

## 意見文からの評判情報抽出に基づく自然言語検索

杉木 健二<sup>†</sup> 松原 茂樹<sup>††</sup>

本論文では、自然言語の検索クエリと意見文とを対応付けることにより、商品や宿泊施設などの意見対象を検索する手法を提案する。意見文から評判情報を抽出し、検索クエリから要求情報を抽出する。これらに対応付けし、各対象のスコアを計算することにより、クエリに合致する対象を表示する。近年、意見文を対象としたテキストマイニングに関する研究が盛んに行われており、意見文から評判情報を抽出する研究が多く行われてきた。しかし、このような情報を用いて商品や宿泊施設などを検索しようとする試みはほとんどない。提案手法では、係り受け関係に基づく構造パターンを用いて意見文から評判情報を抽出する。抽出した評判情報と検索クエリから抽出した要求情報の一致率によってそれらに対応付ける。検索対象のスコアリングは、 $tf \cdot idf$  を拡張することにより実行する。実験では、本手法を用いたシステムの意見文検索の精度は 91.9% であり、検索対象を高い精度で検索することができる可能性を確認した。

### Natural Language Retrieval System Based on Opinion Extraction

KENJI SUGIKI<sup>†</sup> and SHIGEKI MATSUBARA<sup>††</sup>

In this paper, we propose a method for extracting opinion tuples (opinion object, opinion view point, opinion value) from customer reviews and retrieving objects (products, store, accommodations, etc.) using these tuples. Recently, many methods of opinion extraction from customer reviews in web pages were proposed. However, there are few work to retrieve objects which is the opinion target using these opinions with natural language query. Our system extract opinion tuples using syntactic structural patterns which include modification relation between bunsetsus. And then, the system compares these opinion tuples and the tuples extracted from the user query, and ranks opinion objects using a  $tf \cdot idf$ -like scoring formula. The precision rate of extracting relevance opinions by the system was 91.9%.

#### 1. はじめに

近年、blog や SNS をはじめとして、個人が Web 上に意見を発信することが多くなってきている。これらの情報は、企業の危機管理や個人の意思決定支援などにも大きな影響を与えている。このような背景のもと、これらの意見文から評判情報を収集・抽出、または意見文を分析・要約するといったテキストマイニングに関する研究が盛んになっている<sup>1)~9)</sup>。しかし、評判情報を用いて、意見の対象となっている商品や宿泊施設などの評価対象を検索する研究はほとんど行われていない。

そこで本論文では、評判情報を用いて評価対象を検索する手法を提案する。本手法では、意見文から評判情報を抽出し、また、自然言語クエリから要求情報を抽出し、これらの情報に対応付けることにより、評価対象となる商品や宿泊施設を検索する。例えば、検索クエリとしては「部屋がきれいで、接客が気持ちよいホテルを探しています」という入力を想定する。上述のようなクエリに

対して、「部屋がきれい」、「接客が気持ちよい」と書かれた意見文と対応付けることにより、クエリに合致したホテルを出力するシステムの実現を目指す。

本研究では、評判情報に基づいた検索タスクを、意見文から評判情報を抽出するタスクと自然言語により検索するタスクの2つのサブタスクに分割する。

抽出タスクでは、意見テキスト中から評判情報を(評価対象, 評価視点, 評価値)の3つ組として抽出する。本研究では、ある評価対象について書かれた意見文を対象とするため、評価視点と評価値のペア(以下、評価値ペア)を抽出する。

検索タスクでは、まず、抽出タスクと同様の手法により検索クエリから要求情報((検索対象, 評価視点, 評価値)の3つ組)を抽出する。次に、要求情報と評判情報の一致率を定義し、これらに対応付ける。最後に、各評価対象をスコアリングし、スコアの高い順に結果を表示する。

本研究では Web 上の匿名性の高い個人が自由に記述した意見から評判情報を抽出し、スコアリングを行っており、情報の信頼性が問題となる。しかしながら、多くの人が商品や宿泊施設に対して同様の評価を与えていれば、その評価に対して客観性を持たせることができると考える。

以下では、まず、2 節で本研究のタスク設定について

<sup>†</sup> 名古屋大学大学院情報科学研究科  
Graduate School of Information Science, Nagoya University

