

# 信頼度表現を考慮した評価文からの属性情報の抽出

## Attribute Information Extracting Method from Evaluative Sentences based on Grammatical Features

目良 和也  
Kazuya Mera  
広島市立大学

Hiroshima City University

矢野 宏実  
Hiromi Yano  
広島市立大学大学院

Graduate School of  
Hiroshima City University

市村 匠  
Takumi Ichimura  
広島市立大学

Hiroshima City University

**Abstract:** We propose a method to calculate the attribute's intensity of an object from multiple opinions. The intensity is calculated by min-max inference and the membership value of each degree group is obtained from the rate of collected opinions. The rate is calculated considering to the reliability of each opinion which are extracted from evaluative sentences on the WWW. Extracting the opinions from sentences, classifying the opinions into three degree groups, and applying the reliabilities of the opinions are done based on the grammatical features. Furthermore, in order to deal with such degree expression and reliability expression, we define a quintuplet dataset which consists of "evaluative subject," "focused attribute," "orientation expression," "degree expression," and "reliability expression."

### 1. はじめに

現在、インターネット上には多様で膨大な量の情報が存在しており、それらの情報を元に、我々は自分の好みに合わせて購入商品や旅行先などを選定することが出来る。しかし、個人サイトやblogの普及により情報発信が容易になったため、インターネット上の情報量は急速に増加しており、必要な情報がその他多くの情報に埋もれてしまうことも少なくない。このような事情から、インターネット上から対象に関する情報を自動的に収集し、ユーザの要望にあったものを提示できるようなシステムの研究が進められている。

複数の候補から各評価項目を考慮して一つの候補を選択するための手法として、AHPや多属性効用理論などがある。これらの手法では、評価項目間の重要度と評価項目に対する各候補のスコアを計算することで、各候補に対する総合得点を計算する。評価項目となる属性には、値段や数量のように定量的なもの、印象や味のように定性的なものがある。定量的な属性については、各候補の値と理想値を入力とする関数によってスコアを計算できる。一方、定性的な属性については上記のような比較方法が難しいため、一般的に一对比較などを用いてスコアを計算する。

しかしこの一对比較を行うためには、ターゲットユーザが全候補の全評価項目について知っていなければならない。そのため、未知の候補の中から自分の要望に合ったものを選択するといった場合には用いることが出来ない。

立石らは、このような定性的な属性情報を自動的に収集し、属性値を算出する手法を提案している[1]。この手法では、収集した文章から“商品名”と“評価表現”の対を抽出し、各評価軸に対する満足度と信頼度を算出する。評価表現には、あらかじめ肯定/否定の属性を与えておく。満足度は、各評価軸に属する肯定の意見と否定の意見の割合から算出され

る。信頼度は、各評価軸に属する意見の規模から算出される(図1)。

この手法を用いることによって、人々が定性的な属性に対して評価した結果を統合することができる。しかしこの手法では、「少し良い」、「とても良い」のような程度表現が含まれる意見であっても、それらの情報を考慮せずに全て同じ「良い」として扱ってしまう。また、「...かも知れない」、「...に違いない」のような意見の信頼度についても考慮することができない。

そこで本研究では、収集した意見に含まれる程度表現と信頼度表現を考慮した形で、属性の度合を求めるための手法を提案する。しかし、定性的な属性を扱う場合には、大きく二つの問題がある。一つは、定性的な属性はターゲットユーザの感受性や嗜好、過去の経験などに基づいて判断されるため、同じものに対しても異なる評価が存在するというものである。そしてもう一つは、例え同じ程度と認識されたとしても、自然言語記述で表現する際に、異なる表現が用いられうるというものである。

そのため、本手法では、属性の程度を表す副詞表現と、記述の信頼度を表す文末表現に注目する。そして、類似する副詞表現を3つの程度グループ(“少

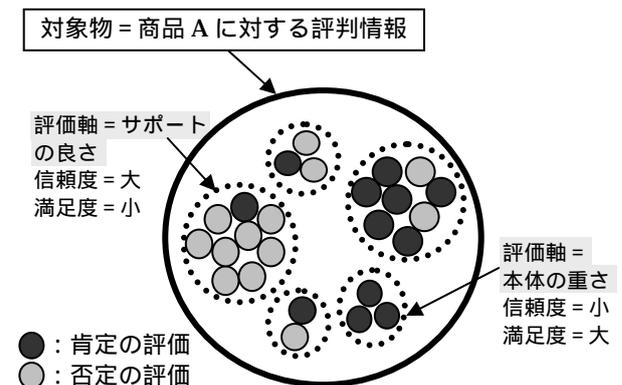


図1 評判情報のモデル [1]

し, “普通”, “とても”) に分類し, グループ内の意見の数や各意見に含まれる信頼度表現から各程度グループの意見比率を計算する. そして, この意見比率を各程度グループへの帰属度とみなし, Mamdani の min-max 推論によって得られた重心の値を評価属性のスコアとする.

