

# テキストマイニングによる評価表現の収集

小林のぞみ<sup>†</sup> 乾健太郎<sup>†</sup> 松本裕治<sup>†</sup>  
立石健二<sup>‡</sup> 福島俊一<sup>‡</sup>

あらまし

近年、Web上に多数存在する掲示板などの文書から、意見情報を自動的に収集・解析する技術への関心が高まっている。このような意見情報の抽出には、評価を表す表現が重要な手がかりとなるが、評価表現には「コクがある」「液晶がきれい」といった領域依存の表現が多数存在するため、人手で書き尽くすことは困難である。そこで、我々は、テキストマイニングの技術を応用し、評価対象表現、属性表現、評価表現の共起パターンを利用して、これら領域依存表現を効率的に収集することを試みた。本稿では、共起パターンに基づく属性・評価表現の半自動的収集方法を提案し、「コンピュータ」と「ビール」の2つの領域を対象に行った経験的評価を報告する。

## Collecting Evaluative Expressions by A Text Mining Technique

KOBAYASHI, Nozomi<sup>†</sup> INUI, Kentaro<sup>†</sup> MATSUMOTO, Yuji<sup>†</sup>  
TATEISHI, Kenji<sup>‡</sup> FUKUSHIMA, Toshikazu<sup>‡</sup>

Abstract

It has been receiving increasing interest how to extract opinions from tremendous piles of Web documents. To automate the process of opinion extraction, a collection of evaluative expressions like "the monitor is fine" would be useful. However, it can be prohibitively costly to manually create an exhaustive list of evaluative expressions for each domain since they tend to be domain-dependent. Motivated by this background, we have been exploring how to accelerate the process of collecting evaluative expressions by applying a text mining technique. This paper proposes a semi-automatic method where we use particular patterns of cooccurrences between an evaluated subject, focused attribute and orientation expression, and reports the results of our empirical evaluation on the computer and beer domains.

## 1 はじめに

Web上に多数存在する掲示板サイトには、個人ユーザから寄せられた大量の文書が蓄積されている。それらの中には、組織や個人に対する評価や噂を述べた文言や商品・サービスに対する不満の声などが無数に含まれており、こうした文書からいわゆる意見情報（評判情報）

を自動的に収集・解析する技術への関心が高まっている [5, 8, 9, 10, 11, 12, 14]。

次の引用は、掲示板によく見られるタイプの記事である。

知り合いにちょっと使わせてもらったんですが、商品1は予想以上に使い勝手が良いです。なので、商品1を購入することにしました。でも商品2の、ソフトがたくさんある、っていうのも気に入ってるんですよ（使えるかどうかは疑問ですが）。電池の持ちは悪いんですけどね...

この例からも推測されるように、組織や商品・サービスに対する意見の主要部分は、〈対象, 属性, 評価〉の3

<sup>†</sup> 奈良先端科学技術大学院大学 情報科学研究科  
Graduate School of Information Science, Nara Institute of Science and Technology

<sup>‡</sup> NEC インターネットシステム研究所  
Internet Systems Research Laboratories, NEC Corp.

要素から構成されると考えられる。我々の目標は、Web ページからこのような形式の意見を抽出し

〈商品 1, 使い勝手, 良い〉  
〈商品 2, ソフト, 気に入る〉  
〈商品 2, 電池の持ち, 悪い〉

のような定型情報の組に変換することである。この目標への一つのアプローチとして、〈対象, 属性, 評価〉のそれぞれに該当する表現を、対象名辞書、属性表現辞書、評価表現辞書としてあらかじめ用意しておく方式を考える。このとき、もし 3 要素に関する十分な規模の辞書を作成できれば、意見の抽出は、(A) 与えられた文書内で、3 つの辞書に登録されたそれぞれの表現を検出し、(B) 検出した個々の対象、属性、評価を〈対象, 属性, 評価〉の組にまとめ上げる、という 2 つのステップで実現できる。しかし、実際には、対象、属性、評価のどれもが対象領域に大きく依存するので、辞書の網羅性を確保するのはそれほど容易でない。たとえば「電池の持ち」は、電気製品の属性にはなりうるが、料理の属性ではない。したがって、電気製品用の辞書には加えるべきだが、料理用の辞書には加えるべきでない。誤って料理用の属性辞書に入れてしまうと、それが情報抽出時のノイズになる恐れがあるためである。以上より、

