のテキスト、 $A$  は回答のテキスト、 $Z$  は Web から無作為抽出テキストを表すものとする。ここで母比率の差の検定に関する次の尺度  $T$  を導入する：

$$T(x, S_1, S_2) = \frac{m(x, S_1)/N(S_1) - m(x, S_2)/N(S_2)}{\sqrt{p(1-p)(1/N(S_1) + 1/N(S_2))}}$$

ただしここで  $p = \frac{m(x, S_1) + m(x, S_2)}{N(S_1) + N(S_2)}$  とする。例えば  $T(x, Q, Z)$  は「句  $x$  が、無作為抽出されたテキストに比べて、質問テキストに偏って出現する度合い」を表すと言える。本研究では、句  $x$  が質問テキストに特徴的である度合い  $C_{Q(x)} = T(x, Q, Z) + T(x, Q, A)$  と定義する。同様に句  $x$  が回答テキストに特徴的である度合い  $C_{A(x)} = T(x, A, Z) + T(x, A, Q)$  と定義する。

上記のような和をとらず、 $T(x, Q, Z)$ 、 $T(x, A, Z)$  を単独で質問 / 回答テキストに特徴的な度合いとした場合、質問と回答のどちらにも出現する表現が「回答に特徴的な表現」とされる可能性がある。Web には質問だけ記されたページも多いが、本研究は Web から質問と回答の「対」を抽出しようとするものである。そこで「質問に比べて回答に特徴的な表現」を明確にし、それを検索に用いることで Web から質問のみを抽出してしまう事態を避けようと考えた。上記のように 2 つの  $T$  の和を特徴度としたのはその為である。ただしこの点についてはいくつかの検証が必要と考えている。

## 4 使用データ

まず Web からの無作為抽出テキストとしては、サーチエンジンで「は」を検索語としてヒットしたページのテキストを用いた。ページ数は 938 である。<sup>2</sup> サーチエンジンには Google を、構文解析ソフトには CaboCha を用いた。以下では本研究が用いた質問回答サイトにおける質問回答対 (以下「質問回答サイト QA」) と FAQ について述べる。

<sup>2</sup> このような抽出が無作為である保証はないが、その点については今後の課題とする。

## 4.1 質問回答サイト QA

日本の質問回答サイトとしては、教えて!goo (<http://oshiete.goo.ne.jp/>)、Yahoo!知恵袋 (<http://chiebukuro.yahoo.co.jp/>)、OKWave (<http://okwave.jp/>) などがある。<sup>3</sup> 本研究では OKWave における質問回答対をデータとして用いた。OKWave は質問回答サイトの中では草分け的な存在であり、提携している質問回答サイトも多いので採用した。<sup>4</sup>

OKWave では 11 のカテゴリーを設け、それぞれの下にサブカテゴリーを設けている。本研究では、この 11 カテゴリーと欄外にある「この Q&A コミュニティーについて」というカテゴリーを入れた 12 個それぞれの下にあるサブカテゴリー 2 個ずつから、30 個ずつ質問回答対を抽出することを試みた。全部で 636 個を調査用質問回答対 QA とした。<sup>5</sup>

## 4.2 FAQ

Google で「FAQ」「Q&A」「よくある質問」「一問一答」という検索語でヒットしたページのうち、3 個以上 20 個以下の箇条書きの形で質問回答対を提示しているページを本研究では FAQ ページとみなし、そこに含まれる質問回答対をデータとして用いた。全部で 630 個を調査用 FAQ とした。「20 個以下」という制限を設けたのは、少数の特定テーマのサイトが、結果に大きく影響を与えることを防ぐ為である。<sup>6</sup>

## 5 結果と考察

### 5.1 有用な表現

3 節で述べた手法によって、質問回答それぞれに特徴的とされた表現の上位 10 個は表 1・2 の通りである。FAQ の方では「年金が」「スパイスの」など、各サイトのテーマと密接に関連した表現がいくつか抽出された。その意味で FAQ の方が質問回答サイト QA よりも、質問回答に真に特徴的な表現というものが少ないのかも知れない。

「質問回答対自動抽出に有用な表現」は表 3 ~ 8 の通りである。各表右端の件数は、Google でヒットした上位 20 件中質問回答対を含むページが何件ヒットしたかを表している。表から分かるように質問回答サイト、FAQ ページともに、2 句、3 句と組み合わせると件数が増え、その意味で抽出精度が高くなっている。だが質問回答サイトに関しては 4 句の組合せにおける精度は、3 句の場合よりも低くなっている。質問回答サイトに関しては 3 つ程

<sup>3</sup> 海外には Yahoo!Answers (<http://answers.yahoo.com/>)、Wondir (<http://www.wondir.com/wondir/jsp/index.jsp>)、answerbag (<http://www.answerbag.com/>) などがある。

<sup>4</sup> OKWave では、質問や回答をする場合には会員登録をすることになっている。登録は無料であるが、これがユーザに責任感を持たせ、信頼できる回答が寄せられていることを本研究では期待している。

<sup>5</sup> カテゴリーによっては 1 個しかサブカテゴリーがなく、また質問回答対が 30 件に満たないサブカテゴリーなどもあった為、総数は 720 になっていない。