<sup>††</sup> 名古屋大学情報連携基盤センター  
Information Technology Center, Nagoya University

述べる。3節で提案する検索システムについて説明する。4節で検索実験について報告する。5節で関連研究をまとめる。

## 2. 評判情報の抽出と検索

本研究の目的を達成するために、意見文から評判情報の抽出タスク、及び、評判情報を用いた検索タスクについて検討する。

### 2.1 検索のための評判情報抽出タスク

意見文から抽出すべき評判情報について検討する。本研究では、評判情報を(評価対象, 評価視点, 評価値)の3つ組として表現し、以下のパターンに合致するものをそれぞれ評価対象, 評価視点, 評価値とする。

(評価対象)の(評価視点)は/が/を/に(評価値)

評価対象： 意見の具体的な対象

評価視点： 評価対象のある評価における視点

評価値： 評価, 事実や状態

例えば「ホテルAの対応は最高でした」という文の場合、「ホテルA」が評価対象、「対応」が評価視点、「最高」が評価値となる。

評価値には、評価に加え事実や状態を含める。事実や状態に関する検索クエリが入力されることも十分に考えられるので、これらの情報も重要である。また、評価値の要素に評価値ペアをもつ場合がある。例えば「部屋は風呂がきれい」という文に対しては、(風呂, きれい)という評価値ペアだけでなく、(部屋, 風呂がきれい)という評価値ペアも抽出する。後者の評価値ペアも上記のパターンに合致する。

抽出タスクにおいて、意見文から評判情報を抽出する例を図1に示す。図1に示す意見文から、(宿泊-料金-価格, 安い), (宿泊-料金-価格, 大変-満足), (スタッフ-対応, とても-良い)という評価値ペアを抽出する。検索に用いるために、評価値ペアの要素はそれぞれ不要語を削除した形態素列であるとしており、本稿では図1のように各形態素をハイフン(-)で区切って表記する。評価視点に含まれる品詞は、名詞, 未知語のみであるとし、評価値に含まれる品詞は、名詞, 動詞, 形容詞, 未知語, 副詞であるとし、それ以外は不要語とした。

評価視点には「フロントの対応」といったような「の(助詞-連体化)」により係り受け関係にあるような複数の文節も含める。また、評価値には、形容詞や動詞を修飾する副詞も含める。

### 2.2 自然言語検索タスク

検索タスクでは「(評価視点)は/が/を/に(評価値)である(検索対象)」というパターンで記述された要求情報に該当する評判情報を検索する。ここで、検索対象とは、商品や宿泊施設などのクラスであり、例えば、ノートパソコン, 車, ホテルが該当する。検索対象と評価対象との関係は、instance-ofの関係である。

## 意見文

宿泊料金の価格が安くて大変満足しています。  
四人で泊まったのに部屋の広さも満足です。  
スタッフの方の接客もとても良かったです。  
次回も利用させていただきたいです。

評判情報(評価値ペア)

評価視点	評価値
宿泊-料金-価格	安い, 大変-満足
部屋-広さ	満足
スタッフ-接客	とても-良い

図1 意見文の例と抽出される評判情報

例えば、検索クエリとしては「(料理)が(おいしい)(ホテル)を探しています。」という文が考えられ、この場合、検索対象は「ホテル」、評価視点は「料理」、評価値は「おいしい」である。この(料理, おいしい)という評価値ペアに合致する評判情報を検索し、合致した評判情報に基づいて評価対象をスコアリングし、スコア順に評価対象を並べて表示する。

本研究では、検索対象を1つのクラスのみとし、クエリ中の評価値ペアと意見文中の評価値ペアとの対応のみを考える。

## 3. 評判情報を用いた自然言語検索システム

### 3.1 本システムの概要

本システムの処理構成を図2に示す。本システムは、(1)抽出処理部, (2)索引付け処理部, (3)検索処理部から構成される。

- (1) 抽出処理部 ある評価対象に対する意見文から評価値ペアを抽出をする。抽出処理では、まず、すべての文を係り受け解析する。次に、意見文のうち、要望を表す文を除去する。それ以外の文を節で分割し、各節内で主語・述語関係, 修飾・非修飾関係を解析し、評価値ペアを抽出する。最後に抽出した評価値ペアから不要語を除去し、評判情報とする。
- (2) 索引付け処理部 抽出した評判情報に対して、転置ファイルによる索引付けをする。
- (3) 検索処理部 まず、抽出処理と同様に、自然言語クエリから要求情報を抽出する。次に、要求情報の評価値ペアと評判情報の評価値ペアとのマッチングをとる。最後に、評価対象をスコアリングし、スコアの高い順に結果を表示する。