どうすれば網羅性の高い対象名・属性表現・  
評価表現辞書を対象領域ごとに安価に構築  
できるか

ということが重要な問題となる。

この問題に対して我々は、テキストマイニングの考え方をベースにして、対象名、属性表現、評価表現の共起パターンから、対象表現と評価表現の 2 つを効率的に収集する方法を検討した。以下本稿では、共起パターンに基づく属性・評価表現の半自動的収集方法を提案し、「コンピュータ」と「ビール」の 2 つの領域を対象に行った経験的評価を報告する。

## 2 テキストマイニングによる属性・評価表現の収集

### 2.1 属性とは？ 評価とは？

何をもって組織や商品の属性、評価を表す表現と考えるかは議論を要する問題である。本稿では、哲学的議論を避け、形式的な定義としては次のような単純な必要条

件だけを仮定する。すなわち、次のテンプレート表現のフィルターになり得るものだけを属性表現、評価表現とする。

〈対象領域の組織・対象名〉の〈属性表現〉  
が/は/も/に/を〈評価表現〉

例えば「商品 1 の液晶は本当にきれい」という文をテンプレートに当てはめると、「〈商品 1〉の〈液晶〉は〈きれい〉」となり、対象名は「商品 1」、属性表現は「液晶」、評価表現は「きれい」と考えられる。また「商品 2 は使いやすいよね」という文ならば、テンプレートに当てはめると、「〈商品 2〉(の〈φ〉)は〈使いやすい〉」と考えられ「商品 2」が対象名、評価表現が「使いやすい」と考えられる。

### 2.2 収集方法

まず、共起パターンと対象名・属性表現・評価表現の各辞書を仮定する。属性表現・評価表現辞書は、それぞれ更に正例辞書と負例辞書からなるものとする。与えられた Web 文書に、共起パターンにマッチする部分が存在し、かつその表現のいずれかが辞書に存在するならば、他の部分を抽出できるのではないかと、というのが基本的なアイデアである。種となる小さな辞書が与えられれば、既知の評価表現から、共起パターンを用いて新しい属性表現を収集でき、逆に、既知の属性表現から新しい評価表現を収集することも可能であると考えられる。このサイクルを繰り返すことにより、種となる小規模の辞書を効率的に大規模化することができると期待できる。

収集の流れを図 1 に添って述べる。例として、共起パターン

【属性】が/は/も/に/を〔評価表現〕

と評価表現辞書を使って属性表現を収集することを考えよう。評価表現の正例辞書には「きれい」や「良い」といったいくつかの表現がすでに含まれているとしよう。このとき、もし与えられた Web 文書中に

... 商品 1 って 液晶 がとってもきれい!...  
... デザイン も良く、気に入っています ...

のような共起が存在すれば、そこから「液晶」や「デザイン」を属性表現の候補として獲得することができる。ただし、上の共起パターンで共起したというだけでは、

... 商品 2 って 意外 に良いね ...