## 2. 程度と信頼度を考慮した属性値計算手法

本稿では, 意見文に含まれる程度表現及び信頼度表現を考慮して, ある対象候補のある一評価属性に対する値を計算するための手法を提案する. 処理手順を図2に示す.

### I. 収集した意見文から, 必要な情報を抽出する

本手法では, まずインターネット上から対象候補の評価属性に関する評判記述を収集する. これらは検索エンジンに対象候補名と評価属性名をクエリとして与えることにより収集する. 次に得られた評判記述文から本手法適用に必要な情報を抽出する. 小林らは, “対象名”, “属性表現”, “評価表現” の3つ組の関係を表すテンプレート表現を定義し, このフィルターになり得るものを評価情報とみなしている[2]. 本研究の手法では, これらの情報セットに, “程度表現” と “信頼度表現” を加えた5つ組の評価情報を抽出する.

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

評価情報は, 形態素解析結果にテンプレートを適用することにより得られる. 我々は以前, “評価対象語”, “評価語”, “様相” の3つ組情報を抽出するための規則を作成していた[3]. 本研究ではその抽出規則を改良することで, 5つ組情報を抽出できるようにする. 新しく作成した規則を表1に示す.

表1 評価情報抽出規則 (一部)

Rules	
clause::=	(<SFE>   ) <phrase> (<SFE>   )
phrase::=	<Subj>の<Attr> (が/は/も/に/を) <OrieP>  <Subj> の <OrieP> な <Attr>  <Subj> の <OrieP>  <OrieP> (の/な/ ) (<Subj>   <Attr>)  <OrieP> のある <Subj>  <Attr> (が/は/も/に) <OrieP>  <OrieP> <Suffix> no <Attr>  <OrieP> <Subj>  <OrieP> <Attr> の <Subj>
Subj::=	<対象名> (<Para> <Subj> / )
Attr::=	<属性表現> (<Para> <Attr> / )
OrieP::=	(<Degree>   ) <評価表現>
Suffix::=	的   風   性
Para::=	や / と / また / または
SFE::=	(表3参照)
Degree::=	(表2参照)