### 3.2 抽出処理

抽出処理では、評価視点と評価値は以下のようなパターンで出現することを考慮する。

- (1) (評価視点)は/が/を/に(評価値)
- (2) (評価値)(評価視点) : 修飾関係

それぞれの場合ごとに、意見文とそれから抽出される評価値ペアの例を以下に示す。

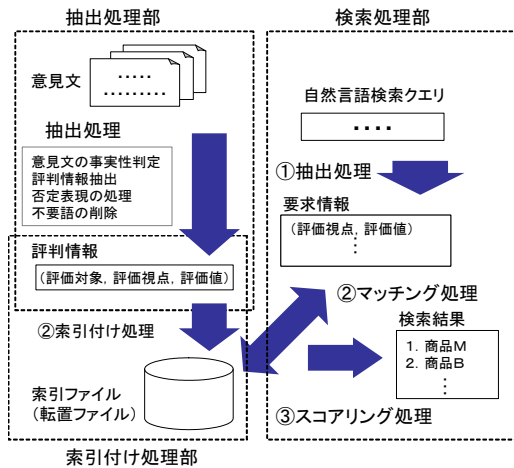


図2 システムの構成

(1) の場合

- (i) 「フロント係の方の対応が非常に良い」  
⇒(フロント-対応, 非常-良い)
- (ii) 「朝食バイキングがおいしかった」  
⇒(朝食-バイキング, おいしい)

(1) のパターンの場合は、例が示すように、評価視点の文節が評価値の文節に係る関係にある。

(2) の場合

- (i) 「すてきなサービスでした」  
⇒(サービス, すてき)
- (ii) 「豪華な朝食がよかった」  
⇒(朝食, 豪華), (朝食, よい)

(2) のパターンの場合は、例が示すように、評価値の文節が評価視点の文節に係る関係にある。

それぞれのパターンごとに、以下に示すようなルール化ができる。

- 「は/が/を/に」を含む文節が評価視点となり、その文節の係り先である文節が評価値である。
  - 評価値を含む文節の係り先が評価視点の文節である。
- 本研究では、これらのパターン (1), (2) を拡張して評価値ペアを抽出する。

まず、(1) のパターンを考える。係助詞や格助詞を含む評価視点となる文節を  $X$ 、その文節の係り先の評価値となる文節を  $Y$  とする。「の (名詞-連体化)」を含む文節が  $X$  に係る場合、この文節も  $X$  に含め、 $X$  以降の  $Y$  に係る文節も  $Y$  に含めるとする以下のパターンとして形式化できる。

- (1-1)  $X \Rightarrow Y$   
(例: 夕食が ⇒ おいしい.)
- (1-2)  $(X \Rightarrow Y_1) \Rightarrow Y_2$   
(例: (部屋が ⇒ 広いのが) ⇒良かった.)
- (1-3)  $X_1 \Rightarrow (X_2 \Rightarrow Y)$   
(例: 部屋は ⇒ (風呂が ⇒ 広い.)
- (1-4)  $((X_1 \Rightarrow Y_1) \Rightarrow X_2) \Rightarrow Y_2$   
(例: ((料理が ⇒ おいしい) ⇒ レストラン) ⇒

がある)

係り受け関係を「 $\Rightarrow$ 」で示す。

(1-1) の場合、 $(X, Y)$  を評価値ペアとする。(1-2) の場合、 $(X, Y_1), (X, Y_2)$  を評価値ペアとする。(1-3) の場合、 $(X_2, Y)$  と  $(X_1, X_2Y)$  を評価値ペアとする。(1-4) の場合は、 $(X_2X_1, Y_1), (X_2, Y_2)$  を評価値ペアとする。 $(X_1, Y_1)$  を抽出すると、上記の例の場合、「料理, おいしい」という評価値ペアが抽出できるが、「レストランの料理」という意味を含めるために、「(レストラン-料理, おいしい), (レストラン, ある)」という評価値ペアを抽出する。

次に、(2) のパターンを考える、 $X$  を評価視点を含む文節、 $Y$  を評価値を含む文節とすると、

(2-1)  $Y \Rightarrow X$

(例: おいしい料理)

というパターンが考えられ、 $(X, Y)$  が評価値ペアとなる。

これらのパターンにより「フロントは対応が親切で、きれいな部屋も満足でした。」という意見文を解析すると、以下のパターンが適用される。

$X_1 \Rightarrow (X_2 \Rightarrow Y_1)$  :パターン (1-3)

$X_3 \Rightarrow Y_3$  :パターン (1-1)

$Y_2 \Rightarrow X_3$  :パターン (2-1)