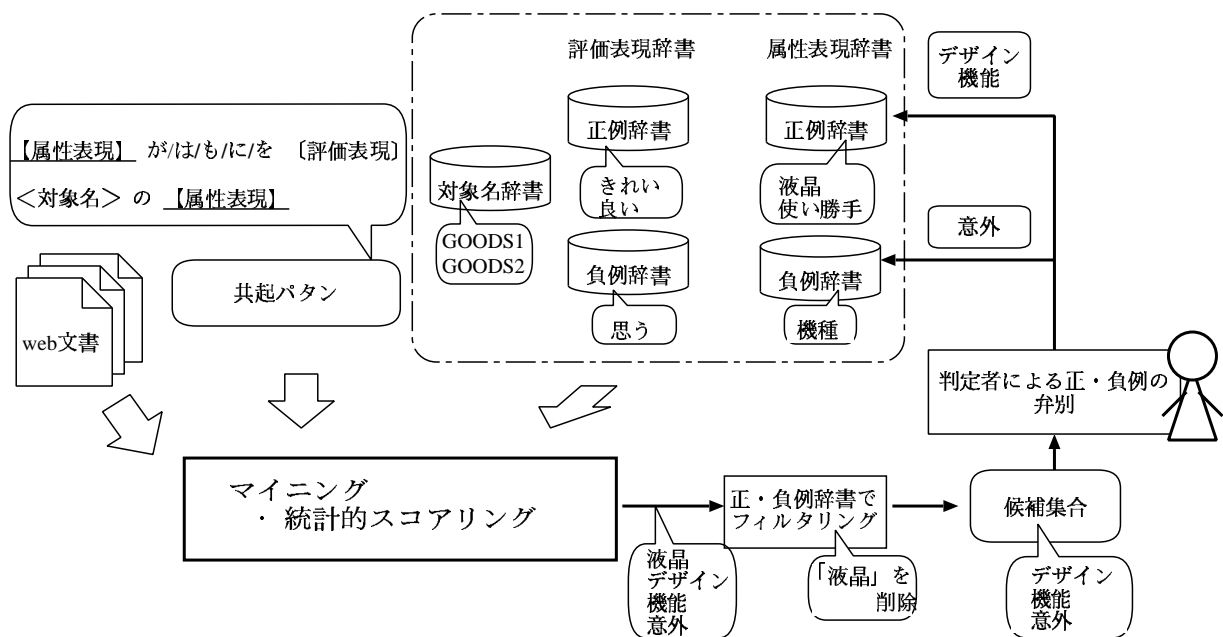


図 1: マイニングによる属性表現・評価表現の獲得

のような共起から「意外」が誤って抽出されてしまう。そこで、「共起の良さ」をはかる何らかの統計的尺度を使って候補をスコアリングする。これにより、候補集合が得られるわけであるが、属性表現の正例辞書または負例辞書に既に登録されている既知表現については、候補集合から除外しておく（図の例では、「液晶」が除外される）。

システムが出力した候補集合には、上述したようにスコアが与えられているが、そのスコアはあくまで統計的な確からしさの見積もりでしかない、よって、人手で各候補が確かに属性表現かどうかを判定するとする。判定者は、残った候補のうちスコアの高いものから順に任意個の候補を正例・負例に弁別すればよい。弁別結果は、それぞれ正例辞書または負例辞書に追加する。

評価表現、属性表現はそれぞれ評価、属性を表し得る最小の表現のみを辞書に登録する。例えば、「安すぎる」のような場合「安い」だけで評価表現となり得るので、「安い」のみを辞書に登録する。一方、「取り出し-やすい」のような場合は「取り出す」のみでは評価表現とはならないため「取り出し-やすい」で辞書に登録とする。

### 3 実験

前節で述べた手法を用いて実験をし、その評価を行った。

#### 3.1 具体的な共起パターン

2節で述べた共起パターンをもう少し具体化すると、次のようなパターンが考えられる。

下線部は候補として抽出する部分であり、その他の部分を辞書により与えるとする。

属性表現となり得るものは名詞か未知語、評価表現となり得るものはサ変名詞、動詞、形容詞、形容動詞と仮定する。それら以外の品詞の語は候補にしないこととする。

1. [ 評価表現 ] [ 属性表現 ]  
e.g. [ ガキっぽい ] [ デザイン ]
2. [ 評価表現 ] <対象名>  
e.g. [ 非力な ] <商品 1 >

パターン 1, 2 は、属性表現もしくは対象名を修飾する形で評価表現が現われるパターンである。候補として出力される表現は評価表現である。

3. <対象名> の【属性表現】が/は/も/に/を〔評価表現〕  
e.g. <商品 2 > の【液晶】は 本当に〔キレイ〕!
4. <対象名> の【属性表現】が/は/も/に/を〔評価表現〕  
e.g. <商品 3 > の【液晶】は〔見にくい〕.
5. 接頭詞【属性表現】(=〔評価表現〕)  
e.g. 低+【価格】、高+【品質】

パターン 3, 4 は, 3 つの表現のうち, いずれかの 2 つの表現が与えられた場合に, 残る 1 つの表現を候補として抽出するパターンである. また, パターン 4 は「接頭詞+属性表現」の形で出現する表現を, 評価表現の候補として抽出する.

以上 5 つに関しては制約が強いため, 候補として得られたものを全て人手で評価することとする.