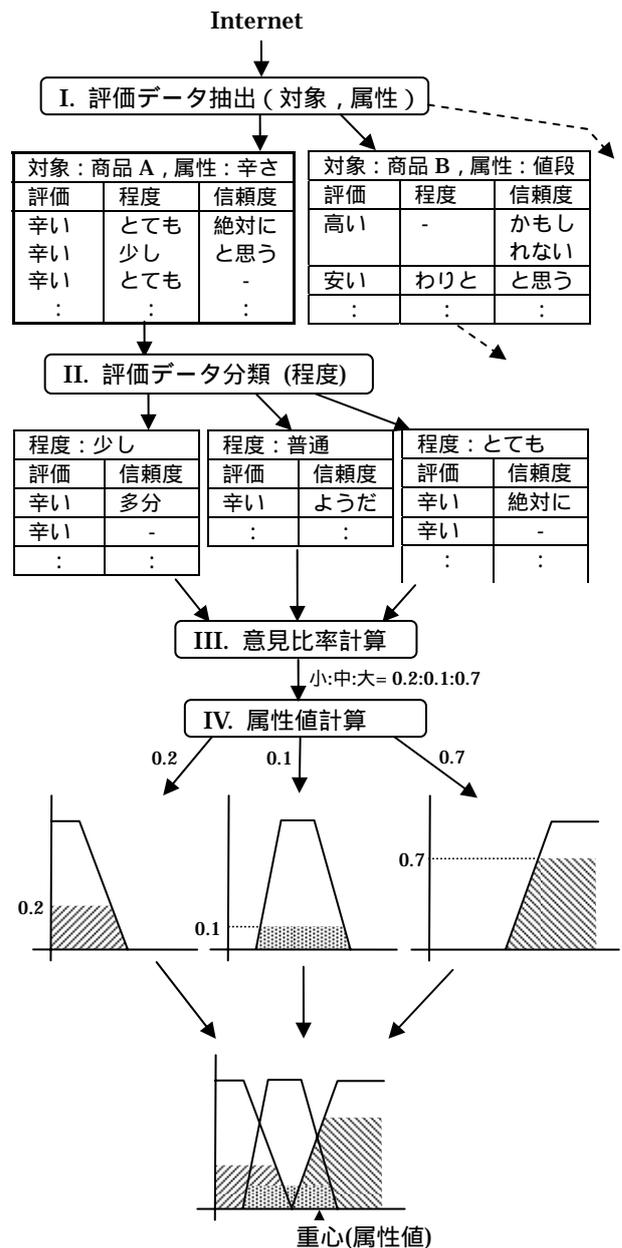


図2 本手法の処理の流れ

### II. 同等の程度表現同士グループに分類する

抽出された評価情報は, 同じ対象候補, 同じ評価属性に関するものであるが, これらをさらに同じ程度表現を持つもの同士のグループに分類する. 程度表現の分類については, 吉江らが提案した分類を参照し[4], 3グループに分類する. 表2に各程度表現のグループを示す. なお本稿は, 肯定時の程度表現に限定している.

表2 程度表現とそのグループ

非常に, ずいぶん, 結構, かなり, だいぶ, とても, 十分, よく, 相当
割と, 割合, 割に, まあまあ, 少し, ちょっと, 少々, 多少, いくらか
(程度表現をもたないもの)

### III. 各程度グループの意見比率を算出する

min-max 法を適用するために、分類された程度グループ内の意見数に沿って、各グループの意見の比率を求める。前述の立石の手法では、意見を肯定/否定の二種類に分け、それらの意見数から全体の評価属性の傾向を求めている。本研究では、意見の信頼度表現をもとに各意見の重みを変化させる。各程度グループの意見比率は以下の式で計算される。

$$R_A = \frac{\sum_i \rho_i}{\sum_j \rho_j} \quad (i \in A, j \in X)$$

$R_A$ はグループ  $A$  の意見比率を、 $\rho_i$ は意見  $i$  の信頼度を表す。信頼度表現とその値については、青山らの実験結果を参照している。青山らは、日本語の文末表現（肯定 26 種類、否定 42 種類）を含む文について質問紙調査を行い、[-100,100]の範囲で各表現の信頼度を算出した[5]。本研究では、これらの結果のうち、標準偏差が 20.00 未満の肯定表現 22 個を用いる（表 3）。

表 3 文末表現と信頼度（一部）

信頼度表現	信頼度
太郎は結婚する	93.10
太郎は結婚するだろう	67.80
太郎は結婚するかもしれない	49.40
必ず太郎は結婚する	93.40

### IV. 属性の程度値を算出する

III で求められた各グループの意見比率をそれぞれの程度への帰属度とみなして min-max 法を適用し、得られた重心を対象属性の度合とみなす。

ここで本来は、意見を述べた人物それぞれに応じたメンバーシップ関数を用意しなければならない。しかし Web 上からの意見収集という形態を取る場合、そのようなことは不可能である。そこで今回は、Hersh が 19 人の被験者に対して質問紙調査を行った結果得られたメンバーシップ関数（図 3）をもとに、それを簡易化したもの（図 4）を用いる。

#### 3. 評価実験

本手法の有効性を検証するため、大学生 6 名（男性 2 名、女性 4 名）に対して、以下の 3 種類の質問紙調査を行い、本手法の出力と比較した。

実験 1：「A は少し甘いと思う」という意見が 10 件あった場合にイメージする A の甘さを [0.0,1.0] で回答

実験 2：「A は少し甘いと思う」という意見が 10 件に加えて、「A はすごく甘い」という意見が 1 件～20 件あった場合にイメージする A の甘さをそれぞれ [0.0,1.0] で回答