すなわち、「フロントは  $X_1 \Rightarrow$  (対応が  $X_2 \Rightarrow$  親切で  $Y_1$ ), (きれいな  $Y_2 \Rightarrow$  部屋も  $X_3$ )  $\Rightarrow$  満足でした  $Y_3$ 」となる。

上記のパターンより、以下の評価値ペアが抽出される。

$(X_1, X_2Y_1), (X_2, Y_1)$  :パターン (1-3)

$(X_3, Y_2)$  :パターン (1-1)

$(X_3, Y_3)$  :パターン (2-1)

これらの評価値ペアは、(フロント, 対応-親切), (対応, 親切), (部屋, きれい), (部屋, 満足) に相当する。

### 3.2.1 前処理

#### 係り受け解析と文節分割

まず、意見文を係り受け解析し、次に、主題が異なる節を分割するために、係助詞が両側の節に含まれる節境界で節を分割する。連用形、連用テ接続、接続助詞を節境界候補とする。

#### 要望文の除去

「～して欲しい」「～と望ましい」「～ば嬉しい」などの期待や願望、依頼などの要望表現を含む要望文は、著者が意図する意味や目的を考慮する必要があるため、今回は抽出対象とせず、これらの文を意見文から除いた。要望文を含む文であるかどうかは、要望表現が含まれているかどうかにより判定した。表1に要望表現の例を示す。「仮定形」や「命令形」の形態素が含まれる文、もしくは「のに」「たら」「たい」などの表現が含まれる文を要望文であるとする。

### 3.2.2 抽出処理

上述した以下の5つの抽出パターンにより、意見文から評価値ペアを抽出する。

(1)  $X \Rightarrow Y$

表 1 要望表現の例

要望表現 (一部)
ば (接続助詞), か (終助詞), ? (記号)
仮定形, 命令形
のに, たら, たい, ても, べき, もっと
欲しい, してください

- (2)  $(X \Rightarrow Y_1) \Rightarrow Y_2$
- (3)  $X_1 \Rightarrow (X_2 \Rightarrow Y)$
- (4)  $((X_1 \Rightarrow Y_1) \Rightarrow X_2) \Rightarrow Y_2$
- (5)  $Y \Rightarrow X$

前処理で分割した節内で、これらのパターンを適用する。まず、この節を、さらに前処理の節境界候補で分割する。次に、(1)~(4) のパターンを適用し、最後に (5) のパターンを適用する。

(1)~(4) のパターンを適用する方法について述べる。最初に (1) のパターンを適用し、さらに (2),(3),(4) のパターンを適用する。まず、各節内で、名詞もしくは未知語と格助詞もしくは係助詞を含む文節の中で最も右側にある文節を  $X_1$  とする。この文節  $X_1$  に対して、最も距離の近い係り受け関係にある文節  $Y_1$  に対して (1) のパターンを適用する。次に、(2)~(4) のパターンを適用する。 $Y_1$  に「の (名詞-非自立)」と格助詞か係助詞が含まれており、係り先の文節があればその文節を  $Y_2$  とし、パターン (2) を適用する。名詞か未知語、かつ、格助詞か係助詞を含む文節が左側にあるかを探す。あれば、 $X_2$  とする。 $X_2$  と  $Y_1$  が係り受け関係にあれば、パターン (3) を適用する。 $X_2$  が  $X_1$  と  $X_2$  の間の文節に係り、さらにその文節が  $X_1$  に係っていれば、その文節を  $Y_2$  とし、パターン (4) を適用する。

(1)~(4) のパターンを適用した後、(5) のパターンを適用する。(1)~(4) のパターンで抽出した評価視点  $X$  と形容詞や動詞、助動詞が含まれる文節  $Y$  が名詞や未知語が含まれる文節  $X$  に係る場合に対して適用する。 $Y$  に副詞が含まれる文節に係る場合はその文節も  $Y$  に含める。

節内に格助詞や係助詞が存在せず、上記のパターンを適用できない節がある。これらの節の場合、節を越えて係り元の文節が格助詞、係助詞を含んでいれば、その文節を  $X$  とし、パターン (1) を適用する。

抽出処理例を図 3 に示す。「フロントは対応が親切で、部屋はきれいで満足でした。」という文に対して前処理をし、主題が異なる節境界で分割する。次に、すべての節境界で分割し、左側の節に対してパターン (1) を適用し、さらにパターン (2) を適用する。右側の節に格助詞や係助詞が存在しないので、節を越えて係り元が格助詞や係助詞を含む節を探し、パターン (1) を適用する。最終的に、(フロント, 対応-親切),(対応, 親切),(部屋, きれい),(部屋, 満足) という評価値ペアが抽出される。