6. <対象名> の【属性表現】  
e.g. <商品 4 > の【デザイン】
7. 【属性表現】が/は/も/に/を〔評価表現〕  
e.g. 【立ち上がり】が〔遅い〕
8. 【属性表現】が/は/も/の/を〔評価表現〕  
e.g. 【立ち上がり】が〔速い〕
9. 〔評価表現〕て〔評価表現〕  
e.g. 〔うるさく〕て〔嫌い〕

パターン 6~8 は, 3 つの表現のうち, 2 つの表現の共起を考えるパターンである. どちらかの表現が与えられた場合に, もう片方の表現を候補として抽出する. パターン 9 は, 評価の理由となっていると思われる部分を取り出すとするパターン [13] である. 例えば「〔うるさく〕て〔嫌い〕」の場合では「うるさい」ということが「嫌い」の理由となっていると考えられる.

これらのパターンについては, 制約が緩いため, ノイズが多くなる可能性がある. そこで, 候補に対し後述のようなスコアリングを行なった.

### 3.2 スコアリング

予備実験として, 頻度, 相互情報量, ダイス係数, 対数尤度比などの共起尺度を用いて, スコアリングを行なった. 出力された候補のうち, スコアの上位 100 件

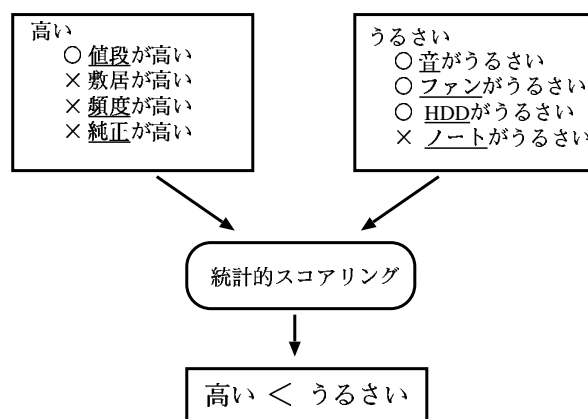


図 2: 信頼度に基づくスコアリング

を取り出して, それぞれ人手で弁別を行なった. その結果, 最も正例数が多かった尺度は頻度であった. 共起尺度があまり効果をなさなかった原因の一つとして, 頻度 1 の候補が多いことが挙げられる. 評価表現は記述者によってさまざまであり, 同じ記述が出にくいということが, その理由ではないかと考えられる. そこで今回の実験では, ベースとして頻度によるスコアリングを使用した. ただし, 頻度のみのスコアリングでは, 上述したように頻度 1 のものが多いため, スコアの低い部分にも正例が多く存在することが予想される. スコアの低い部分に正例が多く存在するならば, スコアリングを行なった結果とランダムに選んだ結果の精度が変わらないということも考えられる. そこで, 低頻度ではあるが正例となるべき表現のスコアを上げるために, その候補を抽出した表現の信頼性を用いてスコアリングを行なうことを考える.

例えば, 図 2 の場合を考える. 今「高い」という評価表現により「値段, 敷居, 頻度, 純正」という 4 つの属性表現の候補が抽出されたとする. このうち「値段」のみが正例であり, あとの 3 つは負例と考えられる. また「うるさい」という評価表現により「音, ファン, HDD, ノート」の 4 つの属性表現の候補が抽出されたとする. このうち「音, ファン, HDD」は正例と考えられ「ノート」は負例と考えられる. この例の場合「うるさい」という評価表現は「高い」という評価表現よりも正例となる候補を多く出力している. 言い換えると「うるさい」という評価表現のほうが「高い」という評価表現よりも属性表現と共起しやすいといえる. そこで「うるさい」に対して「高い」よりも高いスコ

アを与えることにする．このように，属性表現と共起しやすい評価表現や，評価表現と共起しやすい属性表現に対して重みづけを行なう．共起尺度には対数尤度比を用いた [1]．

### 3.3 設定

今回はビールとコンピュータに関する Web 文書を用いて，属性表現，評価表現の収集を試みた．使用した Web 文書は，コンピュータあるいはビールの商品名を含む Web 文書を，クローラを使用して収集した文書集合である．まずそれらの文書を，html タグなどを除去して一文ごとにする．その後，CaboCha [7] で係り受け解析を行ったものを入力として使用している．今回使用した文書はコンピュータが 91686 文，ビールが 102692 文である．