<sup>6</sup> サイトによってはクレジットカードに関する 100 近い質問回答対を提示しているものもある。

質問表現	$C_Q$	応答表現	$C_A$
よろしく	53.3	方が	21.9
宜しく	30.1	私は	18.2
どなたか	29.0	私に	16.9
ご存知の	23.1	思います。	14.4
方、	22.4	言う	12.9
教えて	22.3	ほうが	12.2
何か	20.7	と	11.4
教えてください。	19.3	あります。	11.3
そこで、	18.5	私も	10.7
最近	18.5	もし	10.3

表 1: 質問応答サイト QA の質問と応答それぞれに特徴的な表現

質問表現	$C_Q$	応答表現	$C_A$
どう	46.9	あります。	23.4
Q .	45.1	ことが	23.4
何ですか	37.4	できます。	22.5
どのような	34.5	また、	14.9
あるのですか	33.3	可能です。	14.8
どんな	29.1	なりません。	14.6
過ぎましたが、	27.4	著	14.6
年金が	25.8	ことも	14.5
振り込まれていません。	25.3	スパイスの	13.9
<問> 年金の	25.3	著作物を	13.5

表 2: FAQ の質問と応答それぞれに特徴的な表現

度の句を組み合わせるのが良いのかもしれない。

表 4・5 を見ると、表 1 で応答に特徴的な表現とされたもの(「方が」「私も」など)が含まれていることが分かる。同様に表 7・8 にも、応答に特徴的な表現(「あります」「ことが」など)が含まれている。従って質問応答対をヒットさせるには、質問に特徴的な表現だけでなく、応答に特徴的な表現も組み合わせることで検索した方が良いことが言えた。

さて抽出の評価においては一般に、精度だけでなく再現率も検証する必要がある。だが Google を含む多くの検索エンジンでは、検索結果は 1,000 件程度しか表示されない。従って厳密な再現率検証は難しい。今回のような 20 件ではなく 1,000 件における精度を算出し、その値を評価尺度とするのが現実的と思われるが、作業コストを考え、この点については今後の課題とした。

教えて	どなたか	17 件
教えてください。	言う	17 件
教えてください。	どなたか	17 件
教えてください。	ほうが	17 件
教えて	思います。	16 件
教えてください。	宜しく	16 件
教えて	方が	15 件
教えてください。	宜しく	15 件
教えてください。	私も	15 件
教えて	ご存知の	14 件
教えてください。	ご存知の	14 件
教えてください。	と	14 件
教えてください。	何か	14 件
教えてください。	私は	14 件
どなたか	ご存知の	14 件
どなたか	方が	13 件
どなたか	言う	12 件
どなたか	と	12 件
どなたか	方、	12 件

表 3: 質問応答サイト QA に特徴的な 2 句の組合せ

どなたか	教えて	方が	20 件
教えてください。	言う	ほうが	19 件
教えてください。	思います。	ご存知の	19 件
教えてください。	思います。	私は	19 件
教えてください。	思います。	私も	19 件
教えてください。	ほうが	ご存知の	19 件
教えてください。	ほうが	方が	19 件
教えてください。	宜しく	と	19 件
どなたか	教えて	と	19 件
どなたか	教えてください。	方が	19 件
どなたか	教えてください。	と	19 件
どなたか	教えてください。	言う	18 件
どなたか	教えてください。	方、	18 件
どなたか	教えて	方、	18 件
教えてください。	思います。	宜しく	18 件
教えてください。	方が	私は	18 件
教えてください。	方が	私も	18 件
教えてください。	宜しく	方が	18 件
教えてください。	宜しく	私は	18 件
教えてください。	宜しく	何か	18 件

表 4: 質問応答サイト QA に特徴的な 3 句の組合せ

教えてください。	思います。	私も	と	19 件
教えてください。	ほうが	方が	何か	19 件
教えてください。	ほうが	方が	ご存知の	18 件
教えてください。	ほうが	方が	ご存知の	18 件
教えてください。	ほうが	ご存知の	何か	18 件
教えてください。	思います。	ご存知の	何か	18 件
教えてください。	思います。	方が	ご存知の	18 件
教えてください。	思います。	私も	と	18 件
教えてください。	思います。	と	私は	18 件
どなたか	教えてください。	方、	と	18 件
教えてください。	教えてください。	方が	私も	18 件
教えてください。	教えてください。	方が	私は	17 件
教えてください。	思います。	宜しく	私は	17 件
教えてください。	思います。	私も	ご存知の	17 件
教えてください。	方が	私も	ご存知の	17 件
どなたか	教えてください。	教えて	と	17 件
教えてください。	ほうが	と	何か	16 件

表 5: 質問応答サイト QA に特徴的な 4 句の組合せ

あるのですか	あります。	20 件
あるのですか	Q .	20 件
あるのですか	できます。	19 件
何ですか	できます。	19 件
あるのですか	何ですか	18 件
あるのですか	また、	18 件
Q .	あります。	18 件
Q .	どのような	18 件
あるのですか	どう	17 件
何ですか	ことが	17 件
Q .	年金が	17 件
Q .	できます。	17 件
あるのですか	著作物を	16 件
あるのですか	どんな	16 件
どのような	あります。	16 件
何ですか	どのような	16 件
何ですか	年金が	16 件
あるのですか	ことが	15 件
あるのですか	ことも	15 件
あるのですか	年金が	15 件

表 6: FAQ に特徴的な 2 句の組合せ