### 3.2.3 後処理

#### 否定表現処理

評価値に否定表現が含まれる場合は評価を反転させる

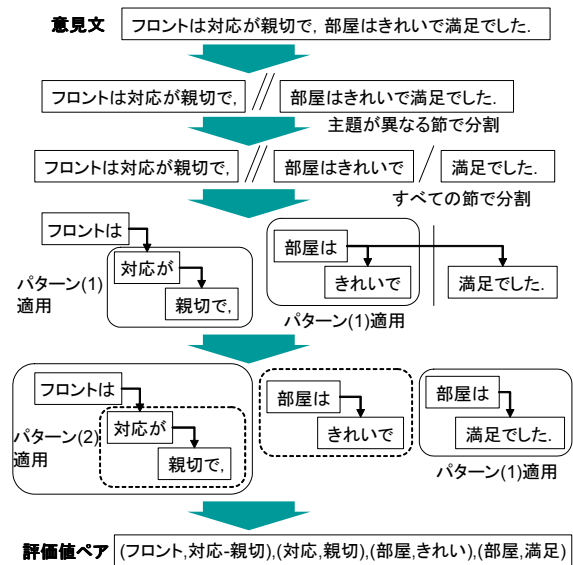


図 3 抽出処理例

処理をする。否定表現を「ありません」、「ない」、「なかった」、「ません」、「不 (接頭語)」とし、これらの表現が評価値に出現する場合、以下のように評価値を反転する。

- 「雰囲気は悪くありませんでした。」 (雰囲気,\*悪い)
- 「対応は不十分でした。」 (対応,\*十分)  
(\*は否定であることを表す)

この処理により、例えば「十分でない」「十分ではありません」「不十分だ」という評価表現を同じ評価値として扱うことができる。

#### 不要語の除去

評価視点、評価対象の形態素列を、名詞、形容詞、動詞、副詞、未知語のみ (自立語) とし、それ以外の助詞、助動詞、非自立語などの形態素を除去する。さらに「方」、「こと」、「もの」、「思う」、「考える」、「する」などの形態素も除去する。不要語除去の例を以下に示す。不要語に該当する助動詞と形態素「方」を除去している。

- 「料理はおいしかったです。」  
(料理, おいしい-た-です)  
(料理, おいしい)
- 「フロントの方の対応は最高でした。」  
(フロント-方-対応, 最高-です-た)  
(フロント-対応, 最高)

### 3.3 索引付け処理

評判情報を高速に検索するために、情報検索の分野で一般的な転置ファイルによる索引付けをする。転置ファイルの構成を図 4 に示す。評価値ペアファイルは評価視点、評価値と参照ファイルへのポインタを保持している。参照ファイルは、意見文の番号と意見文中の評価値ペアの位置情報を保持する。

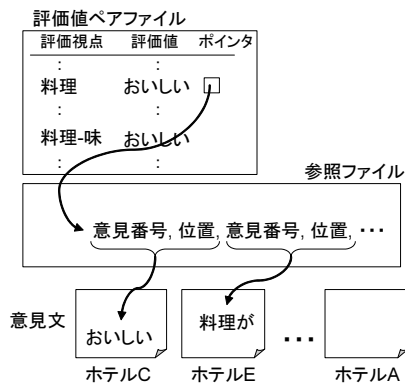


図4 転置ファイルの構成

$$c\_rate(i, j) = \begin{cases} \frac{EOP_{match}}{EOP_{all}} \times \frac{EV_{match}}{EV_{all}} & (*) \\ 0 & (otherwise) \end{cases}$$

\* 要求情報の評価値における末尾の形態素が評判情報の評価値中に存在

$EOP_{match}$  : 評価視点中の形態素一致数

$EOP_{all}$  : 評価視点中の全形態素数 \*

$EV_{match}$  : 評価値中の形態素一致数

$EV_{all}$  : 評価値中の全形態素数 \*

\* 要求情報と評判情報のうち形態素数が多い方の形態素数を適用する

図5 一致率の計算

### 3.4 検索処理部

検索処理ではまず、本抽出手法と同様の処理を検索クエリに対して行い、要求情報を抽出する。これらの要求情報における評価値ペアと各評価対象における評価値ペアとを一致率により対応付ける。評判情報を用いてスコア計算し、評価対象をスコア順に表示する。以降、マッチングとスコアリング手法について説明する。