共起パタンは，3.1 で挙げたうちのパタン 1~8 を用いた．パタン 9 は，予備調査によると，使用したデータがそのような型にあまりあてはまらなかったためか，とれる数が少なく，とれた例も他のパタンにより獲得できるものがほとんどであった．そのため，今回の実験では使用しなかった．パタンの使用順序は，今回は 1, 2 → 3 → 4 → 7 → 8 → 6 → 5 の順に適用した．基本的に，制約の強いパタンを先に行ない，その後で制約の弱いパタンを行なうこととしている．パタン 5 については，属性表現辞書がある程度溜ってこなければ，候補を抽出できないため，制約の強いパタンではあるが，最後に適用している．パタンの使用順序の決め方については，正例の多そうなパタンを優先して動的に順序を制御するなど，工夫の余地がある．

初期辞書については以下の通りである．

|        | 対象名 | 属性表現 | 評価表現 |
|--------|-----|------|------|
| コンピュータ | 25  | 1    | 247  |
| ビール    | 9   | 1    | 247  |

対象名辞書には，あらかじめ持っていた対象名のリストを使用した．評価表現は，我々が以前作成した p/n 辞書 [6] のうち，評価表現と考えられる，形容詞 247 エントリを使用した．そのうちの一部を以下に示す．

高い，空しい，軽い，激しい，堅苦しい，口惜しい，好ましい，煩わしい，卑しい，美しい，麗しい，鬱陶しい，冷たい，美味しい，怖い，腹立たしい，物足りない，聞苦しい，明るい，優しい，勇ましい，雄雄しい，悪い，頼もしい，良い，強い，涙ぐましい，苦い，細かい

p/n 辞書は，単語もしくはフレーズに対し，望ましい事象 (positive) か，望ましくない事象 (negative) かを値として持つ辞書である．今回は表現を収集することが目的であるので，各表現が positive か negative かについては考慮しない．

また接頭詞は，IPA 品詞体系日本語辞書 [2] の接頭詞辞書のうち，以下の 24 個を使用した．

悪，バカ，好，多，低，下，重，長，少，ニセ，古，薄，ばか，短，難，高，アンチ，弱，快，大，超，偽，軽，小

### 3.4 収集精度に関する評価

表 1，表 2 に各サイクルで候補にあがった数，及び正例数，負例数を示す．表の数字は，獲得数 (正例数/負例数) である．ここでいう「正例」は，候補を手で判断したときに，属性または評価表現であると判断した事例である．また「負例」は属性または評価表現でないと判断した事例である．パタン 1~4 に関しては，候補として得られた表現を，全て手で正，負例に弁別しており，パタン 4~7 は，スコアの上位 100 件を手で正，負例に弁別している．

4 回の繰り返しにより獲得できた正例数は，コンピュータの属性表現が 201，評価表現が 318 であり，ビールの属性表現が 69，評価表現が 268 であった．

2 つの結果を比較すると，ビールの獲得数の少なさと，候補中の正例の少なさが目立つ．理由として，次の 2 つが考えられる．1 つは，もともとビールの属性となる表現が少ないということである．コンピュータの場合は，「ディスプレイ」，「キーボード」などの付属する機器が多く存在する．これらの表現はコンピュータの属性表現と考えられる．それに対しビールの場合は，付属する機器のようなものがない．そのため，属性表現はコンピュータよりも少なくなると考えられる．2 つ目の理由として，使用した文に，ビール以外の話題も多く含まれていることが挙げられる．実際に，使用した文書から，ランダムに抽出した 100 文についてそれぞれ確認してみた．コンピュータの方は，半分以上はコンピュータに関するなんらかの記述になっていた．それに対し，ビールの方は，ビールに関する記述であったものが，10 文程度であった．