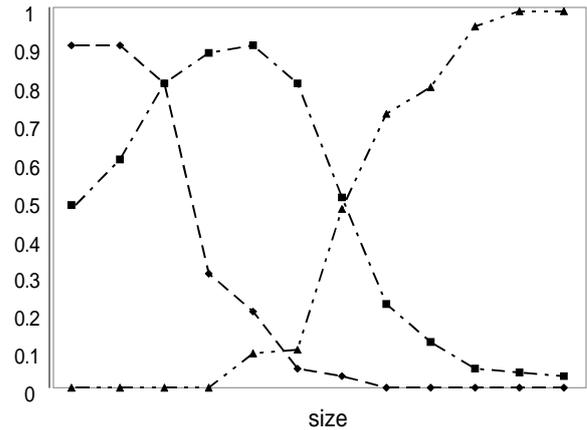


図 3 Hersh のメンバーシップ関数

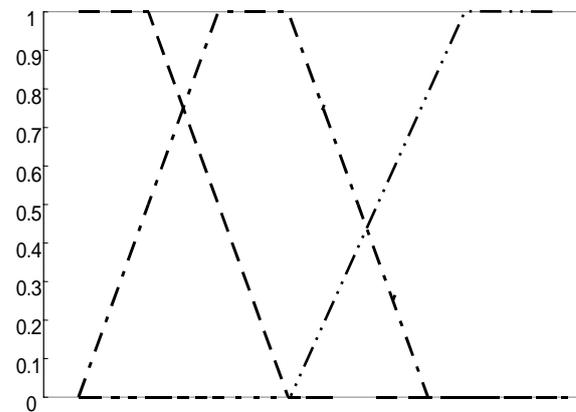


図 4 本手法で用いるメンバーシップ関数

実験 3：「A は少し甘いと思う」という意見が 10 件に加えて、「ひょっとすると A はすごく甘いかもしれない」という意見が 1 件～20 件あった場合にイメージする A の甘さを [0.0,1.0] で回答

実験 1 の結果を表 4 に示す。この結果より、「少し甘い」という意見からイメージする甘さの度合には、個人差があることがわかる。

次に実験 2、3 の結果を表 5 に示す。これより、異なる意見の数に応じてイメージが変化していることがわかる。また「ひょっとすると...かもしれない」のように信頼度の低い表現を含む意見の場合、断定の意見よりも当初の意見に与える影響が少ないことがわかる。この結果は、本手法による計算結果と一致する。

しかし実験 1 にあるように、各被験者によって、基準となるイメージは異なっている。このことより、本手法で得られる値は、比例尺度として認識するのではなく、順序尺度あるいは間隔尺度を求めるための値として解釈すべきである。

表4 「少し甘い」に対するイメージ

被験者	A	B	C
イメージ	0.1-0.2	0.1-0.3	0.1-0.3
被験者	D	E	F
イメージ	0.2-0.4	0.3-0.4	0.3-0.8

表5 異なる意見によるイメージの変化

意見数 (件)	回答範囲の平均値	
	「すごく甘い」	「...かもしれない」
1	[0.28, 0.58]	[0.23, 0.46]
2	[0.31, 0.65]	[0.26, 0.48]
5	[0.36, 0.75]	[0.33, 0.58]
10	[0.48, 0.83]	[0.38, 0.70]
20	[0.55, 0.95]	[0.60, 0.80]

#### 4. まとめ

本論文では、Web上に存在する複数の視点からの異なる意見をもとに、文中に含まれる程度表現および信頼度表現を考慮した形で対象の評価属性の度合を計算するための手法を提案した。そのためにまず、意見文から抽出される評価情報とその抽出規則を拡張した。そして、18種類の程度表現を強度ごとに3段階に分類した。信頼度表現については、22種類の文末表現を対象とした。そして、3段階の程度グループをそれぞれ対象属性に対するファジィ命題、各程度グループの意見比率を各命題への帰属度とみなし、min-max法を適用することで、複数の意見から統合的な値を算出できるようにした。この意見比率を求める際に、信頼度表現をもとに各意見の重みを変化させている。本手法の出力と質問紙調査の結果を比較したところ、本手法によって得られる属性値は、順序尺度を求めるために有効であることがわかった。

今後の課題としては、否定表現や反対語も考慮した属性値の計算や、各属性や被験者個人に合わせたメンバーシップ関数の修正などが挙げられる。特にメンバーシップ関数については今回図3の結果を簡易化したものを用いたが、今後は意見者の発話傾向や被験者の感覚をもとに学習を行い、それぞれの特性に合わせて図3のような詳細なメンバーシップ関数を作成できるようにする。

本手法の応用としては、未知概念が持つ属性情報を自動的に収集できるため、対象物の多属性評価だけでなく、感性情報に基づく評価や感情生起処理なども期待できる。

#### 参考文献

- [1] 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, 情報処理学会自然言語処理研究会, NL144-11, pp.75-82, 2001.
- [2] 小林のぞみ, 乾健太郎, 松本裕治, 立石健二, 福島俊一, テキストマイニングによる評価表現の収集, 情報処理学会研究報告 NL154-12, pp.77-84, 2003.

- [3] 矢野宏実, 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 NL164-28, pp. 165-170, 2004.
- [4] 吉江誠, 真偽疑問文に対する返答発話の肯定/否定意図解析手法の改良, 平成14年度広島市立大学大学院情報科学研究科修了論文, 2003.
- [5] 青山広, “真偽判断と確信度,” 計量国語学, 第21巻第1号, pp.1 - 10, 1997.

#### 連絡先

目良 和也  
 広島市立大学情報科学部  
 〒731-3194 広島市安佐南区大塚東 3-4-1  
 TEL: 082-830-1677  
 FAX: 082-830-1677  
 E-mail: mera@its.hiroshima-cu.ac.jp