#### 3.4.1 マッチング

要求情報の評価値ペアと評判情報の評価値ペアとを一致率により対応付ける。一致率を、図5に示す式を計算することにより求める。要求情報の評価値ペア  $P_i$  と評判情報の評価値ペア  $P_j$  との一致率は、評価視点中の全形態素数において形態素が一致している割合と、評価値中の全形態素数において形態素が一致している割合の積により計算される。ただし、全形態素数は要求情報と評判情報のうち、形態素数が多い方の形態素数とし、評判情報の評価値にこの形態素が含まれることを必須とする。

一致率を導入することの利点は、評判情報と要求情報との部分一致により対応がとれる点と、かつ、どれだけ一致しているかという程度を知ることができる点にある。

#### 3.4.2 スコアリング

スコア計算の方法を図6に示す。式の  $PF_{ij}, IOF_j$  は  $tf \cdot idf$  式のそれぞれ  $tf, idf$  に相当する。また、 $PF_{ij}$  は、評価対象  $O_i$  の評価値ペアの出現頻度とみなすことができ

$$Score(Q, O_i) = \sum_{P_j \in Q} PF_{ij} \cdot IOF_j$$

$$IOF_j = \log\left(\frac{1}{OF_j} + 1\right)$$

$$PF_{ij} = \sum_{P_{k_i} \in O_i} pf_{jk_i} \times c\_rate(j, k_i)$$

$OF_j$ : クエリ中の評価値ペア  $P_j$  との一致率が0より大きい評価値ペアが出現する評価対象数

$pf_{jk_i}$ : 評価値ペア  $P_{k_i}$  が評価対象  $O_i$  に出現する頻度

図6 スコア計算式

るが、クエリ中の評価値ペア  $P_j$  と完全に一致する  $O_i$  の評価値ペアの頻度に加え、部分一致となる評価値ペアも考慮することが望ましい。そのため、一致率と各評価値ペアの頻度との積を加えることにより  $PF_{ij}$  を計算する。

## 4. 検索実験

前節までの手法により試作したシステムの検索精度を評価する。

### 4.1 実験方法

本研究では、ホテルドメインに関する意見文を Web サイト から取得して、実験に用いた。Web ページから意見に該当する箇所を抽出し、CaboCha で係り受け解析したものを用いた。実験で使用した意見文書の数はいくつか (30 ホテル、各 300 意見文書) である。

検索精度を評価するために、検索システムは検索クエリに対して意見文書を返すシステムであるとし、検索クエリにより検索された意見文書集合の精度を求めた。つまり、あるクエリに対する検索結果の全意見文書の集合を  $A$ 、 $A$  の中で検索クエリと関連のある意見文書の集合を  $B$  とすると、精度は  $|B|/|A|$  で求めることができる。

表2に示す10個の検索クエリを設定し、各クエリに対する意見文書の精度と、これらの平均精度を求めた。平均精度とは、各クエリに対する精度の平均値である。また、各クエリに対する文書との一致率を求めた。検索クエリから抽出される評価値ペアと検索された文書の評価値ペアの一致率が0.5以上、0.3以上、0.2以上、0.1以上、及び、0より大きい意見文書を求め、これらの文書が検索クエリとどれだけ一致しているかを人手により求めた。

### 4.2 実験結果

表3に実験結果を示す。(1)~(9)のクエリに対する検索精度は一部を除き、どの一致率に対しても90%以上を維持しているが、(10)のクエリに対する精度は50%程度にとどまっており、他のクエリと比較してかなり精度が低かった。検索クエリに対して、それぞれの一致率の範囲での精度を見ると多少変動はあるものの、それぞ

楽天トラベル「お客さまの声」

[http://travel.rakuten.co.jp/auto/tabimado\\_bbs\\_top.html](http://travel.rakuten.co.jp/auto/tabimado_bbs_top.html)

<http://chasen.org/taku/software/cabocha/>

表 2 実験に用いた検索クエリ

検索クエリ	
(1)	部屋がきれい
(2)	立地条件が非常に良い
(3)	フロントの対応がよい
(4)	駅から近い
(5)	大浴場がある
(6)	コンビニがあって便利
(7)	インターネット接続ができる
(8)	アメニティが充実し満足できる
(9)	朝食が無料で、宿泊料金が安い
(10)	値段の割にサービスがよい