次にパタンごとの精度について考察する．最も良かったパタンはパタン 5《接頭詞+属性表現》であった．このパタンは制約が強いため，獲得できる数は少ないが，

表 1: 繰り返し回数と獲得数：コンピュータ 獲得数 (正例数/負例数)

| pattern | 1 回目 |          | 2 回目 |           | 3 回目 |          | 4 回目 |          | 合計  |           |
|---------|------|----------|------|-----------|------|----------|------|----------|-----|-----------|
| 1,2     | 82   | (42/40)  | 154  | (77/77)   | 44   | (24/20)  | 23   | (9/14)   | 303 | (152/151) |
| 4       | 34   | (13/21)  | 55   | (15/40)   | 10   | (1/9)    | 6    | (1/5)    | 105 | (30/75)   |
| 5       | 9    | (8/1)    | 3    | (3/0)     | 2    | (2/0)    | 2    | (1/1)    | 16  | (14/2)    |
| 7       | 644  | (32/68)  | 935  | (25/75)   | 915  | (26/74)  | 851  | (39/61)  | 400 | (122/278) |
| 合計      | 225  | (95/130) | 312  | (120/192) | 156  | (53/103) | 131  | (50/81)  | 824 | (318/506) |
| 3       | 19   | (8/11)   | 87   | (19/68)   | 1    | (0/1)    | 0    | (0/0)    | 107 | (27/80)   |
| 6       | 713  | (30/70)  | 491  | (21/79)   | 370  | (18/82)  | 258  | (8/92)   | 400 | (77/323)  |
| 8       | 3931 | (35/65)  | 3798 | (26/74)   | 3677 | (24/76)  | 3594 | (12/88)  | 400 | (97/303)  |
| 合計      | 219  | (73/146) | 287  | (66/221)  | 201  | (42/159) | 200  | (20/180) | 907 | (201/706) |

表 2: 繰り返し回数と獲得数：ビール 獲得数 (正例数/負例数)

| pattern | 1 回目 |          | 2 回目 |           | 3 回目 |          | 4 回目 |          | 合計  |           |
|---------|------|----------|------|-----------|------|----------|------|----------|-----|-----------|
| 1,2     | 97   | (33/64)  | 143  | (80/63)   | 54   | (24/30)  | 2    | (0/2)    | 296 | (137/159) |
| 4       | 33   | (12/21)  | 14   | (4/10)    | 3    | (1/2)    | 0    | (0/0)    | 50  | (17/33)   |
| 5       | 6    | (4/2)    | 8    | (8/0)     | 0    | (0/0)    | 1    | (1/0)    | 19  | (17/2)    |
| 7       | 537  | (32/68)  | 623  | (21/79)   | 624  | (24/76)  | 538  | (20/80)  | 400 | (97/303)  |
| 合計      | 236  | (81/155) | 265  | (113/152) | 157  | (49/108) | 103  | (21/82)  | 765 | (268/497) |
| 3       | 17   | (5/12)   | 36   | (3/33)    | 18   | (0/18)   | 0    | (0/0)    | 71  | (8/63)    |
| 6       | 420  | (13/87)  | 301  | (10/90)   | 175  | (3/97)   | 73   | (3/70)   | 373 | (29/344)  |
| 8       | 7762 | (11/89)  | 7772 | (10/90)   | 7737 | (4/96)   | 7616 | (7/93)   | 400 | (32/368)  |
| 合計      | 217  | (29/188) | 236  | (23/213)  | 218  | (7/211)  | 173  | (10/163) | 844 | (69/775)  |

高い精度が得られた。逆に最も悪かったパターンは、パターン 6《<対象名>の【属性表現】》であった。このパターンは制約が弱く、対象名が「ノ格」で係っている先しか見ていない。そのため、「<シグマリオン>の場合」「<VAIO>の話」などの一般的な表現や、「<VAIO>のSRX」のように、対象名の型番になっている表現などが多く抽出されていた。パターン 6 とほぼ同じくらいの精度であったのが、パターン 8《【属性表現】が/は/も/の/を〔評価表現〕である。その原因として、評価表現の中に属性表現以外ともよく共起する表現が含まれていることが挙げられる。例えば、「する」という表現は「味がする」の場合は評価表現であるが「掃除をする」「気持ちがある」など、属性表現以外の表現と共起することが多い。このような表現が、ノイズの原因となると考えられる。

### 3.5 収集洩れに関する評価

次に、数回の実行により獲得できた表現について、同じ Web 文書を見ながら人手で作成した辞書をどれくらいカバーできているかを見た。コンピュータについては、使用した文書よりランダムに選び出した 350 文から人手で抽出した、属性表現 62、評価表現 99 につい

表 3: 被覆率：コンピュータ

|      | 被覆 | 未被覆   | 合計 |
|------|----|-------|----|
| 属性表現 | 47 | 15(5) | 62 |
| 評価表現 | 55 | 44(5) | 99 |