れの一致率に対する平均精度は 92% 前後とほとんど変化しておらず、一致率と精度との関係はあまり見られなかった。

#### 4.3 考察

すべての一致率に対して平均精度が 92% 前後と、比較的高い精度を維持できた。クエリに関連する意見文書が高い精度で検索されていることを示している。

当初は、一致率に閾値を設けて検索することが必要だと思われたが、実験結果では一致率が精度に与える影響はほとんど見られなかったため、閾値を設けず、マッチした意見文書のすべてに対して検索を行うのがよいといえる。

(10) のクエリに対する精度が他のクエリに対して低下した原因は「値段の割によい」というニュアンスがうまく検索できなかったことによる。つまり、クエリ中からは(値段-割, サービス-よい),(サービス, よい)という評価値ペアが抽出されるが、(サービス, よい) が出現する意見文の方が圧倒的に多く、この評価値ペアが優先的に検索されてしまうからである。このような「ある条件下での評価」というような構造的な意味を考慮して検索する方法を考える必要がある。

検索に失敗した他の要因を調べた結果、形態素解析や係り受け解析による失敗と、評価視点に複数の形態素が存在する場合に失敗してしまう場合が多かった。後者の例を以下に挙げる。

- (a) フロントの方も感じがよかったです  
(クエリ (3): フロントの対応がよい)
- (b) フロントの雰囲気もとてもよく  
(クエリ (3): フロントの対応がよい)
- (c) 冷蔵庫の飲み物の料金は安かったです  
(クエリ (9): 朝食が無料で、宿泊料金が安い)
- (d) このホテルのフロントの方の対応がよかったですとありましたので期待していた分、残念でした  
(クエリ (3): フロントの対応がよい)

評価視点は「フロントの対応」についてであるが、(a) は「フロントの感じ」が評価視点となり、(b) では「フロントの雰囲気」が評価視点となりいずれも失敗とした。(c) は宿泊料金とは関係がなく、明らかに間違いである。(d) は、他の人の意見を引用している部分であり、実際は残

念だったことを示している。

次に、判定がどちらとも取れるが、正解とした例である。

- (e) 部屋の掃除もきれいで  
(1) 部屋がきれい)
- (f) 部屋の内装がきれいで  
(1) 部屋がきれい)

これらは、評価視点「部屋」よりさらに具体的な評価視点「掃除」、「内装」が「きれい」であると判断し、正解とした。

意見文書に対する平均検索精度が 91.9% であったので、評価対象を検索するタスクにおいても高い精度を期待できる。検索においては再現率も重要な課題であるので、再現性がどの程度であるかを分析していきたい。

#### 5. 関連研究

評判情報検索、及び、評判情報抽出における関連研究との比較を以下に示す。

##### 5.1 評判情報検索

立石ら<sup>2)</sup> は、抽出した評判情報を用いて商品の評判情報を検索するシステムを提案している。この研究では商品名をクエリとしており、本研究の目的である商品などの対象を検索するシステムとは異なる。矢野ら<sup>10)</sup> は、抽出した評判情報と事前に与えられた個人の嗜好情報をもとに店舗の評価度を求めている。blog を対象にした、評判情報検索システム<sup>11),12)</sup> も提案されており、ある商品名を入力すると、意見のポジティブとネガティブの割合や、評価値のリスト、また、ポジティブ、ネガティブで出現しやすい商品の属性(商品のある側面)を表示する。

いずれも本研究のような、商品などの評価対象を検索するシステムとは異なり、各商品の評判を検索するシステムである。

##### 5.2 評判情報抽出

Hu ら<sup>5)</sup> は、高頻度の名詞句を連想ルールマイニングにより抽出、評価視点とし、評価値は評価視点と隣接する形容詞としている。Posesu ら<sup>4)</sup> は、評価視点候補を名詞句とし Web PMI により判定をし、さらに評価値を依存構造ルールから抽出している。

立石ら<sup>3)</sup> は、小規模の評価視点の辞書・評価値の辞書から共起パターンを用いて人手でブートストラッピング的に双方の辞書を増やすという方法を行っている。これらの辞書を用いて係り受け関係を利用した抽出パターンにより評価視点と評価対象の同定をしている。

本研究では、評価視点と評価値をペアも抽出しており、評価値が評価視点と評価値を含むような階層構造としている。この手法により、検索における再現率の向上や構造的な意味を反映した検索ができると考える。