表 4: 被覆率：ビール

|      | 被覆 | 未被覆  | 合計 |
|------|----|------|----|
| 属性表現 | 14 | 2(1) | 16 |
| 評価表現 | 13 | 8(1) | 21 |

てカバレッジを見た。またビールについては、使用した文書よりランダムに 700 文を選び出し、人手で抽出した属性表現 16、評価表現 21 についてのカバレッジを見た。ここでビールの評価表現および属性表現が少ない理由として、3.4 節で述べたようにビールというドメインでは、属性表現自体が少ないことが挙げられる。また、使用したデータそのものにもかなりのノイズがあることも原因の一つであろう。

表 3、表 4 に被覆率を示す。( ) 内は辞書内には存在し

なかったが、候補として抽出されていた表現の数である。これらの表現は、人手で判断した上位 100 件の中には現れていなかったため、辞書に登録されなかった表現である。コンピュータで被覆できていなかった表現の中で、属性表現、評価表現について、それぞれ 2 つの表現が、正例辞書ではなく、負例辞書に登録されていた。これは、候補集合を判定するときに、実験では、その候補表現のみを見て判断したのに対し、Web 文書から表現を抽出した場合に、文全体を見て判断したため、ゆれが起こったことが原因であると考えられる。この 4 エントリを除いた結果を分析したところ、大きく次の 3 つの原因が見られた。

#### 1. 名詞 + 名詞の複合語

「駆動時間」(駆動 + 時間) のような場合、「駆動」のみでは属性表現とならず、「時間」のみでも属性表現とは考えにくい。よって「駆動時間」という表現で獲得しなければならない。

#### 2. 品詞の制約

今回は属性表現、評価表現となり得るだろう品詞を仮定し、それ以外の品詞のものは候補として出力しないようにしていた。しかし、次に示すように「高め」「横並び」といった一般名詞も評価表現となる場合がある。

- 値段もスペックも 横並び
- でもちょっと値段が 高め かな。

#### 3. 未知の対象名

ある対象名が辞書にあっても、その後ろに型番がつくと解析時に未知語となってしまう。例えば、「VAIO」が対象名辞書にあった場合でも、「VAIOU」は対象名とはとられない。

この問題は、既知の対象名を含んでいる未知語も対象名と見なすことにより、コンピュータのようなドメインに関しては解消できると考えられる。

### 3.6 ドメインの違いによる評価表現の違い

ビールとコンピュータという 2 つのドメインについて実験を行なったわけだが、収集された表現の違いについて述べる。

まず、ビールとコンピュータで共通していた属性表現は、「品質」「価格」「イメージ」「デザイン」「評判」など

17 エントリであり、ビールで負例となっていたが、コンピュータでは正例であったものが「システム」「使い方」「サイズ」「環境」「調子」「動き」など 24 エントリあった。

また評価表現では、共通していた表現が「少ない」「斬新」「きれい」「気に入る」「微妙」など 80 エントリであり、ビールで負例となっていたが、コンピュータでは正例であったものが「使いやすい」「便利」「壊れる」「食う」など 23 エントリであった。また逆に、コンピュータで負例となっていたが、ビールで正例となっていた表現は「純粹」「生きる」「なくなる」「無い」など 18 エントリあった。

この結果より、評価表現はドメインにそれほど強く依存しない表現もあることがわかった。これらの表現は、他のドメインに移ったときでも、使用することが可能だと考えられる。

一方、属性表現についてはやはりドメインに依存した表現がほとんどであるが、「価格」「品質」など、いくつかの表現は共通していた。これらの表現は「商品」というクラス自体が持つ属性と考えられる。

## 4 関連研究

近年、意見情報を自動的に分析する技術への関心が高まっている。分析の一つとして、意見を望ましい (positive) か、望ましくない (negative) かという観点で分類するという研究がある。これらの多くの研究では、それぞれ分析に必要な辞書を手で作成している。例えば、Turney, Pang らは、車や映画などのレビューについて、positive か negative かを判定する研究を行っている [14, 9]。一方、月出らは、TV 番組の自由回答文を用いて、良い意味合い (positive)、悪い意味合い (negative) の単語と、「集中度」「満足度」「期待度」などの評価値との相関についての分析を行っている [5]。また、長江らは、評価語と属性語 (我々の言う評価表現、属性表現と一致する) を用いて、製品を評価している文書が、肯定評価 (positive) か否定評価 (negative) かの判定を行なっている [8]。更に、顧客の問い合わせから否定、肯定表現を抽出しようとする研究 [12] もある。