#### 6. おわりに

本論文では、意見文から評判情報を抽出し、これらの評判情報と自然言語クエリから抽出した要求情報とを対

表 3 表 2 の 10 個の検索クエリに対する実験結果

クエリ	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	平均
精度 (一致率 ≥ 0.5)	100% (192/192)	100% (95/95)	100% (36/37)	98.2% (111/113)	98.3% (122/124)	98.2% (109/111)	84.6% (11/13)	100% (74/74)	99.0% (98/99)	40.0% (8/20)	91.8%
精度 (一致率 ≥ 0.3)	95.4% (201/202)	100% (99/99)	95.4% (42/44)	98.2% (112/114)	96.9% (128/132)	97.6% (123/126)	89.5% (17/19)	98.8% (82/83)	98.1% (105/107)	48.0% (12/25)	91.8%
精度 (一致率 ≥ 0.2)	99.5% (206/207)	99.5% (218/219)	94.2% (65/69)	98.5% (137/139)	96.3% (130/135)	95.6% (130/136)	94.4% (34/36)	98.9% (89/90)	98.4% (124/126)	51.9% (14/27)	92.7%
精度 (一致率 ≥ 0.1)	99.0% (208/210)	99.6% (224/225)	95.0% (77/81)	98.6% (141/143)	96.4% (132/137)	94.6% (141/149)	93.6% (44/47)	95.7% (88/92)	98.5% (132/134)	50.0% (14/28)	92.1%
精度 (一致率 > 0)	99.0% (209/211)	99.6% (225/226)	94.0% (79/84)	97.9% (141/144)	96.4% (132/137)	94.0% (142/151)	93.9% (46/49)	95.7% (88/92)	98.5% (134/136)	50.0% (14/28)	91.9%

応させることにより評価対象を検索する方法を提案した。本手法を実装した意見文書を検索するシステムは、検索クエリと関連した意見文書を高い精度で検索することができることを確認した。これは、検索システムが高い精度で評価対象を検索できる可能性があることを示唆する。

今後の課題は、自然言語クエリに対する類似意見や反対意見も考慮して検索することである。類似意見から抽出した評判情報や反対意見から抽出した評判情報も含めてスコアリングすることを検討する。また、再現率の評価と、従来の評判情報抽出との比較も検討する必要がある。

#### 参 考 文 献

- 1) 小林のぞみ, 乾健太郎, 松本裕治: 意見情報抽出のための評価対象・評価視点間の関係同定, 言語処理学会第 12 回年次大会論文集, pp.65-68 (2006).
- 2) 立石健二, 石黒義英, 福島俊一: インターネットからの評判情報検索, 情報処理学会研究報告, NL-144, pp.75-82 (2001).
- 3) 立石健二, 福島俊一, 小林のぞみ, 高橋哲朗, 藤田篤, 乾健太郎, 松本裕治: Web 文書集合からの意見情報抽出と着眼点に基づく要約生成, 情報処理学会研究報告, NL-163, pp.1-8 (2004).
- 4) Ana-Maria Popescu, Oren Etzioni: Extracting Product Features and Opinions from Reviews, *Proceedings of Joint Conference on Human Language Technology (HLT) and Conference on Empirical Methods in Natural Language Processing (EMNLP)* (2005).
- 5) Minqing Hu and Bing Liu: Mining opinion features in customer reviews, *Proceedings of the 19th National Conference on Artificial Intelligence (AAAI)*, pp.755-760 (2004).
- 6) Kanayama, H. and Nasukawa, T.: Deeper Sentiment Analysis Using Machine Translation Technology, *Proc. of 20th International Conference on Computational Linguistics (COLING)*, pp. 494-500 (2004).
- 7) 藤村滋, 豊田正史, 喜連川優: 文の構造を考慮した評判抽出手法, *DEWS2005*, 6C-i8 (2005).
- 8) 鈴木泰裕, 高村大也, 奥村学: Weblog を対象とした評価表現抽出, 人工知能学会セマンティックウェブとオントロジー研究会 (SIG-SW & ONT) (2004).

- 9) 小林のぞみ, 乾健太郎, 松本裕治: 意見情報の抽出/構造化のタスク仕様に関する考察, 情報処理学会研究報告, NL-171, pp.111-118 (2006).
- 10) 矢野宏美, 目良和也, 相沢輝昭: 嗜好を考慮した評判情報検索手法, 情報処理学会研究報告, NL164, pp.165-170 (2004).
- 11) blogWatcher, <http://blogwatcher.pi.titech.ac.jp/>
- 12) 奥村 学, 南野 朋之, 藤木稔明, 鈴木泰裕: blog ページの自動収集と監視に基づくテキストマイニング, 人工知能学会第 6 回セマンティックウェブとオントロジー研究会, SIG-SWO-A401-01 (2004).