構文における、意味的な素性の一つである「主観性」を当てるという研究も、関連研究としてあげられる。Hatzi-vassiloglou ら [3, 4] は、形容詞を主観性の判断のための手がかりと考えて、形容詞に positive, negative を自動

的に付与する手法を提案している。彼らの目標は、主観性の判断であるので、属性表現のような表現については考えられていない。

## 5 おわりに

本稿では、ドメインに依存する属性表現、評価表現を効率的に獲得する手法について述べた。その手法で実験を行なった結果、ノイズの多い文書からある程度効率的に表現を収集することができた。

今後の課題として、次の2つが考えられる。一つは、獲得できる表現のカバレッジを上げることである。そのために、有効なパタンを追加することが必要となる。また、今回は属性表現、評価表現となり得る表現の品詞を限定したが、それについても見直す必要がある。二つ目として、作成した辞書を使用して、その辞書が実際にどの程度利用できるかを検証を行なうことがあげられる。

## 参考文献

- [1] Ted Dunning. accurate methods for the statistics of surprise and coincidence. *Computational Linguistics*, Vol.19, No.1, 1993.
- [2] 浅原正幸, 松本裕治. IPA ユーザーズマニュアル ver 2.5.1, 30 January 2002.  
<http://chasen.aist-nara.ac.jp/chasen/doc/ipadic-2.5.1-j.pdf>
- [3] Vasileios Hatzivassiloglou, Kathleen R. McKeown. predicting the semantic orientation of adjectives. *Proceedings of the 35th Annual Meeting of the ACL and the 8th Conference of the European Chapter of the ACL*, pp.174-181, 1997.
- [4] Vasileios Hatzivassiloglou, Janyce M. Wiebe. effective of adjective orientation and gradability on sentence subjectivity. *Proceedings of 18th International Conference on Computational Linguistics, ACL*, 2000.
- [5] 月出奈都子, 石崎俊. TV 番組に対する自由回答文の印象抽出システム- インターネットアンケート調査による自由回答文の解析 -. 言語処理学会 第 6 会年次大会 発表論文集, pp.249-251, 2000.
- [6] 小林のぞみ, 乾健太郎, 乾孝司. 語釈文を利用した「p/n 辞書」の作成. 人工知能学会 言語・音声理解と対話処理研究会, SLUD-33, 2001.  
<http://cl.aist-nara.ac.jp/nozomi-k/pndic/>
- [7] 工藤拓, 松本裕治. チャンキングの段階適用による日本語係り受け解析. 情報処理学会論文誌, Vol.43, No. 6, pp. 1834-1842, 2002.
- [8] 長江朋, 望月源, 白井清昭, 島津明. 製品コンセプトと製品評価文章の関係の分析. 言語処理学会 第 8 会年次大会 発表論文集, pp.583-586, 2002.
- [9] Bo Pang, Lillian Lee, Shivakumar Vaithyanathan. thumbs up? sentiment classification using machine learning techniques. *Proceedings of the Conference on Empirical Methods in Natural Language processing (EMNLP)* pp.76-86, 2002.
- [10] 李航, 山西健司. 確率的コンプレキシティを用いたルール学習による自由記述アンケート分析. 言語処理学会第 7 会年次大会発表論文集, pp.379-382, 2001.
- [11] 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 NL144-11, pp.75-82, 2001.
- [12] 館野昌一. 「お客様の声」に含まれるテキスト感性表現の抽出方法. 情報処理学会研究報告 NL153-14, pp.105-112, 2003.
- [13] 徳久良子, 乾健太郎, 徳久雅人, 岡田直之. 言語コーパスにおける感情生起要因と感情クラスの注釈づけ. 人工知能学会 言語・音声理解と対話処理研究会, SLUD-31, 2001.
- [14] Peter D. Turney. thumbs up? thumbs down? semantic orientation applied to unsupervised classification of reviews. *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics (ACL)*, pp. 417-424, 2002.